

Curso: PSI3471 - Funda x + v

https://edisciplinas.usp.br/course/view.php?id=66581

Complemento ao enunciado preliminar da tarefa #3 - orientações adicionais / dicas

Caro/a aluno/a, confira aqui se está matriculado/a ou apenas inscrito/pendente (neste caso, você precisa contatar sua secretária de ênfase e informar-se de providências a tomar; se não reverter o "pendente", pode ser excluído) - atualizado em 14/03

Restrito Disponível se: Você faz parte de T-PSI3471-2019101

- Slides de apoio às atividades das aulas #1 a #4
- Slides de apoio às atividades das aulas #5, #6 e #7
- Slides de apoio às atividades das aulas #7 (alguns pontos revisitados) e #8, preliminar para estudo inicial
- Foto de lousa final na aula 8 - desenvolvemos passo a passo a derivação de Del Eqmi / Del W1A
- Fotos (3) de lousa final na aula 9 - desenvolvemos a derivação de Del Eqmi / Del WAC e detetamos redundâncias de fórmulas; também explicamos aprendizado batch e aprendizado online no MLP
- Apoio para atividade em sala de 27-março-2019 com entrega para nota

Exemplos de sistemas inteligentes usando técnicas de regressão multivariada e/ou reconhecimento multivariado (materiais usados como exemplos nas aulas do Prof Emilio)

- Lista / Inventário com Projetos PSI 2672 (disciplina prática de 5o ano) de 2011 até 2016
- Repositório (36Mb) de apresentações finais de PSI2672 (disciplina de 5o ano) nos anos 2011 a 2016 - perto de 50 projetos de alunos de 5o ano / Prof Emilio Del Moral Hernandez
- RESUMO DAS APRESENTAÇÕES FINAIS DOS PROJETOS DE PSI3571 EM 2018 (Disciplina de 5o ano)
- RESUMO DAS APRESENTAÇÕES FINAIS DOS PROJETOS DE PSI2672 EM 2017 (Disciplina de 5o ano)
- Vitrine com 10 apresentações finais de PSI5886-2018 (Princípios de Neurocomputação - Pós Grad); apresentações finais dos 10 grupos de alunos que cursaram a disciplina em 2018

Prof. Emilio Del Moral Hernandez

3

O Multi Layer Perceptron (MLP)

- Múltiplas entradas / Múltiplas saídas / Múltiplas camadas
- Variáveis (internas e externas) analógicas ou digitais
- Relações lineares ou não lineares entre elas

Proc. Não Linear de Sinais

Decisão


Estimação

Kolmogorov, Cybenko (~1990)

Prof. Emilio Del Moral Hernandez

5

Modelo Neural no modo de Treinamento



Prof. Emilio Del Moral Hernandez

6

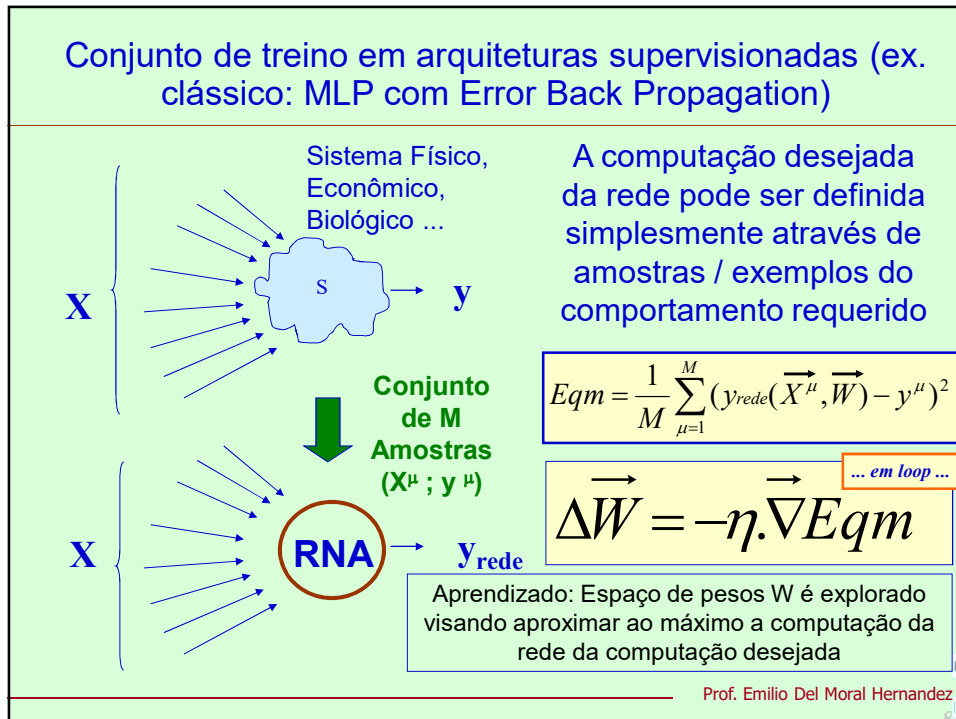
... erro da rede com relação ao conjunto de treinamento como um todo;
simbologia (X^μ ; y^μ); Erro quadrático de exemplar (Eq^μ); Erro quadrático
médio (Eqm)

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


μ identifica um de M exemplos de treinamento

Prof. Emilio Del Moral Hernandez

7



8



9

Método do Gradiente Aplicado aos nossos MLPs: a partir de um $W\#0$, temos aproximações sucessivas ao Eqm mínimo, por repetidos pequenos passos ΔW , 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^μ associado a um exemplo μ , e vá varrendo μ e somando os gradientes de cada Eq^μ , para compor o vetor gradiente de Eqm, assim que sair deste loop em μ ;
 - 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
 - Tire a média dos M gradientes individuais e dê um passo Delta ΔW nesse espaço, com direção e magnitude dados por $-\eta \cdot \text{vetor gradiente (Eqm)}$

Prof. Emilio Del Moral Hernandez

10


Processo de refinamentos graduais a cada iteração ...

$W\#0$	$Eqm\#0$	$GradEqm(W\#0)$	$\Delta W\#0 = -n \cdot GradEqm(W\#0)$
$W\#1$ (= $W\#0 + \Delta W\#0$)	$Eqm\#1$ (< $Eqm\#0$)	$GradEqm(W\#1)$	$\Delta W\#1 = -n \cdot GradEqm(W\#1)$
$W\#2$ (= $W\#1 + \Delta W\#1$)	$Eqm\#2$ (< $Eqm\#1$)	$GradEqm(W\#2)$	$\Delta W\#2 = -n \cdot GradEqm(W\#2)$
$W\#3$ (= $W\#2 + \Delta W\#2$)	$Eqm\#3$ (< $Eqm\#2$)	$GradEqm(W\#3)$	$\Delta W\#3 = -n \cdot GradEqm(W\#3)$
$W\#4$ (= $W\#3 + \Delta W\#3$)	$Eqm\#4$ (< $Eqm\#3$)	$GradEqm(W\#4)$	$\Delta W\#4 = -n \cdot GradEqm(W\#4)$
...
$W\#k$ (= $W\#k-1 + \Delta W\#k-1$)	$Eqm\#k$ (< $Eqm\#k-1$)	$GradEqm(W\#k)$	$\Delta W\#k = -n \cdot GradEqm(W\#k)$
...

Prof. Emilio Del Moral Hernandez

11

Comparando adaptação de pesos por visitas (em loop) unificadas / completas ao lote de M exemplo antes de cada adaptação, *versus* M adaptações parciais, exemplo a exemplo, com M subvisitas individuais aos M componentes do lote (revisitado em loop também): aprendizado em batch versus aprendizado online



$$\text{Grad}(\text{Eqm}) = \sum_{\mu} \text{Grad}(\text{Eq}^{\mu}) / M$$

$$\begin{aligned} \text{DeltaW\#0} &= - \eta \cdot \text{Grad}(\text{Eqm}) \\ &= \sum_{\mu} - \eta \cdot \text{Grad}(\text{Eq}^{\mu}) / M \\ &= \sum_{\mu} \text{DeltaW\#0}^{\mu} / M \\ &\sim \sum_{\mu} \text{DeltaonlineW\#0}^{\mu} / M \end{aligned}$$

Prof. Emilio Del Moral Hernandez

12

Treinamento em Batch (batelada) versus Online (serial) :


- O $\text{Grad}(\text{Eq}^{\mu})$ associado a apenas um exemplo específico $(X^{\mu}; y^{\mu})$ é obtido como desenvolvido nas aulas anteriores do módulo, devemos calcular tantas derivadas parciais $\partial \text{Eq}^{\mu} / \partial w_{xx}$ quantos pesos w_{xx} existam na rede.
- Fazemos esses cálculos através, por exemplo, das técnicas de retropropagação e dos passos direto e reverso. Assim calculamos todas as componentes $\partial \text{Eq}^{\mu} / \partial w_{xx}$ e compomos o gradiente de Eq^{μ} , referente a um μ específico (cada μ define um para entrada / saída de treino).
- ~~Cumulativamente, somamos esses M gradientes de exemplar, $\text{Grad}(\text{Eq}^{\mu})$, para ao final da varredura de μ , chegarmos ao vetor médio $\text{Grad}(\text{Eqm}) = \sum \text{Grad}(\text{Eq}^{\mu}) / M$~~

Adaptamos "online" os pesos w 's: $W_{\text{novo}} = W_{\text{anterior}} - \eta \cdot \text{Grad}(\text{Eq}^{\mu})$

Prof. Emilio Del Moral – PS12533 – EPUSP - direitos reservados consulte-me antes de qualquer uso externo a 2533

Prof. Emilio Del Moral Hernandez

13

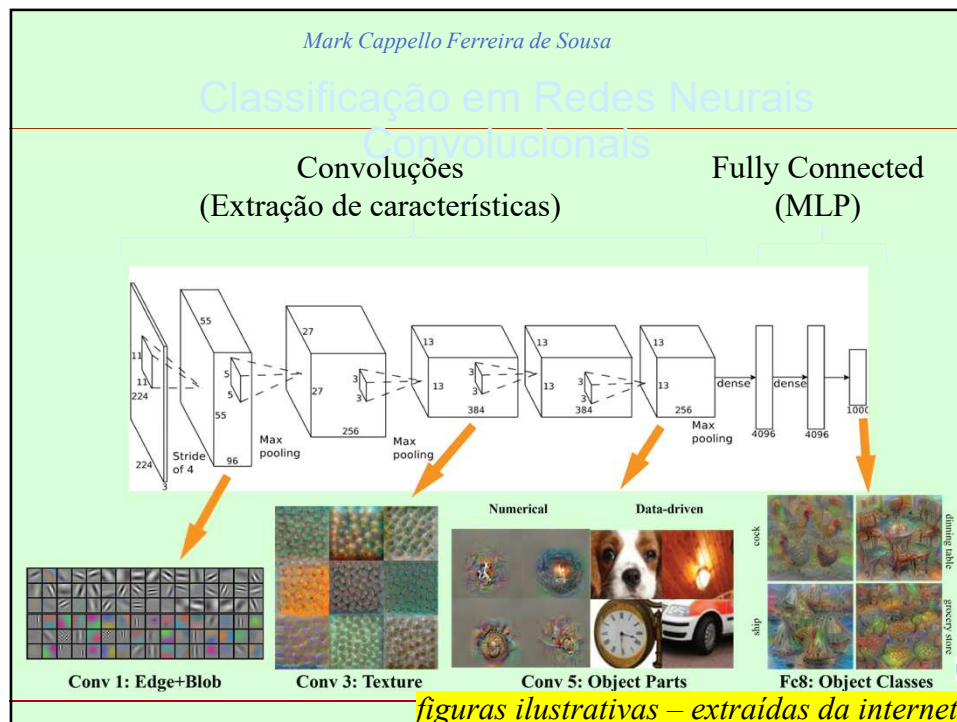


21

Falemos algo sobre as *Redes Neurais Convolucionais –* *ou ConvNets –* *ou Convolutional Neural Networks*

Trata-se de outra técnica atual de grande emprego no contexto de Deep Learning e que também traz algumas soluções para o sobreaprednizado em aplicações de alta dimensão de entrada

22



23

Convolutional Neural N

medium.com/@phidaouss/convolutional-neural-networks-cnn-or-convnets-d7c68850a207

Medium

About membership Tip: subscribe to a topic Sign in Get started

Input Volume (pad 1) (7x7x3)

$x[i, j, 0]$

0	0	0	0	0	0	0
0	0	0	1	0	2	0
0	1	0	2	0	1	0
0	1	0	2	2	0	0
0	2	0	0	2	0	0
0	2	1	2	2	0	0
0	0	0	0	0	0	0

$x[i, j, 1]$

0	0	0	0	0	0	0
0	2	1	2	1	1	0
0	2	1	2	0	1	0
0	0	2	1	0	1	0
0	1	2	2	2	0	0
0	0	1	2	0	1	0
0	0	0	0	0	0	0

$x[i, j, 2]$

0	0	0	0	0	0	0
0	2	1	1	2	0	0
0	1	0	0	1	0	0
0	1	0	2	1	0	0
0	2	2	1	1	1	0
0	0	0	0	0	0	0
0	0	0	0	0	0	0

Filter W0 (3x3x3)

$w0[i, j, 0]$

-1	0	1
0	0	1
1	-1	1

$w0[i, j, 1]$

-1	0	1
1	-1	1
0	-1	0

$w0[i, j, 2]$

-1	1	2
1	1	-1
0	-1	0

Bias b0 (1x1x3)

$b0[i, j, 0]$

0
0
0

Bias b1 (1x1x3)

$b1[i, j, 0]$

0
0
0

Filter W1 (3x3x3)

$w1[i, j, 0]$

0	1	-1
0	-1	0
0	1	1

$w1[i, j, 1]$

-1	0	0
1	-1	0
1	-1	0

$w1[i, j, 2]$

-1	1	2
1	1	-1
1	0	0

Bias b1 (1x1x3)

$b1[i, j, 0]$

0
0
0

Output Volume (3x3x2)

$o[i, j, 0]$

2	3	3
3	7	3
8	10	-3

$o[i, j, 1]$

-8	5	-3
-3	1	0
-3	-8	-5

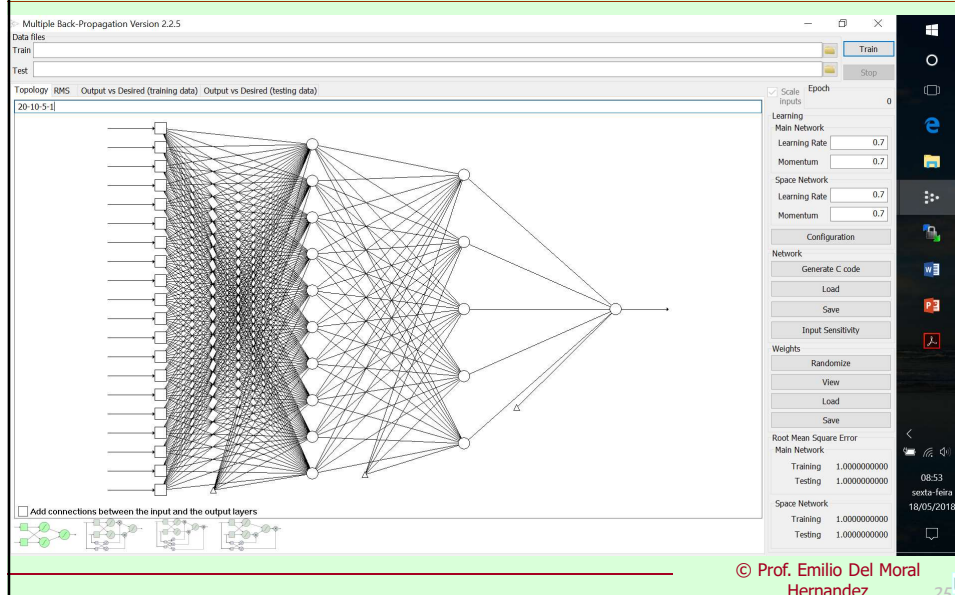
A demo of a Conv layer with $K=7$ filters, each with a spatial extent $F=3$, moving at a stride $S=2$, and input

Never miss a story from Firdaouss Doukali, when you sign up for Medium. [Learn more](#) [GET UPDATES](#)

© Prof. Emilio Del Moral Hernandez

24

Num MLP tradicional, quantos parâmetros “w’s” temos só na primeira camada (com digamos 10 neurônios) se a imagem de entrada tiver 1M pixels?




25

Teoria Redes Convolucionais


ConvNets – Convolução

© Prof. Emilio Del Moral Hernandez


26



29



30



31

Curso: PSI3471 - Fundai X

https://edisciplinas.usp.br/course/view.php?id=66581

- Slides de apoio às atividades das aulas #7 (alguns pontos revisitados) e #8, preliminar para estudo inicial
- Foto de lousa final na aula 8 - desenvolvemos passo a passo a derivação de Del Eqmi / Del W1A
- Fotos (3) de lousa final na aula 9 - desenvolvemos a derivação de Del Eqmi / Del WAC e detetamos redundâncias de formulas; também explicamos aprendizado batch e aprendizado online no MLP
- Slides de apoio às atividades da aula #10
- Video mencionado em sala sobre Redes Neurais Convolucionais (uma ferramenta de Deep Learning) -

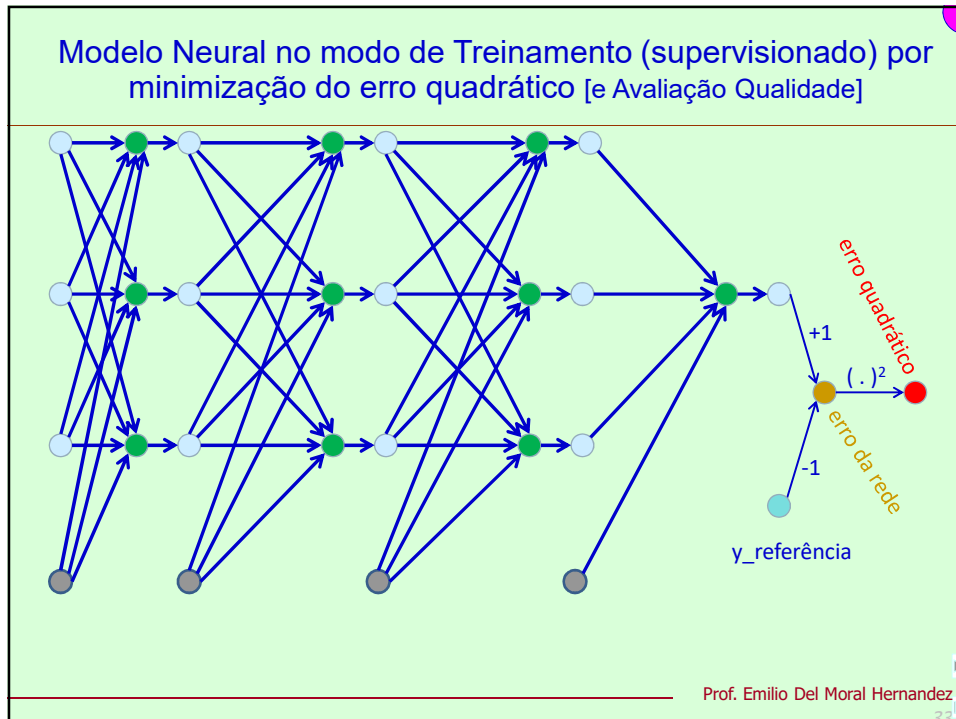
TAREFA #4 para entrega em escaninho e-disciplinas até dia 03 de abril (escaninho aberto no dia 28/março):

- Apoio para atividade em sala de 27-março-2019 com entrega para nota
- Enunciado postado em forma definitiva em 28-março fim do dia
- Entregue aqui a tarefa #4 - Derivação analítica + Cálculo de incrementos de 3 pesos sinápticos e avaliação de melhoria do erro quadrático + Tempo da tarefa

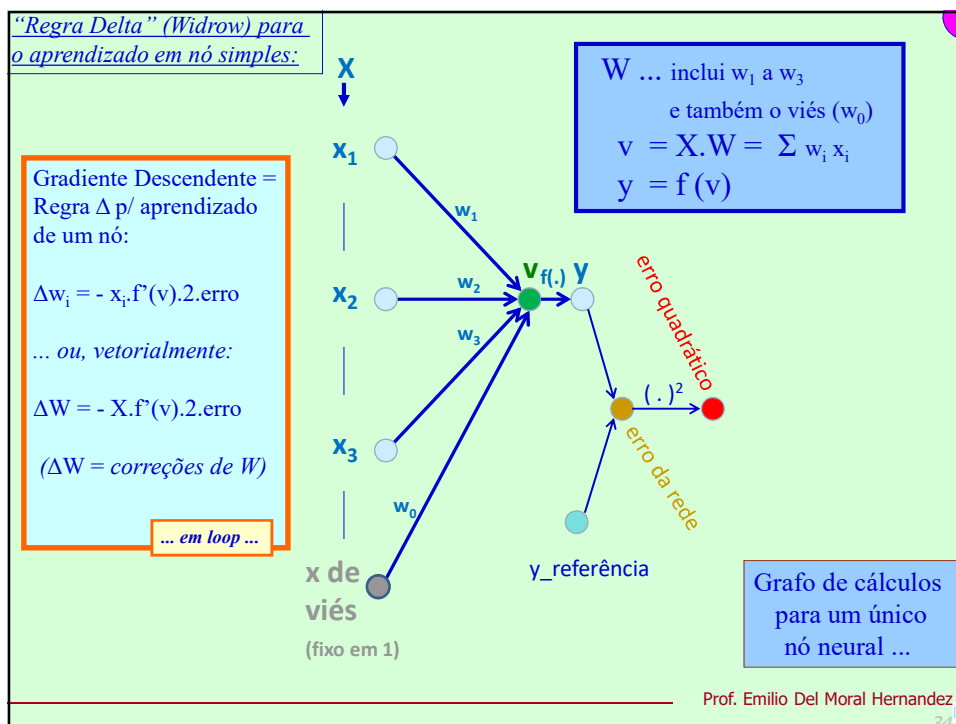
Exemplos de sistemas inteligentes usando técnicas de regressão multivariada e/ou reconhecimento multivariado (materiais usados como exemplos nas aulas do Prof Emilio)

- Lista / Inventário com Projetos PSI 2672 (disciplina prática de 5o ano) de 2011 ate 2016
- Repositório (36Mb) de apresentações finais de PSI2672 (disciplina de 5o ano) nos anos 2011 a 2016 - perto de 50 projetos de


32




33



34




42



43

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


44

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




Prof. Emilio Del Moral Hernandez

45



46



47

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

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

$$\partial E_{\mu} / \partial w =$$

$$= (2 \cdot \text{erro_rede}) \cdot (\partial y_{\text{rede}} / \partial y_{\text{nó}}) \cdot (\partial y_{\text{nó}} / \partial w)$$


$$= (2 \cdot \text{erro_rede}) \cdot \overset{\text{definição}}{\text{FatorRetroprop_nó}} \cdot (\partial y_{\text{nó}} / \partial w)$$

$$= (2 \cdot [\text{erro_rede} \cdot \text{FatorRetroprop_nó}]) \cdot (\partial y_{\text{nó}} / \partial w)$$

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

Prof. Emilio Del Moral Hernandez


48




Os triângulos representam os erros associados a cada nó

Prof. Emilio Del Moral Hernandez

49




50



51

Retropagação de erro envolvendo cadeia com trifurcação




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

Prof. Emilio Del Moral Hernandez

52

Retropagação de erro explorando recursão

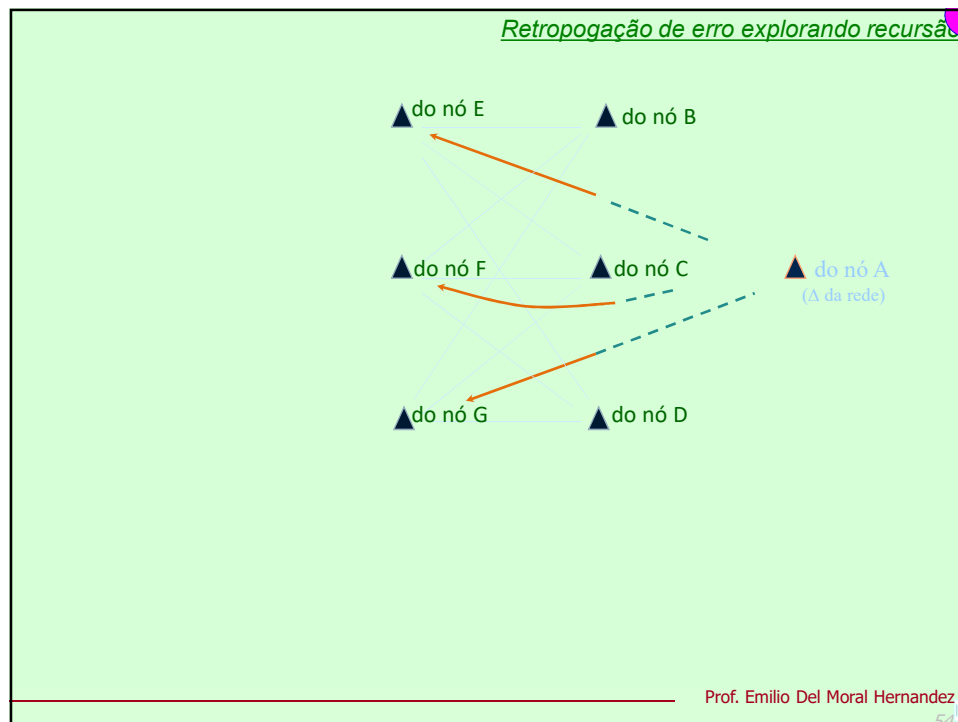


$$\begin{aligned} \text{erro E} &= \alpha \cdot (\text{erro da rede} \cdot \beta) + \lambda \cdot (\text{erro da rede} \cdot \rho) + \phi \cdot (\text{erro da rede} \cdot \sigma) \\ &= \alpha \cdot (\text{erro B}) + \lambda \cdot (\text{erro C}) + \phi \cdot (\text{erro D}) \end{aligned}$$


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

Prof. Emilio Del Moral Hernandez

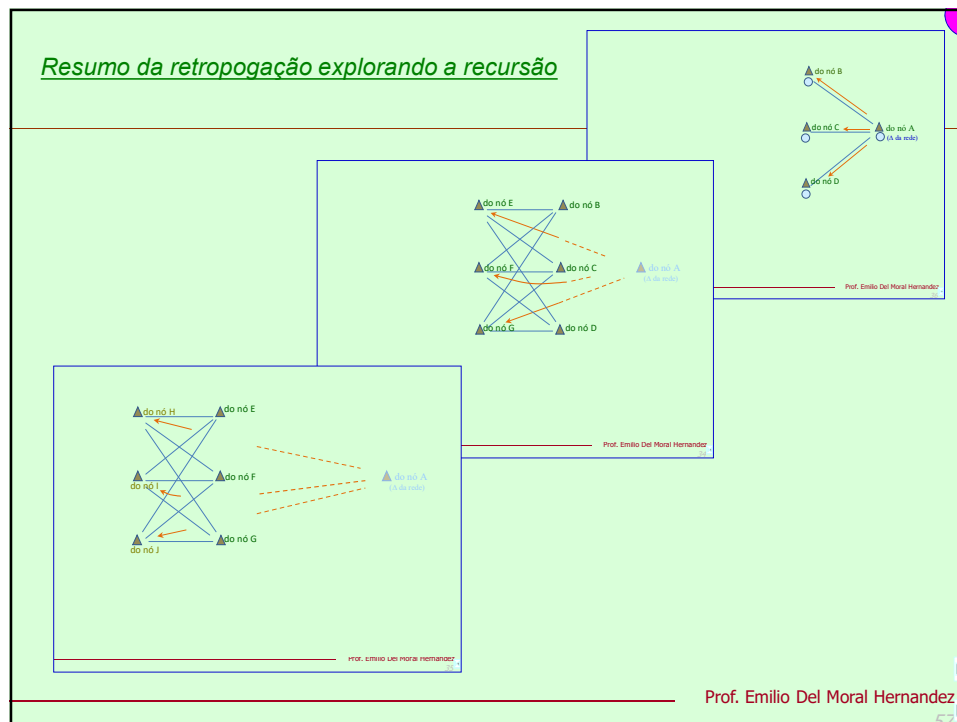
53



54



55



57


58

Aula 10
(de 15)
do Prof. Emilio
de PSI3471 de
27-mar-2019
se encerrou aqui


© Prof. Emilio Del Moral Hernandez

58

58



59



60

Método do Gradiente Aplicado aos nossos MLPs: a partir de um $W\#0$, temos aproximações sucessivas ao Eqm mínimo, por repetidos pequenos passos ΔW , 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^{μ} associado a um exemplo μ , e vá varrendo μ e somando os gradientes de cada Eq^{μ} , para compor o vetor gradiente de Eqm, assim que sair deste loop em μ ;
 - 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
 - Tire a média dos M gradientes individuais e dê um passo Delta ΔW nesse espaço, com direção e magnitude dados por $-\eta \cdot \text{vetor gradiente (Eqm)}$

Prof. Emilio Del Moral Hernandez

61

Concluindo ... Processo de aproximações sucessivas ao Eqm mínimo:

- Chutamos um vetor W inicial, escolhido randomicamente
- Tipicamente essa escolha randômica leva a um Eqm alto e portanto insatisfatório. Para melhorar o Eqm, queremos calcular Grad (Eqm) com a finalidade de adaptar W , “caminhando” contrariamente ao gradiente do erro: $W_{\text{novo}} = W_{\text{corrente}} - \eta \cdot \text{Grad (Eqm)}$
- Loop Externo: Loop do Gradiente Descendente
 - Loop Interno: varredura dos M exemplares de treino. Para o cálculo de Grad (Eqm), usamos um Loop de varredura dos M exemplares de entrada / saída disponíveis para o treinamento da rede:
 - Para chegarmos a Grad (Eqm), calculamos M vetores gradiente, um para cada $(X^{\mu}; y^{\mu})$. Devemos obter M vetores Grad (Eq^{μ}), um para cada exemplar entrada / saída $(X^{\mu}; y^{\mu})$, varrendo pois todos os M exemplares disponíveis para treino da rede neural.
 - O Grad(Eq^{μ}) associado a apenas um exemplo específico $(X^{\mu}; y^{\mu})$ é obtido como desenvolvido nas aulas anteriores do módulo, devemos calcular tantas derivadas parciais $\partial Eq^{\mu} / \partial w_{xx}$ quantos pesos w_{xx} existam na rede.
 - Fazemos esses cálculos através, por exemplo, das técnicas de retropropagação e dos passos direto e reverso. Assim calculamos todas as componentes $\partial Eq^{\mu} / \partial w_{xx}$ e compomos o gradiente de Eq^{μ} , referente a um μ específico (cada μ define um par entrada / saída de treino).
 - Cumulativamente, somamos esses M gradientes de exemplar, Grad (Eq^{μ}), para ao final da varredura de μ , chegarmos ao vetor médio Grad (Eqm) = $\sum \text{Grad (Eq}^{\mu}) / M$
 - Ao sairmos do Loop em μ acima (ao finalizarmos a varredura de todos os μ) chegamos ao vetor médio, Grad(Eqm), e estamos prontos para darmos um pequeno passo vetorial ΔW no espaço de pesos, com a direção e magnitude dados por $-\eta \cdot \text{Grad (Eqm)}$.
 - Assim adaptamos os pesos w 's: $W_{\text{novo}} = W_{\text{anterior}} - \eta \cdot \text{Grad (Eqm)}$
 - Com essa mudança, devemos melhorar o Eqm, pois o reduzimos, incrementalmente.
 - Como o gradiente descendente opera por aproximações sucessivas, temos um Loop Externo: várias adaptações de W , $W_{\text{novo}} = W_{\text{corrente}} - \eta \cdot \text{Grad (Eqm)}$, são necessárias em sequência.
 - Critério de parada: seguimos no loop do Gradiente descendente até Eqm ser zero, baixo, ou estável (sem melhorias incrementais observadas), ou até estourarmos um número limite de adaptações.
- Ao sairmos do Loop Externo, temos “bons w 's” (que levam a erros Eqm baixos) e podemos usar o modelo neural para estimar novos valores de y , com conhecimento apenas dos x 's.

Prof. Emilio Del Moral Hernandez

62


... E lembrando ... Para que serve uma RNA MLP com pesos treinados por EBP como aprendido nas aulas recentes ?? ... Serve por exemplo para modelar sistemas descritos por você nas atividades entregues de #1, #2 e #3.

Nota: lembremos também do poder do MLP conferido pela aproximação universal de Cybenko + considerações práticas que necessariamente relaxam a premissa ideal de um sistema regido por uma função exata ligando X e y , conforme slides que seguem

Prof. Emilio Del Moral Hernandez

63

Modelagem de um sistema por função de mapeamento $X \rightarrow y$
(a RNA como regressor contínuo não linear multivariável)



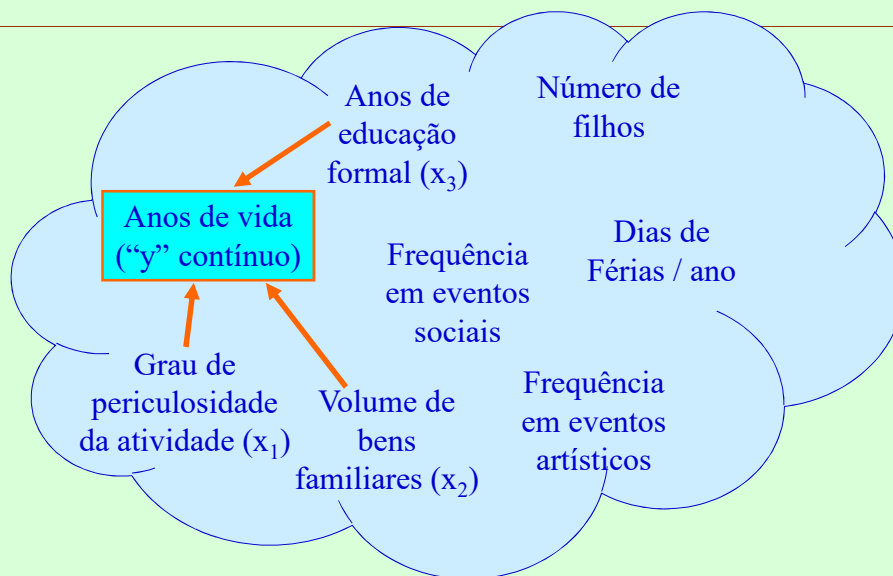
Assumimos que a variável y do sistema a modelar é uma função (normalmente desconhecida e possivelmente não linear) de diversas outras variáveis desse mesmo sistema

A RNA, para ser um bom modelo do sistema, deve reproduzir essa relação entre X e y , tão bem quanto possível

Prof. Emilio Del Moral Hernandez

65


Um hipotético universo de variáveis inter-dependentes, passível de modelagem/ens



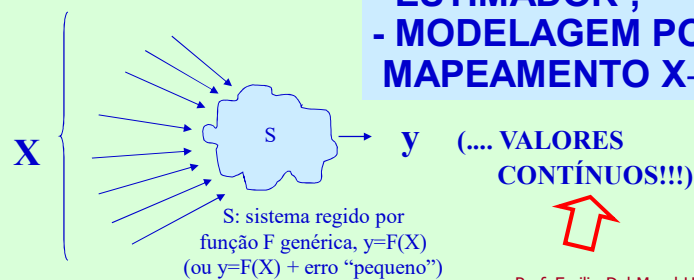
Prof. Emilio Del Moral Hernandez

66

A função $y(X)$ "a descobrir", num caso geral de função contínua $y(X)$




**- ESTIMADOR ;
- MODELAGEM POR
MAPEAMENTO $X \rightarrow y$**



Prof. Emilio Del Moral Hernandez

67

Cenário mais real: a “função” $y(X)$ do sistema modelado é “difusa”: $y = F_{\text{médio}}(X) + \text{flutuação} \dots$



.... em problemas concretos / reais, há sempre alguma ambiguidade no mapeamento que leva valores de X a valores de y . Para decepção de Cybenko, não temos uma função $y = F(X)$ no sentido matemático exato, pois para uma dada ênupla de valores X fixados, temos tipicamente uma faixa de valores que podem ser observados para a variável y : $y = F_{\text{médio}}(X) + \text{flutuação}$.


Neste cenário, buscamos que o modelo capture o comportamento médio das relações observadas entre X e y :

$$\dots y_{\text{rede}} \sim y_{\text{médio}} \text{ esperado para um dado } X$$

Prof. Emilio Del Moral Hernandez

68

Cenário mais real: a “função” $y(X)$ do sistema modelado é “difusa”: $y = F_{\text{médio}}(X) + \text{flutuação} \dots$

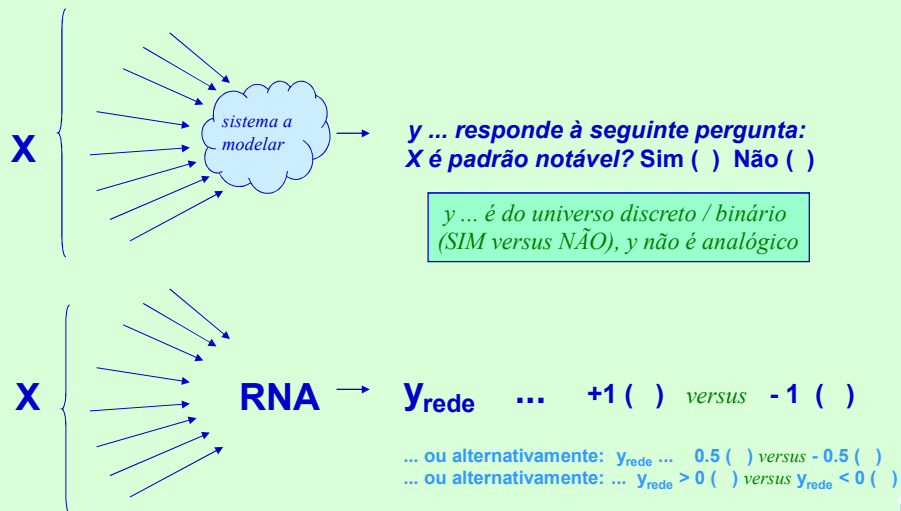


... neste cenário, podemos olhar para o y observado no sistema que se deseja modelar não mais como um valor específico bem definido, mas como um valor médio esperado (dado valor de X) e uma faixa de valores em torno desse valor médio esperado.

Prof. Emilio Del Moral Hernandez

69

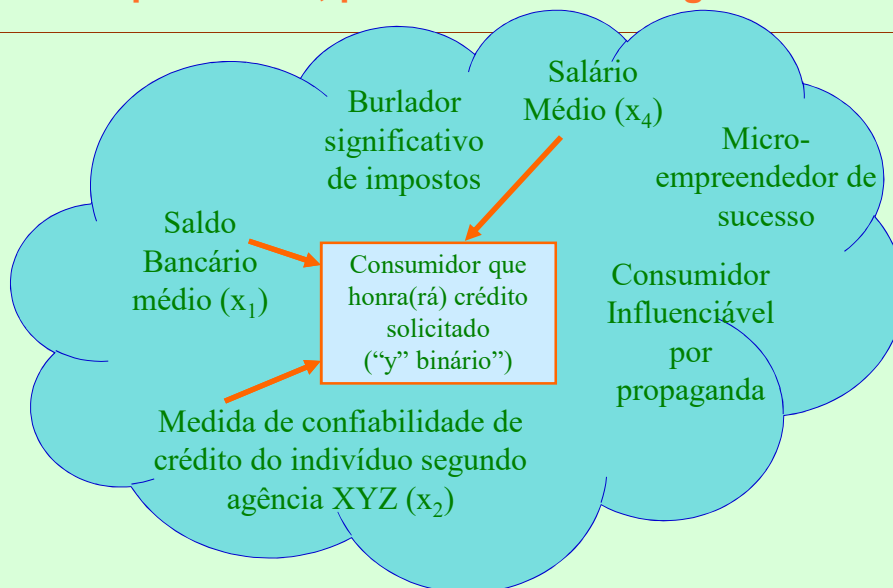
RNAs como reconhecedor / detetor de padrões ...



Prof. Emilio Del Moral Hernandez

70

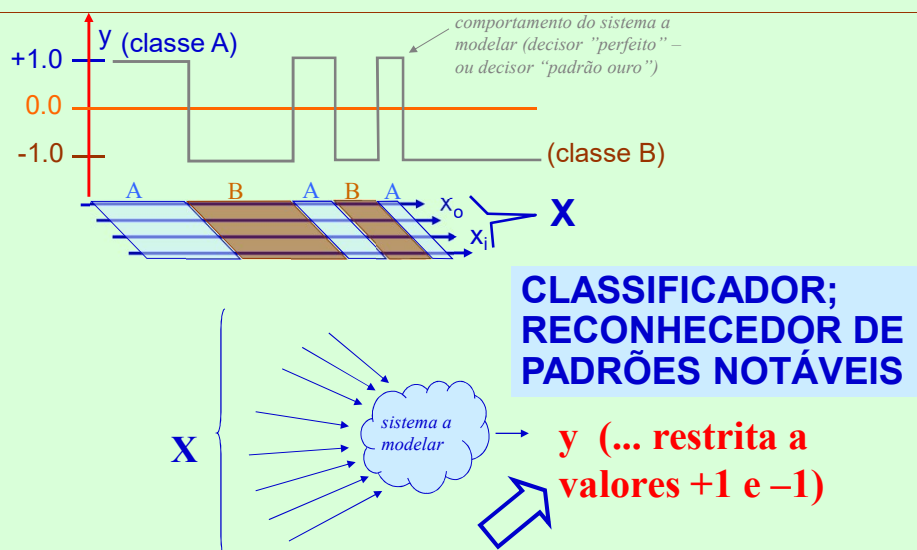
Um hipotético universo de variáveis inter-dependentes, passível de modelagem/ens



Prof. Emilio Del Moral Hernandez

71

Caso de classificação binária / reconhecimento de padrões, será do tipo ...




Prof. Emilio Del Moral Hernandez

72

Capacidade de reconhecimento de padrões em casos complexos NÃO LINEARES


Com as RNAs, a hipersuperfície de separação entre classes vai muito além dos hiperplanos



Prof. Emilio Del Moral Hernandez

73

Cenário mais real: a separação entre regiões do espaço de X não é perfeitamente definida




.... em problemas concretos / reais, há sempre alguma ambiguidade no mapeamento que leva valores de X aos valores discretos de y . Não temos uma função $y=F(X)$ no sentido matemático exato, pois para uma dada ênupla de valores X fixado temos em alguns casos de fronteira a possibilidade de observar no y empírico tanto a classe A quanto a classe B: $y=A$ ou B , com maior ou menor probabilidade para cada classe de acordo com o X . Neste desejamos que o modelo capture o comportamento médio das relações observadas entre X e y :

... $y_{rede} \sim$ classe 'mais esperada' para um dado X

Prof. Emilio Del Moral Hernandez

74

Cenário mais real: a separação entre regiões do espaço de X não é perfeitamente definida




... podemos olhar para o y (classe A ou B) observado no sistema que se deseja modelar não mais como uma classe sempre bem definida e com fronteiras de separação entre A e B bem definidas no espaço de valores de X , mas como sendo delineadas na modelagem através de fronteiras com eventuais faixas de tolerância e com sobreposição parcial das classes no espaço de X

Prof. Emilio Del Moral Hernandez

75

Situações de classes com sobreposição parcial no espaço de atributos X ; situações de fronteiras de separação difusas ...



Prof. Emilio Del Moral Hernandez