

## Disciplina PSI 3471 – Profs. Emilio e Hae - 2020

- Fundamentos de Sistemas Eletrônicos Inteligentes
- Segundas (7:30) e Quartas feiras (9:20)
- Sala B2-09 *(ou outro outra, em datas específicas)*
  
- Prof. Emilio Del Moral Hernandez  
emilio@lsi.usp.br
- Prof. Hae Y. Kim  
hae@lps.usp.br

© Prof. Emilio Del Moral Hernandez

3

## ICONE – EPUSP: Grupo de Inteligência Computacional, Modelagem e Neurocomputação Eletrônica

Prof. Dr. Emilio Del Moral Hernandez

Graduação em Engenharia Elétrica na EPUSP

Doutorado em Engenharia Elétrica pela  
University of Pennsylvania (Upenn – Philadelphia)

Livre Docente da EPUSP, na área de  
Neurocomputação Eletrônica e Sistemas Adaptativos

Atuante no IEEE e nas atividades técnicas da IEEE - CIS

Contato: [emilio.delmoral@usp.br](mailto:emilio.delmoral@usp.br) / [emilio@lsi.usp.br](mailto:emilio@lsi.usp.br)

**Website do Grupo:** <https://sites.usp.br/lsi/icone/>



© Prof. Emilio Del Moral Hernandez

4

## Minha conexão com as temáticas deste curso

- Mestrado (EPUSP, em hw p/ imagens ) e Doutorado (Upenn em RNs)
- Livre Docência em Neurocomputação Eletrônica e Sistemas Adaptativos – PSI-EPUSP
- Ensino de disciplinas de graduação e de pós graduação relacionadas
- Orientações de Mestrado e Doutorado em E.E.
- Orientações de IC e de TCC em E.E.
- Coordenação das pesquisas do grupo ICONE-EPUSP – Grupo de Inteligência Computacional, Modelagem e Neurocomputação Eletrônica (<https://sites.usp.br/lsi/icone/>)
- IEEE Computational Intelligence Society (congressos e periódicos)

... ou seja, contextos de Eng Elétrica e assemelhados ...

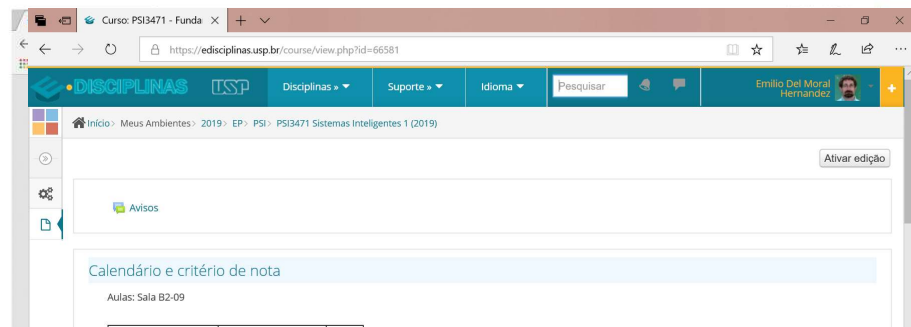
5

*Extratos do Jupiter e STOA ...*

### **Programa – PSI 3471 – Fundamentos de Sistemas Eletrônicos Inteligentes**

Aprendizagem de máquina supervisionada, reconhecimento de padrões, classificação e regressão não linear multivariada, com aplicações em voz, imagens e fusão de informação em matrizes de sensores; Conceitos em imagens: Operações com pixels; operações de vizinhança; Transformações geométricas, multiresolução e casamento de padrões; Aplicações de aprendizagem de máquina em visão computacional.

### **STOA ....**



The screenshot shows a web browser window with the URL <https://edisciplinas.usp.br/course/view.php?id=66581>. The page header includes the text "DISCIPLINAS USP" and "Disciplinas", "Suporte", and "Idioma". A search bar is visible with the text "Pesquisar". The user's name "Emilio Del Moral Hernandez" is displayed in the top right corner. The main content area shows a breadcrumb trail: "Início > Meus Ambientes > 2019 > EP > PSI > PSI3471 Sistemas Inteligentes 1 (2019)". Below this, there is a section titled "Avisos" and a "Calendário e critério de nota" section with the text "Aulas: Sala B2-09".

7

71 - Fundai x + v

https://edisciplinas.usp.br/course/view.php?id=73914

PSI3471 - Fundamentos de Sistemas Eletrônicos Inteligentes - Calendário e critério de nota

Aulas: Sala B2-09  
Professores: Emilio e Hae

segunda-feira 7:30-9:10	quarta-feira 9:20-11:00	Observação
17/02 Hae-1	19/02 Hae-2	
24/02 Carnaval	26/02 Carnaval	
02/03 Emilio-1	04/03 Emilio-2	entrega semanal
09/03 Emilio-3	11/03 Emilio-4	entrega semanal
16/03 Emilio-5	18/03 Emilio-6	entrega semanal
23/03 Emilio-7	25/03 Emilio-8	entrega semanal
30/03 Emilio-9	01/04 Emilio-10	entrega semanal
06/04 Semana Santa	08/04 Semana Santa	
13/04 Emilio-11	15/04 Emilio-12	entrega semanal
20/04 Tiradentes	22/04 P1 (Emilio)	semana da P1
27/04 P1 (Emilio)	29/04 Emilio-13	semana da P1
04/05 Hae-3	06/05 Hae-4 [início dos testinhos]	
11/05 Hae-5	13/05 Hae-6	
18/05 Hae-7	20/05 Hae-8 [entrega EP1]	
25/05 Hae-9	27/05 Hae-10	
01/06 Hae-11	03/06 Hae-12	
08/06 Hae-13	10/06 Hae-14	
15/06 P2	17/06 P2	
22/06	24/06 [entrega EP2]	
29/06	01/07	

**Nota:**  
Se  $\min(MEmilio, MHae) \geq 3$   
então  $MFinal = (MEmilio + MHae) / 2$   
senão  $MFinal = \min(MEmilio, MHae)$   
MEmilio e MHae são calculadas como:  $(Prova + MExercicios) / 2$   
PSub somente em caráter excepcional para quem justificar formalmente e no prazo a falta em alguma das duas provas (doença, luto, etc); a autorização para realização da PSub está sujeita à aprovação dos Profs e às regras da CoC-PSI. No dia a combinar.

© Prof. Emilio Del Moral Hernandez

10

## Materiais de apoio às aulas no e-disciplinas

**ATENÇÃO: leitura destes NÃO substitui participação e atividades em sala de aula!  
Mesmo o estudo completo do livro texto base (Haykin) não substitui nossos debates e atividades!**

Curso: PSI3471 - Fundai x + v

https://edisciplinas.usp.br/course/view.php?id=73914

Materiais do prof. Emilio (primeira parte do curso, até aproximadamente P1)

- Programação de temáticas aula a aula / semana a semana, para as aulas do Prof. Emilio.
- Ementa geral e referências como consta no sistema Jupiter

Slides apresentados e outros materiais de apoio às atividades em sala serão disponibilizados aqui durante o transcorrer do semestre.

Atenção: Os materiais de apoio disponibilizados via e-disciplinas **NÃO substituem as discussões e o aprendizado que ocorrem com a sua presença nas aulas desta disciplina.** O mesmo ocorre com relação ao estudo mesmo que completo do livro base (Haykin); ele não substitui debates e atividades realizadas em sala de aula. Se tiver alguma dúvida sobre a necessidade da sua presença em sala de aula, estou disponível para ajudá-lo a entender; me procure após encerrarmos a nossa próxima aula e conversamos sobre isso.

© Prof. Emilio Del Moral Hernandez

12

14	
<p><b>— Aulas do Prof Emilio em PSI3471 da #1 (em 02/março) à #13 (em 29/abril) —</b></p> <p><b>Plano aproximado de temáticas aula a aula / semana a semana – versão de 01 de março</b></p> <p><i>(atividades com entregas simples aproximadamente semanais ocorrerão durante as aulas)</i></p>	
<b>#1 (02/março – 2ªf)</b>	Conceitos em regressão linear e não linear. Regressão univariada e Regressão multivariada; Contrastes com técnica mais simples já conhecida: a regressão linear univariada (reta média). Diferenças principais entre 1) a Regressão e 2) o Reconhecimento / Detecção / Identificação de Padrões Multivariados. Conceitos em Reconhecimento / Detecção / Identificação de Padrões. Entendendo primeiro as ferramentas de modelagem mais simples: as ferramentas lineares multivariadas ... elementos matemáticos em regressão linear multivariada e em discriminadores lineares multivariados. Dados empíricos para calibração de parâmetros em regressores e em discriminadores; o aprendizado supervisionado.
<b>#2 (04/março – 4ªf)</b>	Neurônios biológicos como base para os neurônios artificiais; equações e propriedades matemáticas do neurônio artificial isolado; relação do neurônio isolado com os regressores e com os discriminadores lineares multivariados.
<b>#3 (09/março – 2ªf)</b>	Foco nas Redes de Neurônios Artificiais (RNAs) concatenando múltiplos neurônios; arquiteturas neurais diversas; arquiteturas MLP – Multi Layer Perceptron; Relação de RNAs com a implementação de regressores e reconhedores <b>NÃO LINEARES MULTIVARIADOS</b> . O ensaio computacional de redes neurais – ambientes simples como o MBP – Multiple Back Propagation – e ambientes mais complexos alternativos, de sua escolha.
<b>#4 (11/março – 4ªf)</b>	Grafos da computação em redes neurais do tipo MLP; notação matemática para pesos sinápticos, variáveis de entrada, saída e variáveis intermediárias no MBP; exemplares empíricos / observações empíricas para o treinamento supervisionado em MLPs; aprendizado com base na propagação reversa do erro (EBP – Error Back Propagation).
© Prof. Emilio Del Moral Hernandez	
14	

14

15	
<p><b>— Aulas do Prof Emilio em PSI3471 da #1 (em 02/março) à #13 (em 29/abril) —</b></p> <p><b>Plano aproximado de temáticas aula a aula / semana a semana – versão de 01 de março</b></p> <p><i>(atividades com entregas simples aproximadamente semanais ocorrerão durante as aulas)</i></p>	
<b>#5 (16/março – 2ªf)</b>	Foco no 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 e em conjunto com os alunos: trabalho focado num peso sináptico específico da rede, escolhido pelo professor para máxima complexidade da dedução.
<b>#6 (18/março – 4ªf)</b>	Discussão da extensão simples das deduções do EBP para 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.
<b>#7 (23/março – 2ªf)</b>	Foco em Reconhedores – Circuitos lógicos genéricos e suas implementações através de computação neural; relação com discriminadores. Construindo reconhedores de padrões com fronteiras de separação genéricas: separadores lineares; bancos de separadores lineares como aproximadores efetivos de fronteiras genéricas.
<b>#8 (25/março – 4ªf)</b>	Técnicas de medida de qualidade em reconhedores de padrões: matriz de confusão, conceitos de falsos positivo e negativo, especificidade e sensibilidade. Curvas ROC.
<b>#9 (30/março – 2ªf)</b>	Foco agora em Regressores - Casos simples de aproximação de funções univariadas. Teorema de Cybenko: o MLP como aproximador universal de funções multivariadas; implicações práticas do teorema para a implementação de regressores e reconhedores de padrões não lineares multivariados genéricos.
<b>#10 (01/abril – 4ªf)</b>	Medidas de qualidade diversificadas para regressores multivariados (distintas do erro quadrático médio); Flutuação do desempenho do modelo com as particulares amostras de treino e de teste e técnicas de reamostragem; técnica de validação cruzada, k-fold cross validation e leave one out. Sobreajuste / sobreaprendizado / perda de generalização em regressão polinomial e em redes neurais; limitação do número de nós neurais para evitar o sobreajuste e otimizar a generalização da rede neural; partição do volume de observações em conjuntos de treino, validação e teste.
<b>06 e 08 de abril: Semana Santa – não há aula</b>	
© Prof. Emilio Del Moral Hernandez	
15	

15

16
<i>06 e 08 de abril: Semana Santa – não há aula</i>
<p><b>#11 (13/abril – 2ªf)</b> Soluções em reconhecimento e em regressão empregando dois estágios: primeiro estágio para extração de características / extração de medidas e para a redução de dimensionalidade + segundo estágio MLP como reconhecedor / regressor genérico; técnicas diversas de extração de características em projetos concretos. Extensões de análise harmônica (Fourier) para a extração de características; conceitos básicos em análise tempo-frequência. PCA - Análise de Componentes Principais como extrator de características.</p>
<p><b>#12 (15/abril – 4ªf)</b> Aprofundando a conexão dos temas que aprendemos com o Deep Learning: conexão com redes neurais convolucionais; camadas convolucionais, Autoencoders e Autoencoders em cascata como extratores de características e redutores de dimensionalidade. Apanhado das temáticas aprendidas e troca de ideias sobre a “A4 de consulta” + sessão de dúvidas p/ P1;</p>
<i>22 de abril (4ªf) e 27 de abril (2ªf): P1 em PSI3471 – ou seja, dentro da semana de provas P1 da Elétrica (em 20 de abril, pela ponte de Tiradentes, não há aula na 2ª feira)</i>
<p><b>#13 (29/abril – 4ªf)</b> 1) Parte das temáticas e atividades desta aula após a P1 serão definidas mais adiante no semestre, de acordo com a evolução das aulas anteriores; 2) Conexão do aprendido até o momento com as próximas temáticas no curso.</p>
© Prof. Emilio Del Moral Hernandez 16

16

<h2 style="color: blue;">Algumas possibilidades para regressão linear sobre dados empíricos do universo de valores <math>(x_1, x_2, x_3, y) \dots</math></h2>
<ul style="list-style-type: none"> <li>• Modelagem por reta média, considerando por exemplo unicamente a variável <math>x_1</math> como impactante significativo no valor esperado para a variável dependente <math>y</math></li> <li>• Modelagem por plano médio, considerando duas variáveis <math>x_1</math> e <math>x_2</math> como impactantes significativos em <math>y</math></li> <li>• Modelagem por hiperplano médio se o número de variáveis que impactam no valor de <math>y</math> for 3 ou maior que 3 (<math>x_1, x_2, x_3</math> etc)</li> </ul> <p style="text-align: center;"><i>Discutamos em lousa alguma formulação matemática ...</i></p>
© Prof. Emilio Del Moral Hernandez 17

17

Relembrando duas classes de aplicação alvo a abordadas no curso e iniciando a solução com técnicas LINEARES “(+-)”

18

- Regressores multivariados **lineares** e não lineares
- Reconhecimento automático de padrões ...
  - / discriminadores (ou identificadores)

**lineares** e não lineares

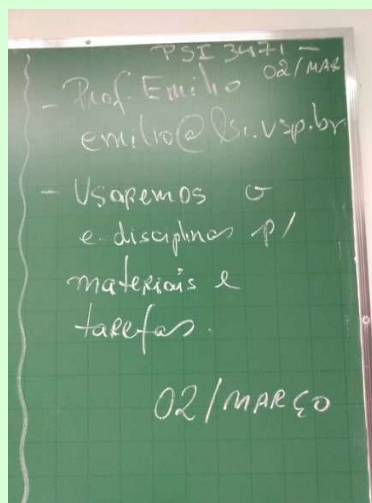
*aparte formal ... Linear / Afim*

© Prof. Emilio Del Moral Hernandez

18

18

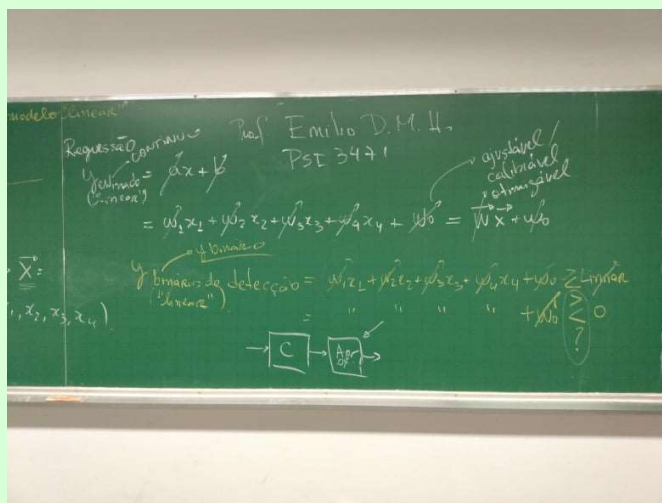
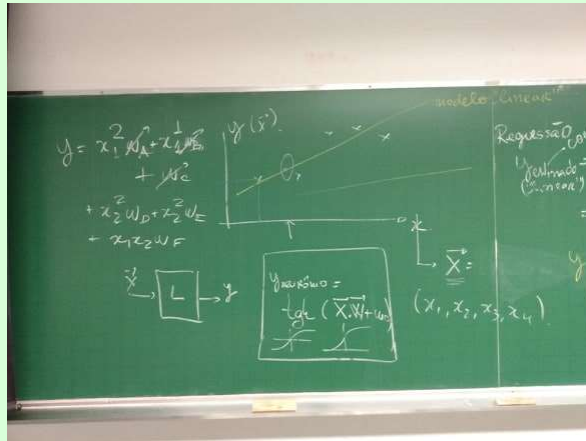
19



© Prof. Emilio Del Moral Hernandez

19

19



# aparte formal ... Linear / Afim, a rigor são diferentes

25

Wikipédia - A enciclopédia livre

## Função afim

Origem: Wikipédia, a enciclopédia livre.

**Nota:** Não confundir com Função linear, ou Transformação linear.

Uma **função afim**, também conhecida como **função polinomial de grau 1** ou **função polinomial de primeiro grau** é uma função do tipo  $f(x) = ax + b$ , cujo gráfico é uma reta não perpendicular ao eixo  $o\alpha z$ . Tal função também pode ser entendida como uma transformação linear ( $Az$ ) seguida por uma translação ( $+b$ ).

$$z \mapsto Az + b$$

no caso finito-dimensional cada função afim é dada por uma matriz  $A$  e por um vetor  $B$ , que possam ser escritos como a matriz  $A$  com uma "coluna extra" do  $B$ . Fisicamente, uma função afim é a que preserva:

1. Colinearidade entre pontos, isto é, três pontos que se encontram em uma linha continuam a ser colineares após a transformação;
2. relações das distâncias ao longo de uma linha, isto é, para os pontos colineares distintos  $p_1, p_2, p_3$ ,  $\|p_2 - p_1\|/\|p_3 - p_2\|$

Uma função afim é composta de um ou de diversos transformadores lineares. Diversas transformações lineares podem ser combinadas em uma única matriz, assim que a fórmula geral dada acima é ainda aplicável.

Em uma dimensão (ou seja, quando  $x$  e  $y$  são escalares), os termos  $A$  e  $b$  são chamados, respectivamente, de coeficiente angular e coeficiente linear.

### Índice [escondido]

- 1 Definição formal
  - 1.1 Coeficientes
- 2 Função linear
  - 2.1 Função linear e proporcionalidade
- 3 Crescimento ou decréscimo
  - 3.1 Crescente
  - 3.2 Decrescente
  - 3.3 Constante
- 4 Zero
- 5 Aplicações
  - 5.1 Relação com a progressão aritmética
  - 5.2 Relação com o movimento retilíneo uniforme
- 6 Referências
- 7 Bibliografia

© Prof. Emilio Del Moral Hernandez

25

# aparte formal ... Linear / Afim, a rigor são diferentes

26

Wikipédia - A enciclopédia livre

## Função linear

O coeficiente "b" determina o deslocamento da reta em relação à origem, por isso ele é conhecido como coeficiente linear da reta.

Ver artigo principal: Função linear

Uma função linear é um caso particular da função afim onde  $a \neq 0$  e  $b = 0$ , sendo, portanto, expressa como:

$$f(x) = ax.$$

Veja na figura ao lado um exemplo de gráfico de função linear.

Um caso específico da função linear é a função identidade, onde  $a = 1$ . Logo a função identidade é expressa como:

$$f(x) = x.$$

Observe na figura ao lado um exemplo de gráfico de função identidade.

### Função linear e proporcionalidade

Uma das principais aplicações da função linear é a relação de proporção existente entre os elementos do domínio e da imagem, pois observamos que conforme variam os elementos do domínio, suas respectivas imagens variam na mesma proporção, sendo essa proporção o coeficiente angular da função, nesse caso chamado de taxa de variação.

Assim, seja a função linear  $f(x) = ax$ , vemos que o conjunto dos pontos que representa a reta dessa função são os pontos do tipo  $(x, ax)$ , onde  $a$  é a razão entre  $y$  e  $x$ .

Essa relação será diretamente proporcional se a função for crescente e inversamente proporcional se a função for decrescente.

### Crescimento ou decréscimo

Uma função afim pode ser crescente, decrescente, dependendo do valor do coeficiente angular. Uma função pode ainda ser constante, se  $a=0$  e ela terá grau 0.

### Crescente

Uma função afim é crescente quando seu coeficiente angular for positivo, ou seja,  $a > 0$ .

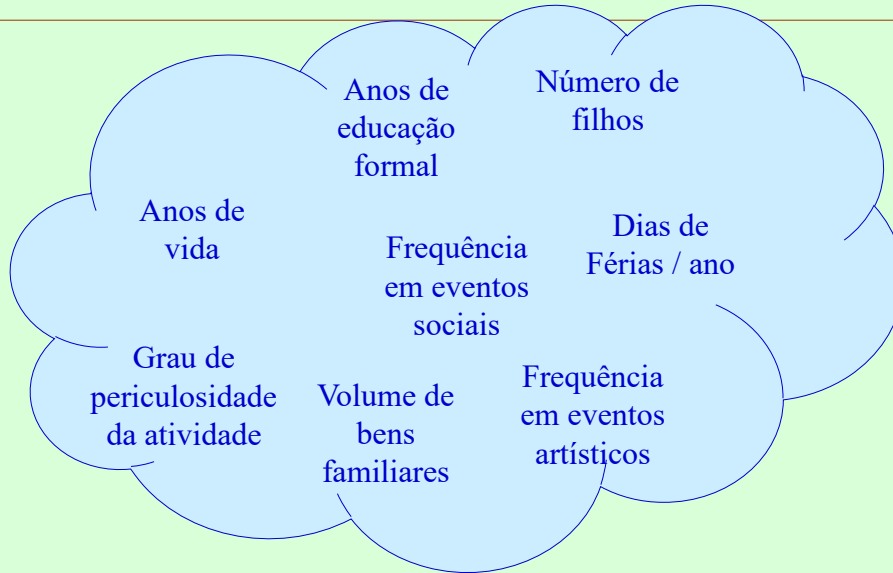
### Demonstração

Por definição, dizemos que uma função  $f: A \rightarrow B$  definida por  $y = f(x)$  é crescente no conjunto  $A_1 \subset A$  se, para dois valores quaisquer  $x_1$  e  $x_2$  pertencentes a  $A_1$ , com  $x_1 < x_2$ , tivermos  $f(x_1) < f(x_2)$ .

26



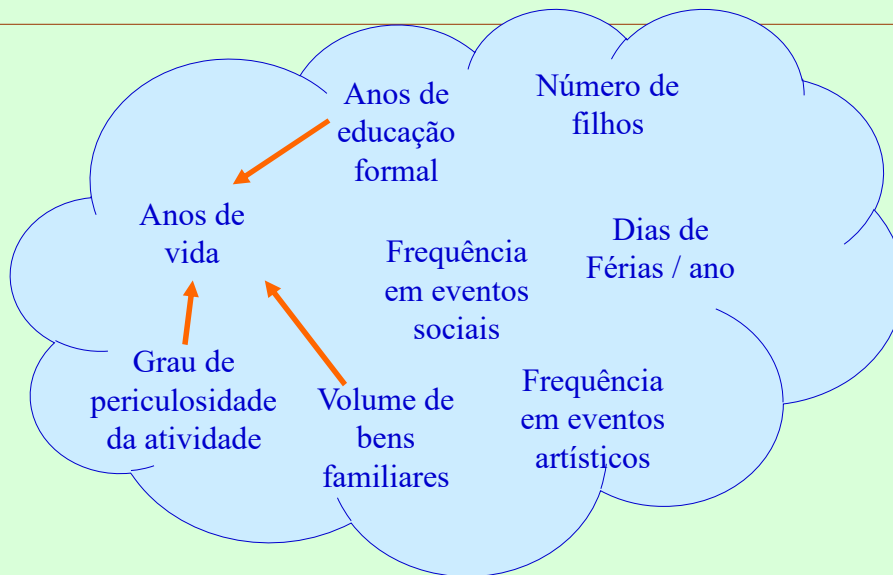
## Um hipotético universo de variáveis interdependentes, passível de modelagem/ens



© Prof. Emilio Del Moral Hernandez

46

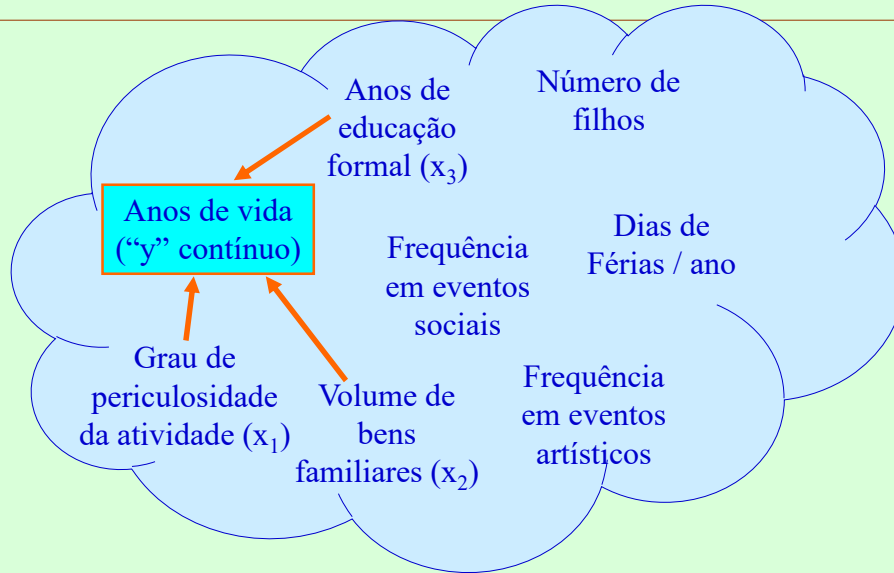
## Um hipotético universo de variáveis interdependentes, passível de modelagem/ens



© Prof. Emilio Del Moral Hernandez

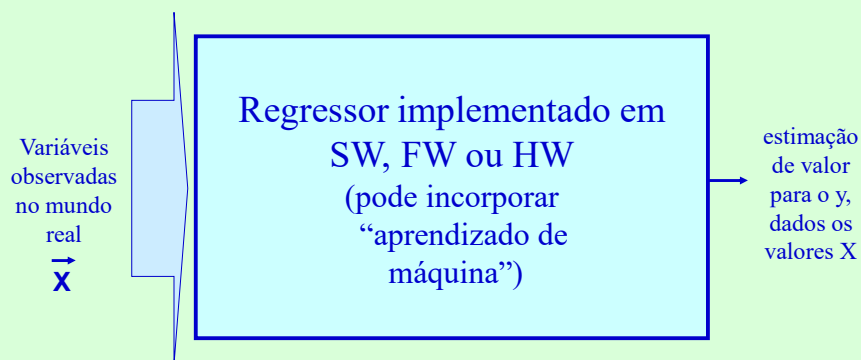
47

## Um hipotético universo de variáveis interdependentes, passível de modelagem/ens



48

## Regressor multivariado (em sw, fw ou hw)

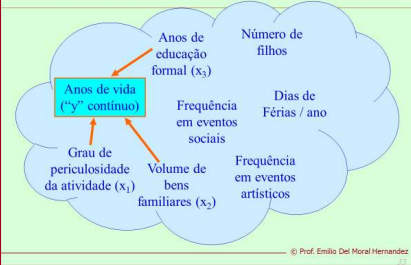


49

- 1) Quais as dimensões dos vetores de entrada e saída neste regressor exemplo?
- 2) Qual a precisão esperada? (o erro será zero em  $y$  estimado?)
- 3) Como coletaríamos os dados empíricos?
- 4) Qual a utilidade da estimação de  $y$  dado  $X$ ?


50

Um hipotético universo de variáveis interdependentes, passível de modelagem/ens



© Prof. Emilio Del Moral Hernandez

Regressor multivariado (em sw, fw ou hw)



© Prof. Emilio Del Moral Hernandez

© Prof. Emilio Del Moral Hernandez

50

50

Relembrando as duas classes de aplicação alvo a serem abordadas no curso

53

- Regressão multivariada (linear e não linear)
- Reconhecimento automático de padrões ...

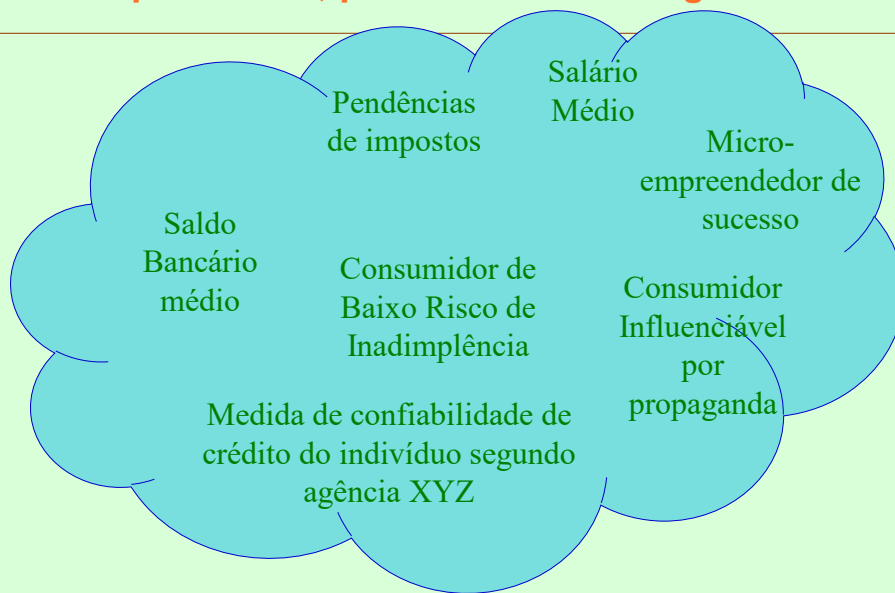
© Prof. Emilio Del Moral Hernandez

53

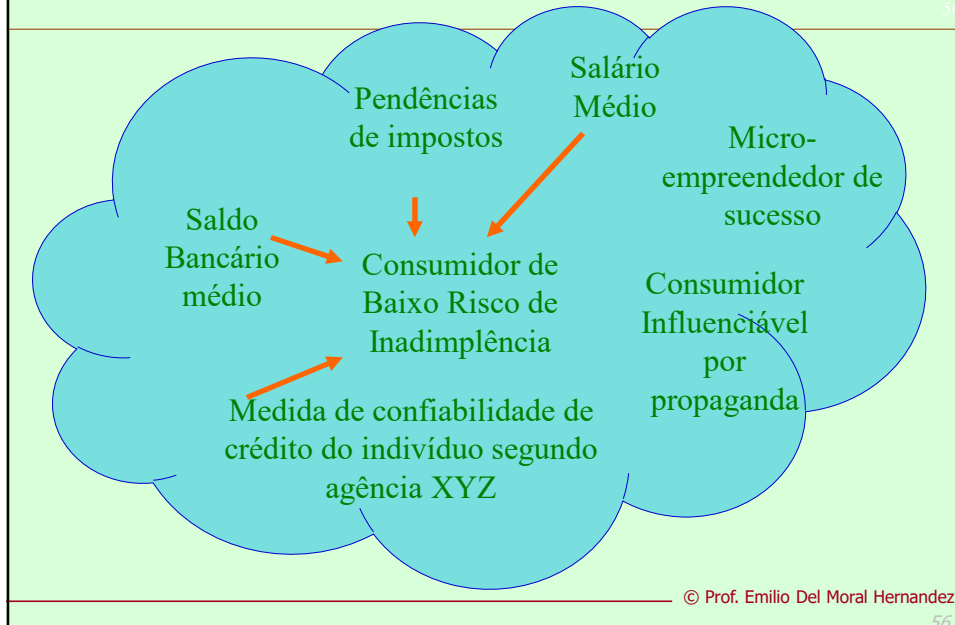
53

Passemos agora a elaborar uma situação hipotética de reconhecimento de padrões (y discreto), em lugar de regressão multivariada (y contínuo) ...

### Um hipotético universo de variáveis interdependentes, passível de modelagem/ens

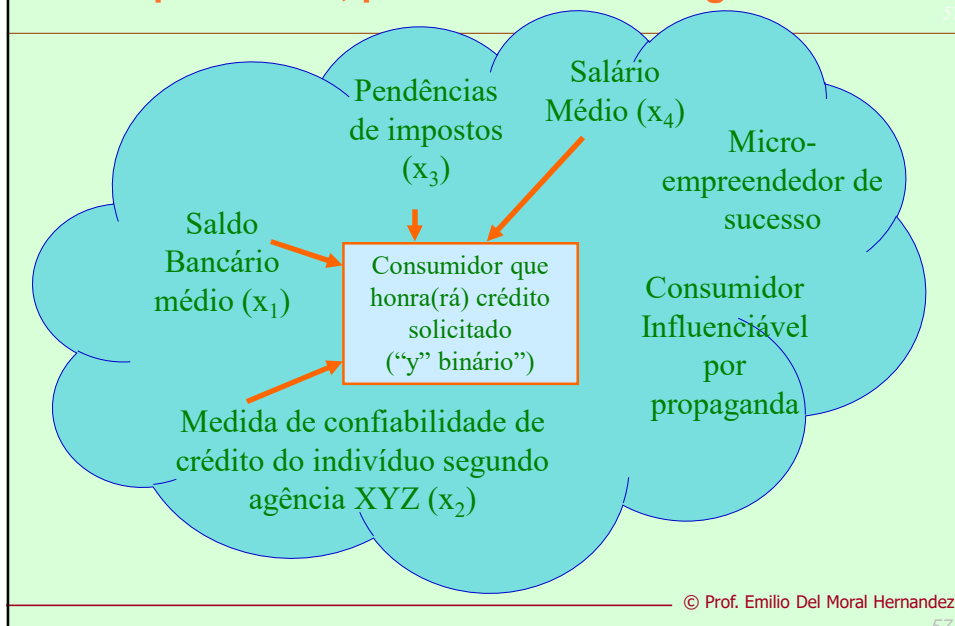


## Um hipotético universo de variáveis interdependentes, passível de modelagem/ens



56

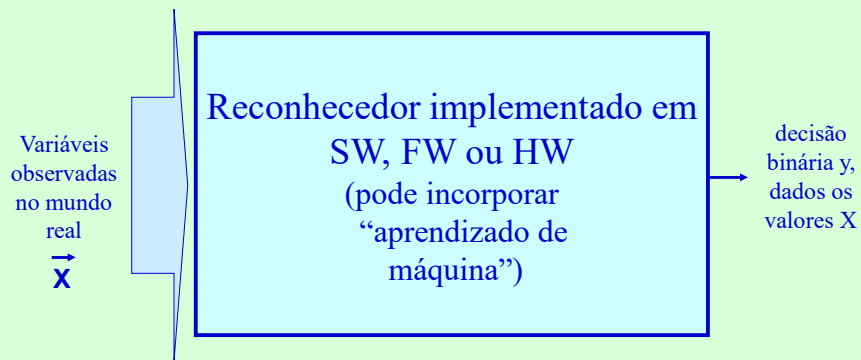
## Um hipotético universo de variáveis interdependentes, passível de modelagem/ens



57

## Detector / reconhecedor multivariado (em sw, fw ou hw)

58



© Prof. Emilio Del Moral Hernandez

58

58

## Abrindo o leque de aplicações alvo a serem abordadas no curso

59

- Regressão multivariada (linear e não linear)
- Reconhecimento automático de padrões ...
  - Detecção de padrões relevantes: reconhecimento binário
  - Reconhecimento multiclases

© Prof. Emilio Del Moral Hernandez


59

59

Uma metáfora para a tarefa de classificação de padrões genérica ou multiclases (classificação não binária)...

60

Universo de objetos observados ...



© Prof. Emilio Del Moral Hernandez


60

60

Uma metáfora para a tarefa de classificação de padrões multiclases (classificação não binária)...

62

Um dado objeto específico observado é de que tipo ?



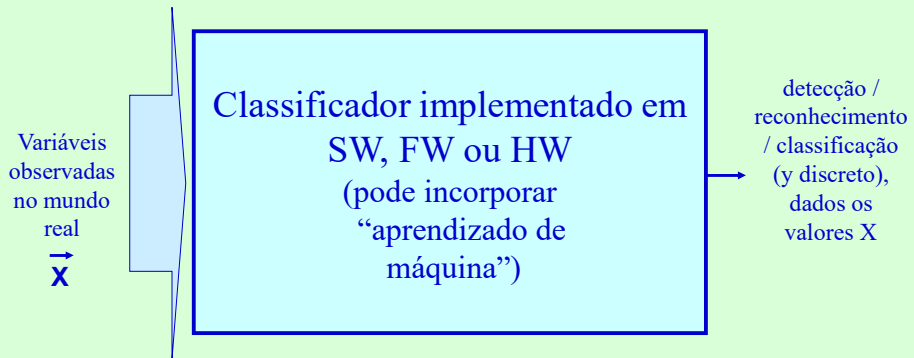
© Prof. Emilio Del Moral Hernandez

62

62

Detector / reconhecedor / classificador multivariado  
(em sw, fw ou hw)

64



© Prof. Emilio Del Moral Hernandez

64

64

65

*Avançando para outro tópico ...*

© Prof. Emilio Del Moral Hernandez

65

65



## Alguns dos focos / classes específicas de aplicação que são alvos do curso

66

- Modelagem envolvendo sistemas com múltiplas variáveis
- Uso de ferramentas que possibilitem representação de fenômenos não lineares além dos lineares )
- Reconhecimento / Identificação / Classificação de “objetos” a partir de medidas múltiplas (vindas de múltiplos sensores, por exemplo)
- Regressão / previsão / estimação de grandezas analógicas a partir de medidas correlacionadas com tal grandeza
- Exploração de elementos para “automação parcial” da modelagem, via aprendizado de máquina

© Prof. Emilio Del Moral Hernandez

66

66

67

### — Aulas do Prof Emilio em PSI3471 da #1 (em 02/março) à #13 (em 29/abril) —

Plano aproximado de temáticas aula a aula / semana a semana – versão de 01 de março  
(atividades com entregas simples aproximadamente semanais ocorrerão durante as aulas)

#1 (02/março – 2ªf) Conceitos em regressão linear e não linear. Regressão univariada e Regressão multivariada; Contrastes com técnica mais simples já conhecida: a regressão linear univariada (reta média). Diferenças principais entre 1) a Regressão e 2) o Reconhecimento / Detecção / Identificação de Padrões Multivariados. Conceitos em Reconhecimento / Detecção / Identificação de Padrões. Entendendo primeiro as ferramentas de modelagem mais simples: as ferramentas lineares multivariadas ... elementos matemáticos em regressão linear multivariada e em discriminadores lineares multivariados. Dados

#2 (04/março – 4ªf) Neurônios biológicos como base para os neurônios artificiais; equações e propriedades matemáticas do neurônio artificial isolado; relação do neurônio isolado com os regressores e com os discriminadores lineares multivariados.

#3 (09/março – 2ªf) Foco nas Redes de Neurônios Artificiais (RNAs) concatenando múltiplos neurônios; arquiteturas neurais diversas; arquiteturas MLP – Multi Layer Perceptron; Relação de RNAs com a implementação de regressores e reconhecedores NÃO LINEARES MULTIVARIADOS. O ensaio computacional de redes neurais – ambientes simples como o MBP – Multiple Back Propagation – e ambientes mais complexos alternativos, de sua escolha.

#4 (11/março – 4ªf) Grafos da computação em redes neurais do tipo MLP; notação matemática para pesos sinápticos, variáveis de entrada, saída e variáveis intermediárias no MBP; exemplares empíricos / observações empíricas para o treinamento supervisionado em MLPs; aprendizado com base na propagação reversa do erro (EBP – Error Back Propagation).


© Prof. Emilio Del Moral Hernandez

67




67

## Neurônio Artificial - inspirado no biológico (ou também chamado de “nó” da rede neural)

68



$$y = \text{tgh} (\sum w_i x_i)$$



© Prof. Emilio Del Moral Hernandez

68

68

## ... algumas outras disciplinas PSI em sistemas eletrônicos inteligentes ou fortemente relacionadas

74

PSI3472  
Conc. E Impl.  
eletiva no 2º  
Semestre  
do 4º ano

PSI3571  
Rec. Padrões e  
Intel. Comput.  
eletiva no  
5º ano

**PSI3471**  
(fundamentos)

PSI3422  
Lab. de Sist.  
Eletrônicos  
2º sem 4º

... E também:

- Disciplinas em imagens eletivas de 5º ano
- Disc. em Proc. de Voz – eletiva do 5º
- Disc. em filtragem adaptativa de 4º e 5º
- Disc. em embarcados eletrivas de 4º e 5º
- Disc optativa em Sistemas Cognitivos
- .... Outras ...


© Prof. Emilio Del Moral Hernandez

74

74

## ... Relação com as demais linhas formativas da ênfase Eletrônica e Sistemas

75



© Prof. Emilio Del Moral Hernandez

75

75

## Redes Neurais Artificiais

***São sistemas computacionais, de implementação em hardware ou software, que imitam as habilidades computacionais do sistema nervoso biológico, usando um grande número de processadores simples (neurônios artificiais) e interconectados entre si.***

### ***Emprestam da biologia:***


- A estrutura de processamento microscópico (processamento de informação de neurônios individuais)
- Em algum grau, aspectos da organização de redes neurais biológicas
- Aspectos de plasticidade sináptica e do aprendizado através de exemplos (através de casos)

76

*Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©*

76

## The biological neuron




(figura modificada da internet) 77

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

77

## Sinapses




(figura extraída da internet)

78

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

78

## Action Potential Generation and Propagation (no Axônio e ramificações axonais)




(figura extraída da internet)

79

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

79



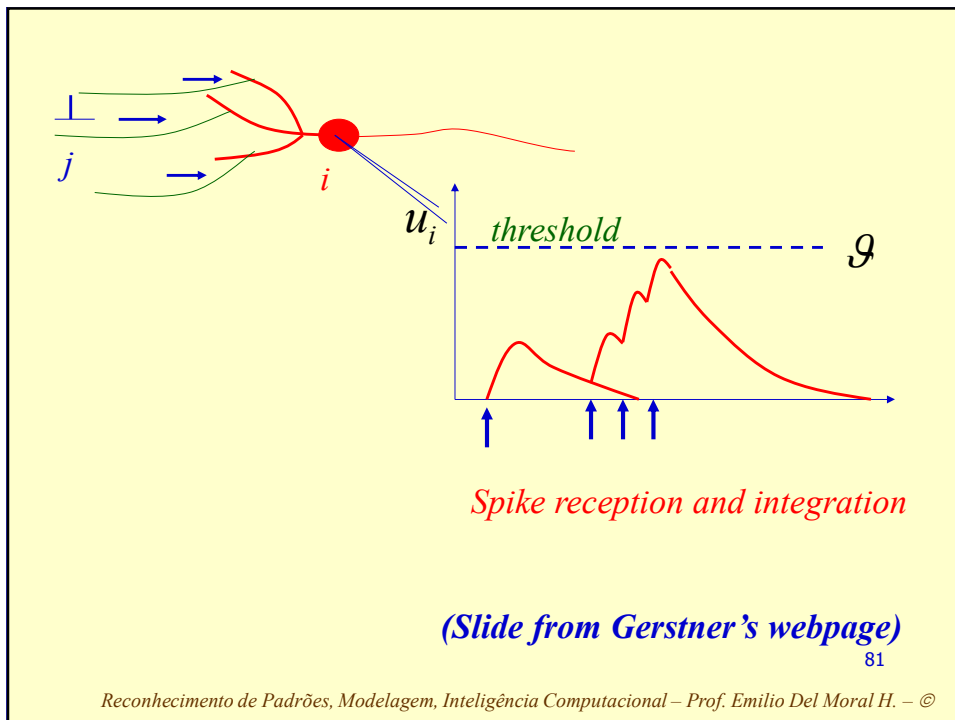
*Spike reception*

(Slide from Gerstner's webpage)

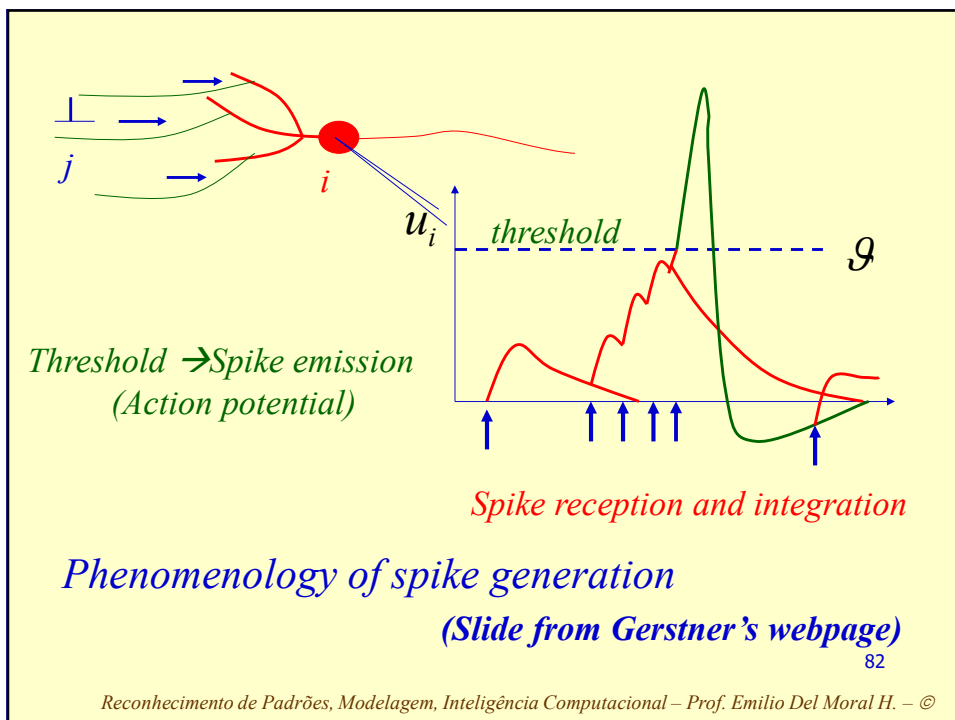
80

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

80

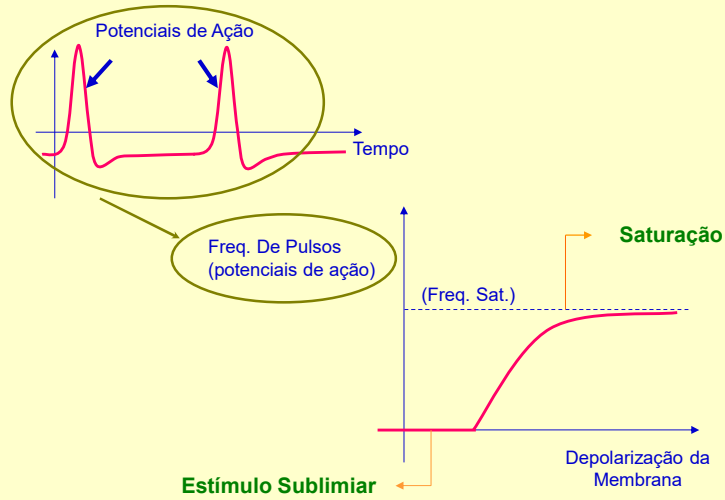


81



82

... Vendo com mais detalhe ... a relação entre estímulo global e atividade na saída não é linear:




83

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©

83

### Integrate-and-fire Model



$$\tau \cdot \frac{d}{dt} u_i = -u_i + RI(t) \quad \text{Linear}$$

$$u_i(t) = \mathcal{G} \Rightarrow \text{Fire+reset Não linear}$$

(Slide from Gerstner's webpage)


84

Reconhecimento de Padrões, Modelagem, Inteligência Computacional – Prof. Emilio Del Moral H. – ©




84

## Neurônio Artificial - inspirado no biológico (ou também chamado de “nó” da rede neural)

85



$$y = \text{tgh} (\sum w_i x_i)$$





© Prof. Emilio Del Moral Hernandez

85



85

## Computação linear e não linear, com codificação freqüencial

88



$$y = f_T (\sum w_i x_i)$$



© Prof. Emilio Del Moral Hernandez



88

88





# Computação linear e não linear, com codificação frequencial

89



$$y = f_T(\sum w_i x_i)$$




© Prof. Emilio Del Moral Hernandez

89


89

# Computação linear e não linear, com codificação frequencial

90



$$y = f_T(\sum w_i x_i)$$




© Prof. Emilio Del Moral Hernandez

90

90

Caso particular do nó com comportamento linear  
...  $f_T(\text{arg}) = k \cdot \text{arg}$

91




© Prof. Emilio Del Moral Hernandez

91

91

Caso particular do nó com comportamento binário  
...  $f_T(\text{arg}) = \text{sign}(\text{arg})$

92



© Prof. Emilio Del Moral Hernandez


92

92

Um pioneiro ... o Perceptron:  $y = \text{sinal}(\sum w_i x_i - \theta)$   
 (função de transferência tipo “degrau”)

93

- Viabiliza a classificação de padrões com separabilidade linear
- O algoritmo de aprendizado adapta os Ws de forma a encontrar o hiperplano de separação adequado
- Aprendizado por conjunto de treinamento




93

E se a saída do nosso problema não for digital?  
 O “Perceptron Contínuo”:  $y = \text{tgh}(\sum w_i x_i - \theta)$

94


- Que problemas de entradas contínuas conseguimos atacar usando uma função de transferência tangente hiperbólica)



94

*Sugestão: Instale o MBP e digite "3-1" no campo Topology (ou antes veja os tutoriais)*

95



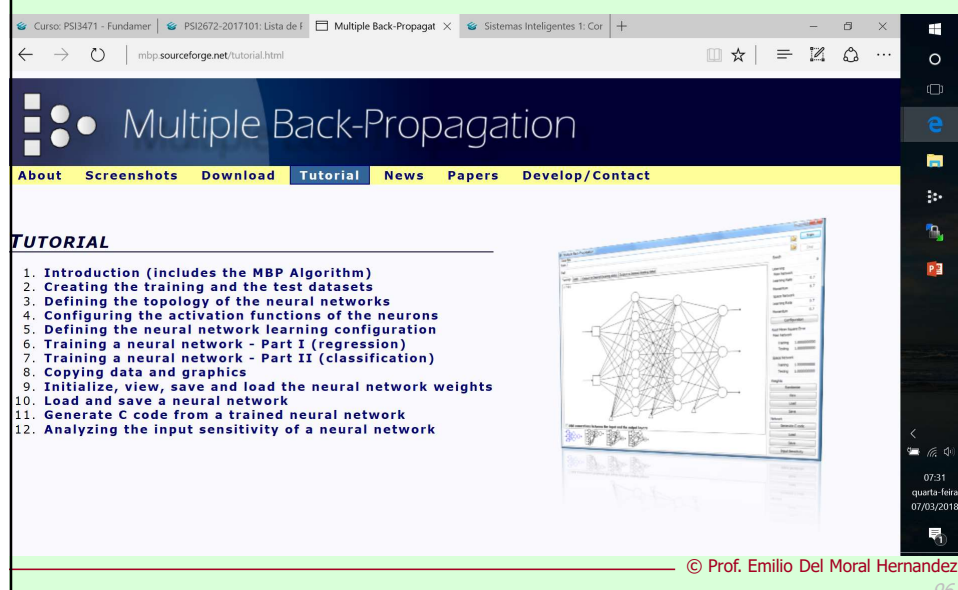
© Prof. Emilio Del Moral Hernandez

95

95

<http://mbp.sourceforge.net/> ...

96



**TUTORIAL**

1. Introduction (includes the MBP Algorithm)
2. Creating the training and the test datasets
3. Defining the topology of the neural networks
4. Configuring the activation functions of the neurons
5. Defining the neural network learning configuration
6. Training a neural network - Part I (regression)
7. Training a neural network - Part II (classification)
8. Copying data and graphics
9. Initialize, view, save and load the neural network weights
10. Load and save a neural network
11. Generate C code from a trained neural network
12. Analyzing the input sensitivity of a neural network

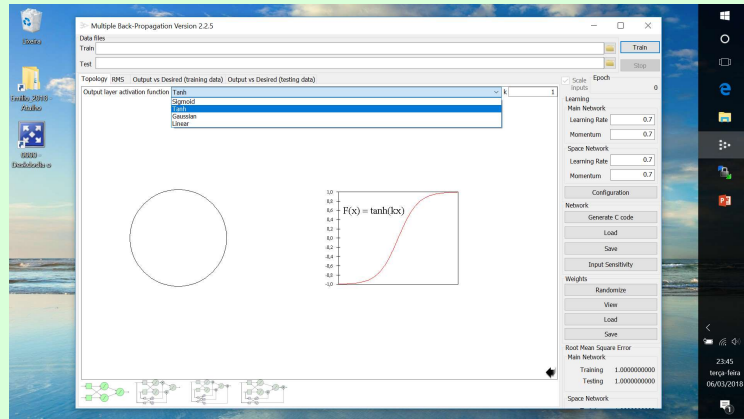
© Prof. Emilio Del Moral Hernandez

96

96

## Depois escolha a função de ativação do nó neural

97



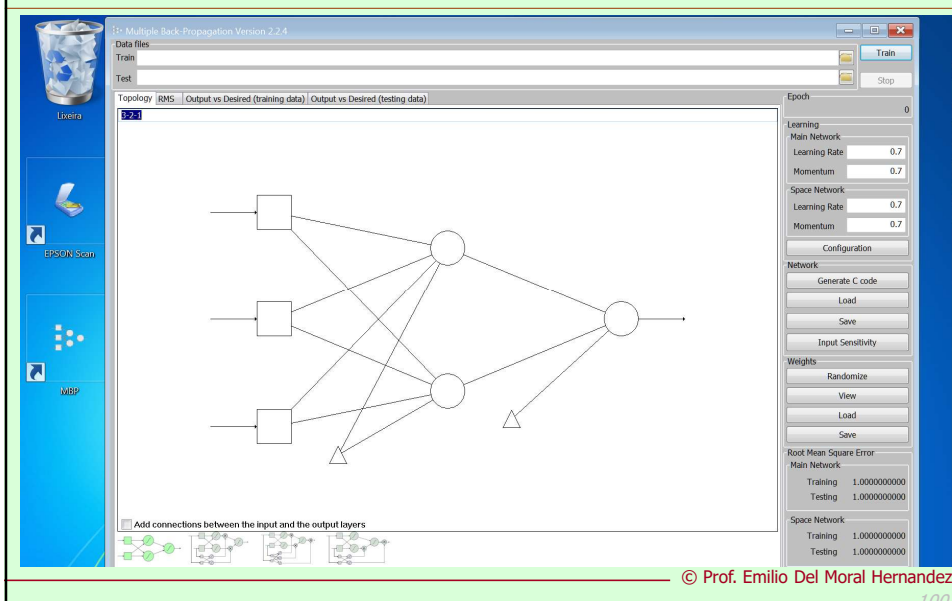
© Prof. Emilio Del Moral Hernandez

97

97

## Indo além do neurônio "camaleão" simples Uma rede neural com 3 nós neurais ...

100



© Prof. Emilio Del Moral Hernandez

100

100

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

101

Vamos pensar em nossos próprios desafios de regressão multivariada (com, digamos ao menos 4 variáveis de “entrada” no modelo) para a previsão / estimação de alguma grandeza relevante?  
Façamos isto no contexto de Eletrônica & Sistemas / ou de Sua ênfase.

**ATIVIDADE EM SALA,  
COM DEBATE COM COLEGAS  
E ENTREGA ESCRITA**

© Prof. Emilio Del Moral Hernandez

101

101

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

102

Vamos pensar em nossos próprios desafios de reconhecimento multivariado (com, digamos ao menos 4 variáveis de entrada no modelo) para uma detecção / reconhecimento automático relevante?  
Façamos isto no contexto de Eletrônica & Sistemas / ou de Sua ênfase.

**ATIVIDADE EM SALA,  
COM DEBATE COM COLEGAS  
E ENTREGA ESCRITA**

© Prof. Emilio Del Moral Hernandez

102

102

-1) Sua ênfase – sua Engenharia

0) Quais são os seus  $x$ 's e o seu  $y$ ? (que grandezas / a medidas de que correspondem?)

1) Quais as dimensões dos vetores de entrada e saída neste seu regressor?

2) Qual a precisão esperada? (o erro será zero em  $y$  estimado?)

3) Como você coletaria os dados empíricos com observações / pares  $(X_i; y_i)$ ?

4) Qual a utilidade do seu regressor? (Qual a utilidade da estimação de  $y$  CONTÍNUO dado  $X$ ?)

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

**Regressor multivariado (em sw, fw ou hw)**

103

© Prof. Emilio Del Moral Hernandez

103

-1) Sua ênfase – sua Engenharia

0) Quais são os seus  $x$ 's e o seu  $y$ ? (que grandezas são ? / a medidas de que correspondem?)

1) Quais as dimensões dos vetores de entrada e saída neste seu detector / reconecedor?

2) Porque a taxa de acerto esperada é menor que 100%?

3) Como você coletaria os dados empíricos com observações / pares  $(X_i; y_i)$ ?

4) Qual a utilidade do seu detector/reconecedor? (Qual a utilidade da estimar esse  $y$  BINÁRIO dado  $X$ ?)

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

**Detector / reconecedor / classificador multivariado (em sw, fw ou hw)**

104

© Prof. Emilio Del Moral Hernandez

104

Formalizar uma ideia possível  
para seu TCC envolvendo  
regressão multivariada e/ou  
reconhecimento / detecção (y  
binário) de padrões  
multivariados (X com muitas  
dimensões)

**PRELIMINAR, para  
você já ir pensando ...**