

## Disciplina PSI 3471 – Profs. Emilio e Hae - 2019

- 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

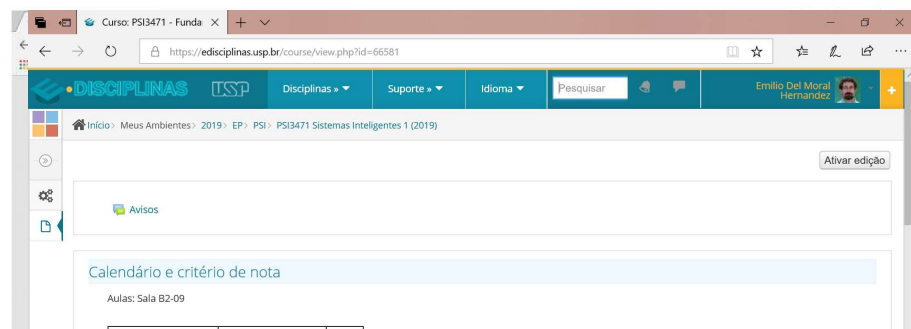
1

*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 "Curso: PSI3471 - Funda". The main content area shows a navigation menu with "Disciplinas", "Suporte", and "Idioma". Below the menu, there is a section titled "Calendário e critério de nota" with the text "Aulas: Sala B2-09".

4

Curso: PSI3471 - Funda

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

segunda-feira 7:30-9:10	quarta-feira 9:20-11:00	Tarefas
18/02 Emílio-1	20/02 Emílio-2	
25/03 Emílio-3	27/03 Emílio-4	
04/03 Carnaval	06/03 Carnaval	
11/03 Emílio-5	13/03 Emílio-6	
18/03 Emílio-7	20/03 Emílio-8	
25/03 Emílio-9	27/03 Emílio-10	
01/04 Emílio-11	03/04 Emílio-12	
08/04 Emílio-13	10/04 Emílio-14	
15/04 Semana Santa	17/04 Semana Santa	
22/04 Emílio-15	24/04 Hae-1	
29/04 P1 (Emílio)	01/05 Dia do trabalho	
06/05 Hae-2	08/05 Hae-3	
13/05 Hae-4	15/05 Hae-5	
20/05 Hae-6	22/05 Hae-7	
27/05 Hae-8	29/05 Hae-9	
03/06 Hae-10	05/06 Hae-11	
10/06 Hae-12	12/06 Hae-13	
17/06 Hae-14	19/06 Hae-15	
24/06 P2 (Hae)	(a definir) PSub	

Critério de nota:  
 Se  $\min\{MEmílio, MHae\} \geq 3$   
 então  $MFinal = (MEmílio + MHae) / 2$   
 senão  $MFinal = \min\{MEmílio, MHae\}$

MEmílio e MHae são calculadas como:  $(Prova + MExercícios) / 2$

PSub somente em caráter excepcional para quem justificar formalmente e no prazo a falta em alguma das duas provas (doença, luto, etc); a autorização da PSub está sujeita à aprovação dos Profs e às regras da CoC-PSI. No dia a combinar.

5

## Materiais de apoio às aulas no STOA

**ATENÇÃO: leitura destes NÃO substitui participação e atividades em sala de aula!**

Curso: PSI3471 - Funda | Jupiterweb

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

**Materiais do prof. Emílio (15 aulas de 18-fev a 22-abr + P1)**

Slides apresentados e outros materiais de apoio às atividades em sala serão disponibilizados aqui.

Atenção: Os materiais de apoio disponibilizados via STOA **NÃO Substituem as discussões e o aprendizado que ocorrem com a sua presença nas aulas desta disciplina**. 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.

[Ementa no sistema Jupiter](#)

**Materiais do prof. Hae**

Site do prof. Hae: <http://www.lps.usp.br/hae/>  
 Site desta disciplina: <http://www.lps.usp.br/hae/psi3471>  
 Apostilas e transparências: <http://www.lps.usp.br/hae/apostila>  
 Software para processamento de imagens: <http://www.lps.usp.br/hae/software>

**Tópico 4**

6

### **Tópicos:**

- Aprendizagem de máquina supervisionada: redes neurais, classificação por vizinhos mais próximos e técnicas supervisionadas similares.
- Reconhecimento de padrões,
  - classificação e
  - regressão não linear multivariada,
  - com aplicações em voz,
  - imagens e
  - fusão de informação em matrizes de sensores.
- Extração de características de informações complexas (imagens, vídeo, voz, sistemas multissensores, sinais biológicos)
- técnicas de redução de dimensionalidade: análise de componentes principais;
- análise harmônica; análise wavelet;
- ganho de informação.
- Técnicas de avaliação de qualidade:
  - validação cruzada;
  - k-fold cross validation;
  - curvas ROC em sistemas com limiar de decisão variável;
  - matrizes de confusão; sensibilidade e especificidade;
  - medidas de qualidade em regressão não linear multivariada.

© Prof. Emilio Del Moral Hernandez

7

### **... seguindo ( + tópicos):**

- Seleção de características e dimensionamento de reconhedores e regressores para limitação do sobreaprendizado (overfitting).
- Operações com pixels: sistemas de cores; histograma; limiarização.
- Operações de vizinhança: filtro linear; convolução; derivadas; Fourier; correlação cruzada normalizada; "template matching"; morfologia: filtro mediana.
- Transformações geométricas. Multi-resolução: pirâmide e espaço de escala; detecção de objetos robusta a mudança de escala.
- Uso de aprendizagem de máquina em visão computacional (ex: reconhecimento de dígitos manuscritos, projeto automático de filtros).

### **Bibliografia**

[1] Simon Haykin, "Redes Neurais: Princípios e Práticas", Bookman, 2001. [2] Simon Haykin, "Neural Networks and Learning Machines," Prentice Hall 2008. [3] R. O. Duda, P. E. Hart and D. G. Stork. "Pattern Classification", Wiley, 2001. [4] Cesare Alippi, "Intelligence for Embedded Systems, a Methodological Approach", Springer 2014. [5] André Fábio Kohn, "Reconhecimento de Padrões: uma Abordagem Estatística", Edição PEE/USP, 1998. [6] R. C. Gonzalez, R. E. Woods, "Digital Image Processing, Second Edition," Prentice-Hall, 2002. [7] G. Bradski and A. Kaehler, "Learning OpenCV - Computer Vision with the OpenCV Library," O'Reilly, 2008. [8] Richard Szeliski, "Computer Vision: Algorithms and Applications," (Texts in Computer Science), Springer, 2010.

© Prof. Emilio Del Moral Hernandez

8

## 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: [www.lsi.usp.br/ICONE](http://www.lsi.usp.br/ICONE)



© Prof. Emilio Del Moral Hernandez

9

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

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:

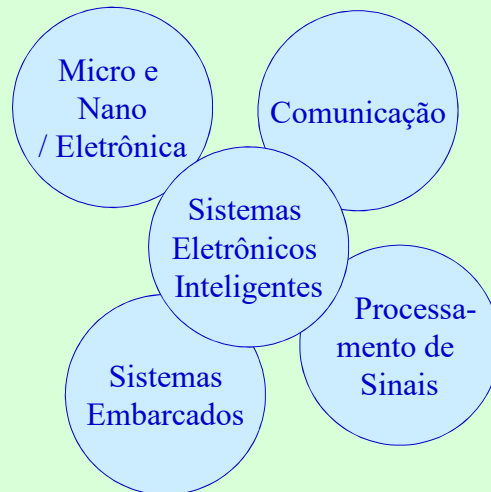
- Disciplinas em imagens eletivas de 5º ano
- Disc. em Proc. de Voz – eletiva do 5º
- Disc. em filragem adaptativa de 4º e 5º
- Disc. em embarcados eletrivas de 4º e 5º
- Disc optativa em Sistemas Cognitivos
- .... Outras ...

© Prof. Emilio Del Moral Hernandez

20

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

21



© Prof. Emilio Del Moral Hernandez

21

21

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

22

- 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

22

22

### **Tópicos:**

- Aprendizagem de máquina supervisionada: redes neurais, classificação por vizinhos mais próximos e técnicas supervisionadas similares.
- Reconhecimento de padrões,
  - classificação e
  - regressão não linear multivariada,
  - com aplicações em voz,
  - imagens e
  - fusão de informação em matrizes de sensores.
- Extração de características de informações complexas (imagens, vídeo, voz, sistemas multissensores, sinais biológicos)
- técnicas de redução de dimensionalidade: análise de componentes principais;
- análise harmônica; análise wavelet;
- ganho de informação.
- Técnicas de avaliação de qualidade:
  - validação cruzada;
  - k-fold cross validation;
  - curvas ROC em sistemas com limiar de decisão variável;
  - matrizes de confusão; sensibilidade e especificidade;
  - medidas de qualidade em regressão não linear multivariada.

© Prof. Emilio Del Moral Hernandez

23

23

### **... seguindo ( + tópicos):**

- Seleção de características e dimensionamento de reconhecedores e regressores para limitação do sobreaprendizado (overfitting).
- Operações com pixels: sistemas de cores; histograma; limiarização.
- Operações de vizinhança: filtro linear; convolução; derivadas; Fourier; correlação cruzada normalizada; "template matching"; morfologia: filtro mediana.
- Transformações geométricas. Multi-resolução: pirâmide e espaço de escala; detecção de objetos robusta a mudança de escala.
- Uso de aprendizagem de máquina em visão computacional (ex: reconhecimento de dígitos manuscritos, projeto automático de filtros).

### **Bibliografia**

[1] Simon Haykin, "Redes Neurais: Princípios e Práticas", Bookman, 2001. [2] Simon Haykin, "Neural Networks and Learning Machines," Prentice Hall 2008. [3] R. O. Duda, P. E. Hart and D. G. Stork. "Pattern Classification", Wiley, 2001. [4] Cesare Alippi, "Intelligence for Embedded Systems, a Methodological Approach", Springer 2014. [5] André Fábio Kohn, "Reconhecimento de Padrões: uma Abordagem Estatística", Edição PEE/USP, 1998. [6] R. C. Gonzalez, R. E. Woods, "Digital Image Processing, Second Edition," Prentice-Hall, 2002. [7] G. Bradski and A. Kaehler, "Learning OpenCV - Computer Vision with the OpenCV Library," O'Reilly, 2008. [8] Richard Szeliski, "Computer Vision: Algorithms and Applications," (Texts in Computer Science), Springer, 2010.

© Prof. Emilio Del Moral Hernandez

24

24

## 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 ([www.lsi.usp.br/ICONE](http://www.lsi.usp.br/ICONE))
- IEEE Computational Intelligence Society (congressos e periódicos)

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

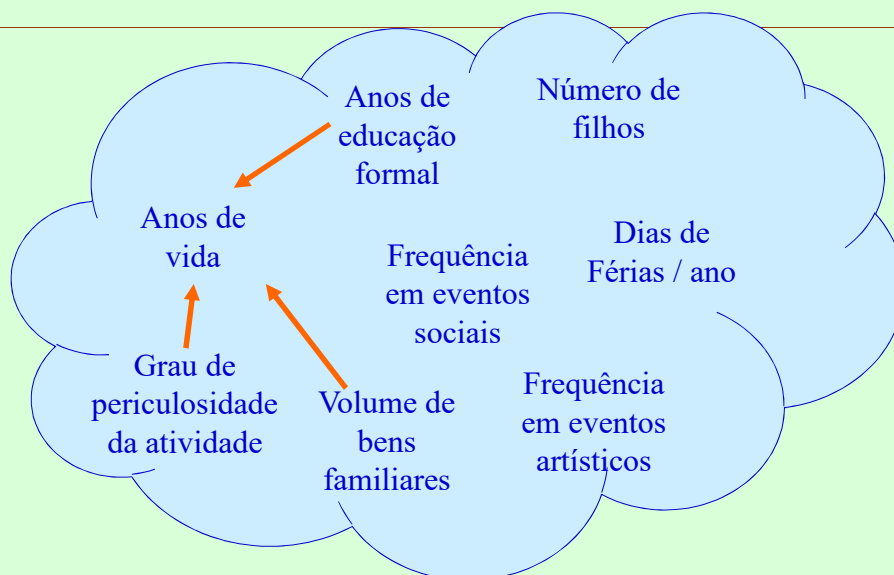
## Um hipotético universo de variáveis interdependentes, passível de modelagem/ens



© Prof. Emilio Del Moral Hernandez

27

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

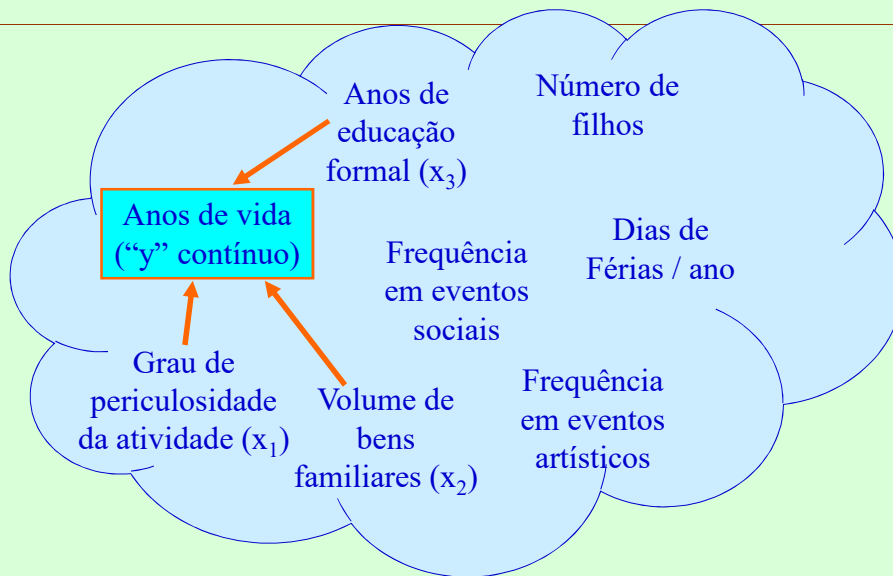


© Prof. Emilio Del Moral Hernandez

28



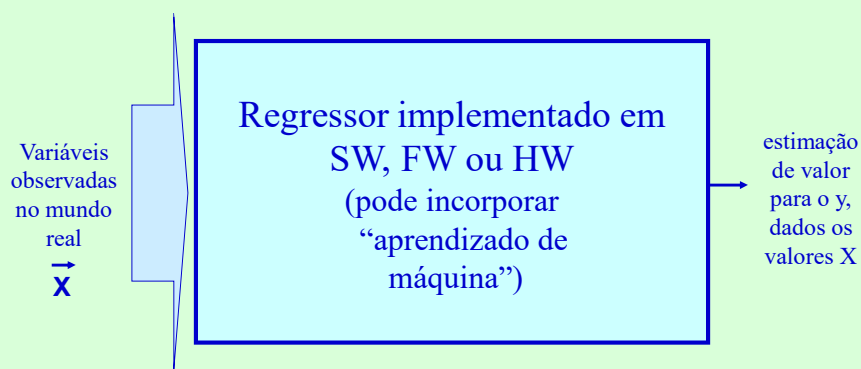
## Um hipotético universo de variáveis interdependentes, passível de modelagem/ens



© Prof. Emilio Del Moral Hernandez

29

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



© Prof. Emilio Del Moral Hernandez

30

## Algumas possibilidades para regressão linear sobre dados empíricos do universo de valores $(x_1, x_2, x_3, y)$ ....

- Modelagem por reta média (considerando por exemplo unicamente a variável  $x_1$  como impactante significativo em  $y$ )
- Modelagem por plano médio (considerando  $x_1$  e  $x_2$ )
- Modelagem por hiperplano médio ( $x_1$ ,  $x_2$  e  $x_3$ )

*Discutamos em lousa alguma formulação matemática ...*

© Prof. Emilio Del Moral Hernandez

31

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

Vamos pensar em nossos próprios desafios de regressão multivariada (com, digamos ao menos 3 variáveis de “entrada” no modelo) para a previsão / estimação de alguma grandeza relevante?  
Façamos isto no contexto de Eletrônica / Sistemas / Sua ênfase.

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

© Prof. Emilio Del Moral Hernandez

32

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

33

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

© Prof. Emilio Del Moral Hernandez

33

33

34

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

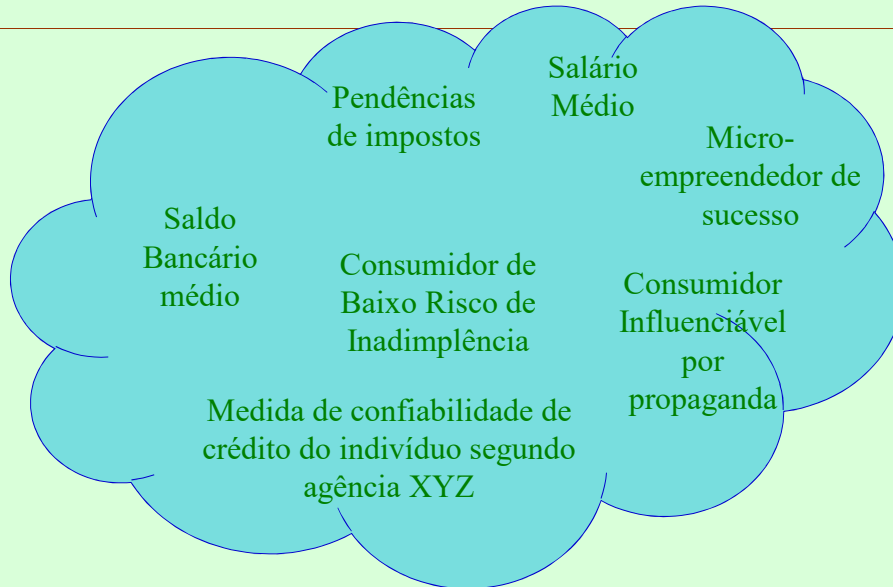
© Prof. Emilio Del Moral Hernandez

34

34

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

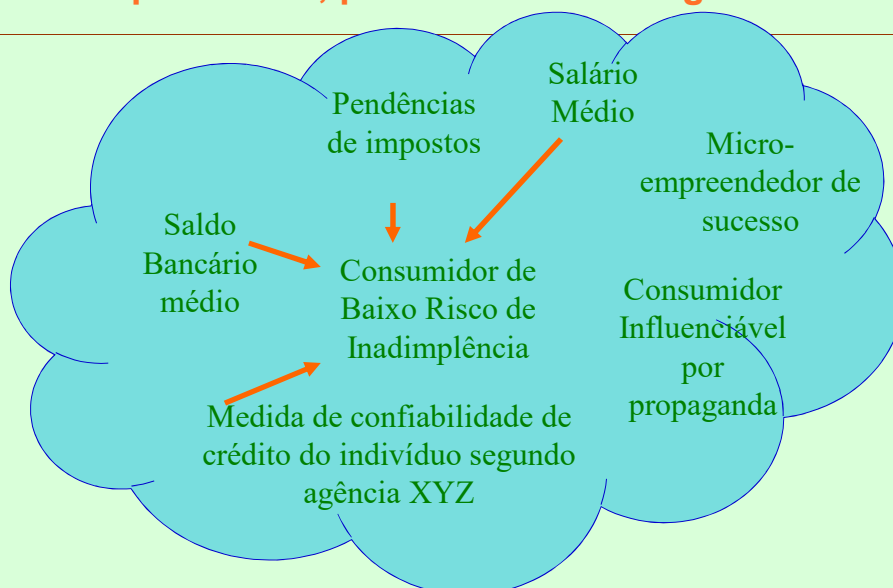
35



35

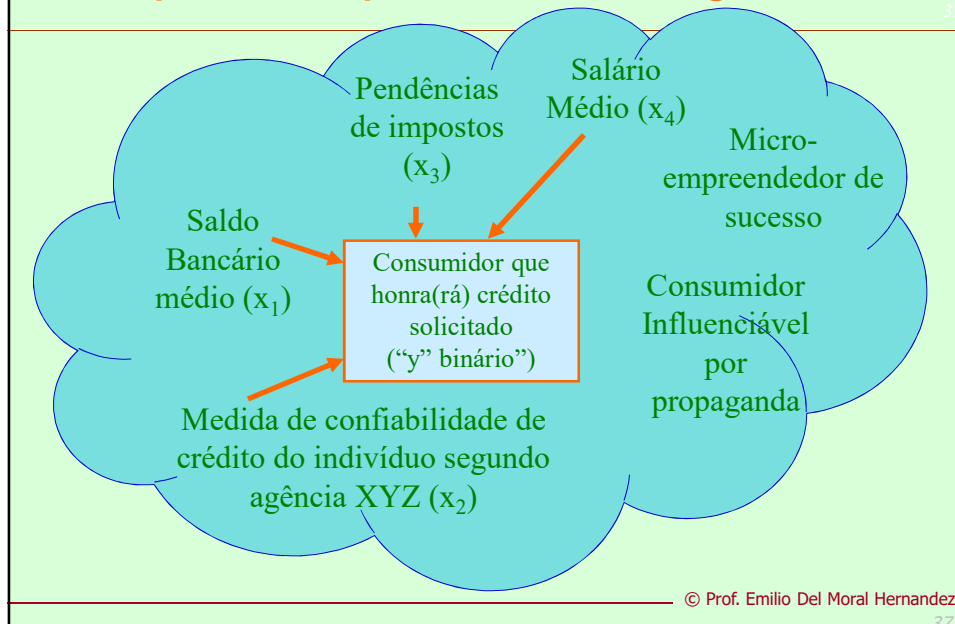
## Um hipotético universo de variáveis inter-dependentes, passível de modelagem/ens

36



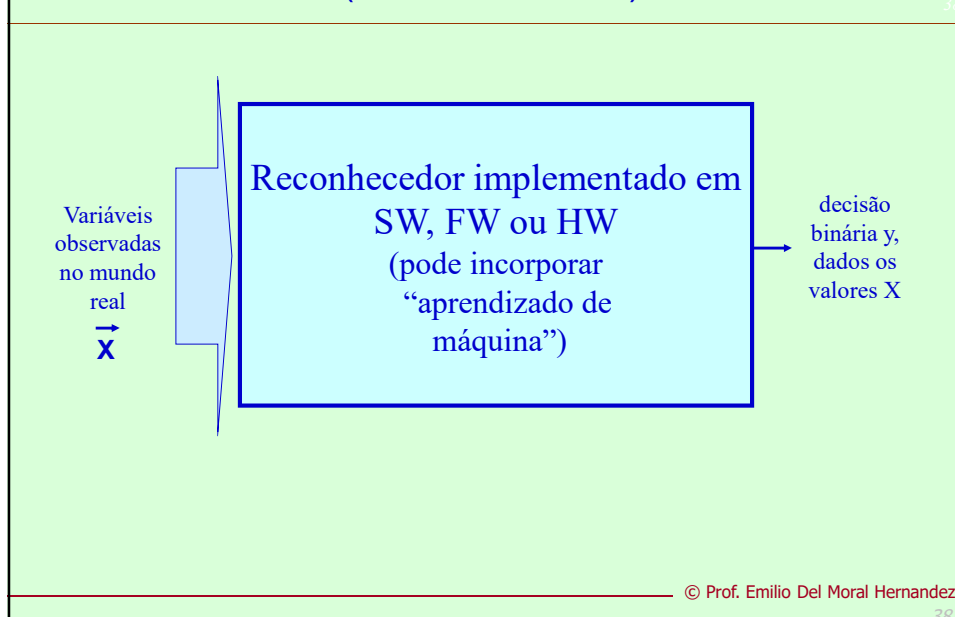
36

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



37

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



38

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

39

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

© Prof. Emilio Del Moral Hernandez


39

39

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

40

Universo de objetos observados ...



© Prof. Emilio Del Moral Hernandez

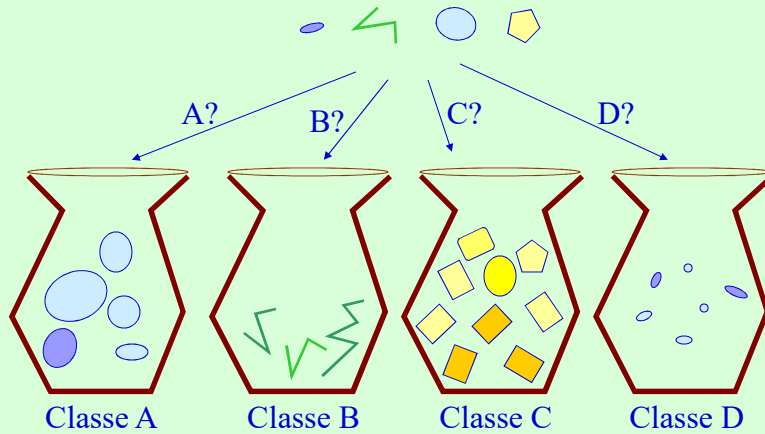
40

40

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

42

Um dado objeto específico observado é de que tipo ?




© Prof. Emilio Del Moral Hernandez

42

42

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

44



© Prof. Emilio Del Moral Hernandez

44

44

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

45

Vamos pensar em nossos próprios desafios de reconhecimento multivariado (com, digamos ao menos 3 variáveis de entrada no modelo) para uma classificação / reconhecimento / categorização automática relevante?

Façamos isto no contexto de Eletrônica & Sistemas / Sua ênfase.

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

© Prof. Emilio Del Moral Hernandez

45

45

### Tópicos:

- Aprendizagem de máquina supervisionada: redes neurais, classificação por vizinhos mais próximos e técnicas supervisionadas similares.
- Reconhecimento de padrões,
  - classificação e
  - regressão não linear multivariada,
  - com aplicações em voz,
  - imagens e
  - fusão de informação em matrizes de sensores.
- Extração de características de informações complexas (imagens, vídeo, voz, sistemas multissensores, sinais biológicos)
- técnicas de redução de dimensionalidade: análise de componentes principais;
- análise harmônica; análise wavelet;
- ganho de informação.
- Técnicas de avaliação de qualidade:
  - validação cruzada;
  - k-fold cross validation;
  - curvas ROC em sistemas com limiar de decisão variável;
  - matrizes de confusão; sensibilidade e especificidade;
  - medidas de qualidade em regressão não linear multivariada.

© Prof. Emilio Del Moral Hernandez

46

46



**... seguindo (+ tópicos):**

- Seleção de características e dimensionamento de reconhedores e regressores para limitação do sobreaprendizado (overfitting).
- Operações com pixels: sistemas de cores; histograma; limiarização.
- Operações de vizinhança: filtro linear; convolução; derivadas; Fourier; correlação cruzada normalizada; "template matching"; morfologia; filtro mediana.
- Transformações geométricas. Multi-resolução: pirâmide e espaço de escala; detecção de objetos robusta a mudança de escala.
- Uso de aprendizagem de máquina em visão computacional (ex: reconhecimento de dígitos manuscritos, projeto automático de filtros).

**Bibliografia**

[1] Simon Haykin, "Redes Neurais: Princípios e Práticas", Bookman, 2001. [2] Simon Haykin, "Neural Networks and Learning Machines," Prentice Hall 2008. [3] R. O. Duda, P. E. Hart and D. G. Stork. "Pattern Classification", Wiley, 2001. [4] Cesare Alippi, "Intelligence for Embedded Systems, a Methodological Approach", Springer 2014. [5] André Fábio Kohn, "Reconhecimento de Padrões: uma Abordagem Estatística", Edição PEE/USP, 1998. [6] R. C. Gonzalez, R. E. Woods, "Digital Image Processing, Second Edition," Prentice-Hall, 2002. [7] G. Bradski and A. Kaehler, "Learning OpenCV - Computer Vision with the OpenCV Library," O'Reilly, 2008. [8] Richard Szeliski, "Computer Vision: Algorithms and Applications," (Texts in Computer Science), Springer, 2010.

50

Concluindo com um 3º item e entregando a atividade criativa ...  
 Registrar adequadamente em A4 as duas propostas (regressor e reconhecedor) e em 3º item formalizar uma ideia possível para seu TCC envolvendo regressão multivariada e/ou reconhecimento de padrões multivariado

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

© Prof. Emilio Del Moral Hernandez

50

50

51

## Lembrete – o STOA PSI3471 cresce a cada semana ...

Curso: PSI3471 - Funda x PSI2672-2017101: Lista de l | Multiple Back-Propagation | Sistemas Inteligentes 1: Cor +

disciplinas.usp.br/course/view.php?id=61009

**Materiais do Prof. Emilio - Parte inicial do curso (26/02 a 23/04)**

Atenção: A leitura dos materiais de apoio disponibilizado via STOA **NÃO Substituem as discussões e o aprendizado que ocorrem com a sua presença nas aulas desta disciplina**. 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.

- Alguns slides de apoio ao início de PSI3471-2018 - Prof EmilioDMH (Spoiler de slides) ATENÇÃO: Os MATERIAIS DE ESTUDO NÃO SUBSTITUEM a PRESENÇA e as ATIVIDADES em sala de aula!!
- 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
- Breve descrição dos 12 projetos mais recentes de PSI2672 (disciplina de 5o ano), que foram apresentados em 2017
- Instale o ambiente MBP no seu computador Windows (instale / use máquina virtual se seu computador for Apple; ou use os computadores da sala C1-10 ou similar)

**Diversos adicionais referentes às temáticas até P1 - inclui contribuições de colegas de sala!**

- Contribuição de Lucas Ribeiro - Ambiente de ilustração / exercício identificado por colega de sala de aula de PSI3471

Materiais: O que você deseja fazer com 333-Arquivo com slides de 50 Projetos em PSI2672 2011-2016 (1).zip? De: edisciplinas.usp.br

© Prof. Emilio Del Moral Hernandez

51

51

Inventário de Projetos Desenvolvidos em PSI 2672 - Práticas em Reconhecimento de Padrões, Modelagem e Neurocomputação, nas 6 turmas de 2011 a 2016  
prof. Emilio Del Moral Hernandez

Ano 2016

Cancelador ativo de ruído  
Classificação de fibrilação atrial a partir de eletrocardiograma  
Classificador de movimentos a partir de acelerômetro vestível  
Estimador de Valor de Ações (Flutuações Financeiras e Predição)  
Estimador de desempenho em redação (desempenho escolar)  
Medidor da qualidade da água  
Reconhecedor de dígitos de placas de veículos  
Reconhecedor de imagens de frutas  
Rec. da intenção de mover a mão direita e a esquerda a partir de sinais cerebrais

Ano 2015

Estimador do valor de fechamento das ações da Petrobras  
Classificador de instrumentos musicais  
Regressor embarcado para ventilação inteligente  
Solar Power Production Estimation (Software for a Smart Metering device)  
Reconhecedor de Objetos em Imagens Digitais  
Reconhecimento de Folhas a Partir de Fotos com Fundo Branco  
Benchmark de CPUs: um regressor multivariado de desempenho  
Reconhecedor de caracteres: um classificador de padrões  
Reconhecedor de acordes musicais: um classificador de padrões  
Detecção de Fraudes em Compras no Cartão  
Padrões nos Sobreviventes e Vítimas do Titanic  
Estimador de pigmentos para tintas a partir de uma amostra

© Prof. Emilio Del Moral Hernandez

52

Ano 2014

Identificador de sistema dinâmico  
Previsor Futebolístico  
Eye tracker  
Reconhecimento de placas de automóveis  
Reconhecimento de padrões de consumo em aparelhos aplicado a Smart Grids  
Estimativa de preços de carros  
Classificador de cogumelos venenosos

Ano 2013

Classificação de sinais de EEG e relação com epilepsia  
Estimador de consumo de eletricidade residencial  
Análise Sentimental de notícias  
Identificação de um Pixel Isolado em uma Imagem Simples  
Preditor de sobrevivência em pacientes Cardíacos  
Estimador do grau do mal de Parkinson  
Classificador de idiomas

Ano 2012

Classificação da Qualidade do Leite  
Estimador de PH para amostras de vinho  
Previsão de Ações na Bolsa de Valores (reconhecedor de padrões)  
Previsão de Ações na Bolsa de Valores (estimador)  
Reconhecedor de Combustível Adulterado

Ano 2011

Classificação em Gêneros Musicais  
Estimador de Correção do Erro de um Sensor de Pressão Diferencial  
Análise da qualidade de vinhos baseado em características físico-químicas  
Sistema de reconhecimento de Placas de Trânsito  
Reconhecedor de Alcoolismo e Sinais Cerebrais  
Língua eletrônica para a determinação de propriedades do leite

53

## Lembrete – o STOA PSI3471 cresce a cada semana ...

54

Curso: PSI3471 - Fundamen | PSI2672-2017101: Lista | Multiple Back-Propagation | Sistemas Inteligentes 1: Cor +

edisciplinas.usp.br/mod/page/view.php?id=1835195

DISCIPLINAS USP Apoio às disciplinas da USP

Acesso Senha USP

Início > Ambientes > 2017 > EP > PSI > PSI2672-2017101 > Projetos Finais de PSI2672 em 2017 > Lista de Projetos Finais de PSI2672 realizados em ...

Lista de Projetos Finais de PSI2672 realizados em grupo, em 2017

Lista de Projetos Finais de PSI2672 realizados em grupo, em 2017 - Apresentações ocorrem nos dias 21 de junho (Grupo 1 e mais algum outro que decida antecipar) e 28 de junho (demais grupos), na B2-09 às 15:30 hs; ao final da lista, há + detalhes para alguns dos 12 projetos

**Dois Projetos do Grupo 1:**

(Carlos Grívol, Carlos Prete, Gabriel Crabbé, Tiago Azevedo)

- Regressor multivariado: CIDADE LISA - Sistema automático de detecção de irregularidades nas vias usando smartphones
- Reconhecedor de padrões: ABCIS - Automatic Brazilian Coin Identification System

**Dois Projetos do Grupo 2:**

(Felipe Y., Alan, Felipe La Regina, Saint Clair Bernardes)

- Regressor multivariado: Previsor de taxa de acertos de questões de Matemática e Física de vestibular
- Reconhecedor de padrões: Analisador da qualidade do ar embasado nos níveis de concentração de gás carbônico, ozônio monóxido de carbono, temperatura, umidade e dióxido de nitrogênio.

<https://edisciplinas.usp.br/mod/page/view.php?id=1835195>

© Prof. Emilio Del Moral Hernandez

54

## Lembrete – o STOA PSI3471 cresce a cada semana ...

55

Curso: PSI3471 - Fundamen | PSI2672-2017101: Lista de 1 | Multiple Back-Propagation | Sistemas Inteligentes 1: X +

edisciplinas.usp.br/mod/page/view.php?id=2282074

DISCIPLINAS USP Apoio às disciplinas da USP

Acesso Senha USP

Início > Ambientes > 2018 > EP > PSI > Sistemas Inteligentes 1 > Diversos adicionais referentes às temáticas até P1... > Contribuição de Lucas Ribeiro - Ambiente de ilustr...

Contribuição de Lucas Ribeiro - Ambiente de ilustração / exercício identificado por colega de sala de aula de PSI3471

Contribuição voluntária de Lucas Ribeiro:

....

segue o link para a Teachable Machine:

<https://teachablemachine.withgoogle.com/>

Descrição:

Página com demonstração de reconhecimento de padrões em imagens utilizando aprendizado de máquina. É muito simples de usar: não é necessário programar nem instalar nada, e a própria página contém um tutorial e explicações extras.

..

Lucas R.

Última atualização: terça, 6 Mar 2018, 21:19

© Prof. Emilio Del Moral Hernandez

55

Lembrete – o STOA PSI3471 cresce a cada semana ...

56

**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

56

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

57

- 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

57

## Quais vocês acham seriam valores adequados aos pesos “w” de cada entrada nesses 2 exemplos?

- No caso de  
 $\text{anos\_vida} = f_{\text{Tlinear}}(\text{educação, bens, periculosidade})$
- E no caso de  
 $\text{bom\_pagador} = f_{\text{Dlinear}}(\text{saldo, salário, crédito})$
- Qual o papel do viés nessas duas análises?
- Sabem a diferença de transformação linear e afim? ...  
.... Importante para conciliar nosso jargão em reconhecimento de padrões com o jargão de sistemas lineares

59

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

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  $ox$ . Tal função também pode ser entendida como uma transformação linear ( $Ax$ ) seguida por uma translação ( $+b$ ).

$$z \mapsto Ax + b$$

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"  $B$ . 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 (su seja, quando  $x$  e  $y$  são escalares), os termos  $A$  e  $b$  são chamados, respectivamente, de coeficiente angular e coeficiente linear.

**Índice** [esconder]

- 1 Definição formal
  - 1.1 Coeficientes<sup>[?]</sup>
- 2 Função linear
  - 2.1 Função linear e proporcionalidade
- 3 Crescimento ou decrescimento
  - 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

60

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

61

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

**Função linear** [editar | editar código-fonte]

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** [editar | editar código-fonte]

Ver artigo principal: 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  $x$ .<sup>[R]</sup>

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

**Crescimento ou decréscimo** [editar | editar código-fonte]

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

**Crescente** [editar | editar código-fonte]

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


**Demonstração:**<sup>[R]</sup>

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  $f(x_1) < f(x_2)$ .




61

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

62



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




© Prof. Emilio Del Moral Hernandez

62

62

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

63




© Prof. Emilio Del Moral Hernandez

63

63

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

64



© Prof. Emilio Del Moral Hernandez

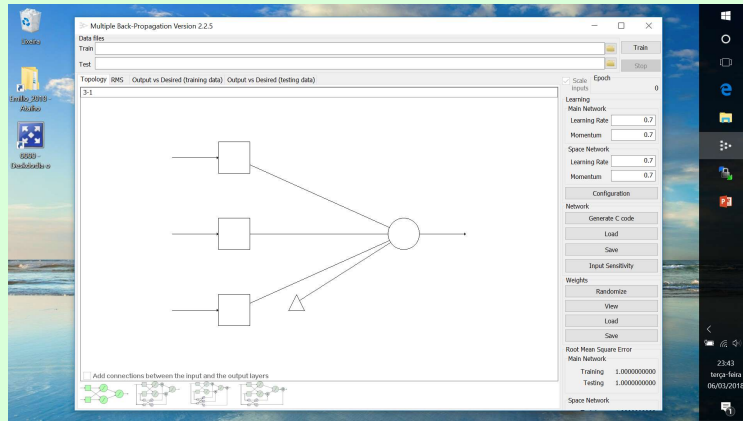
64

64



## Instale o MBP e digite "3-1" no campo Topology

65

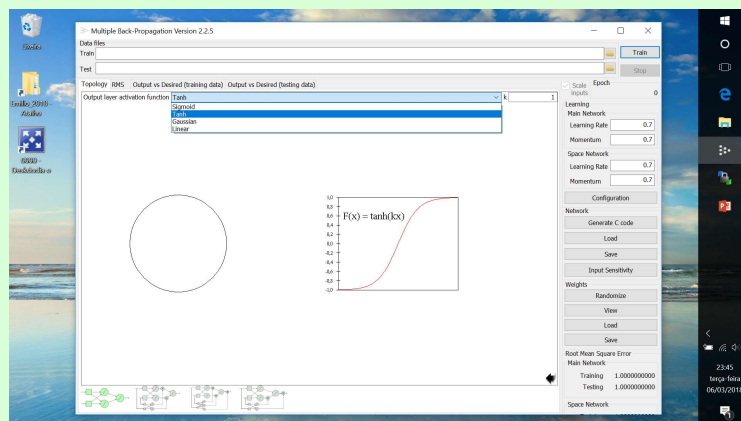


© Prof. Emilio Del Moral Hernandez

65

## Depois escolha a função de ativação do nó neural

66




© Prof. Emilio Del Moral Hernandez

66

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

68

- 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




68

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

69

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



69

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

© Prof. Emilio Del Moral Hernandez

70

*Alguns exemplos de  
sistemas de  
reconhecimento  
e de  
regressão  
multivariada, com os  
quais tive contato e que  
empregaram redes neurais  
e técnicas relacionadas*

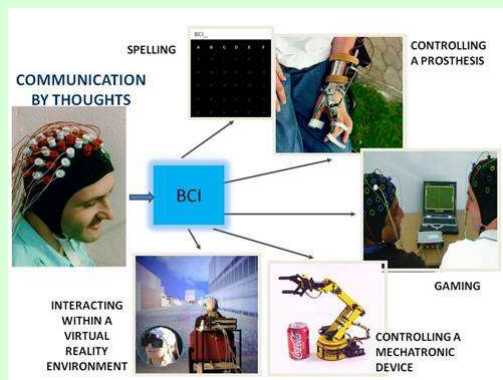
19

PSI2672 – Rec Padrões, Modelagem, Redes Neurais – Prof. Emilio Del Moral Hernandez – © 2016

74

## Brain Computer Interfaces ... “um amplo parênteses” ...

75




© Prof. Emilio Del Moral Hernandez

75

75

## Brain Computer Interfaces – área do trabalho do doutorando Julio Cesar Saldaña

76



Slide - Contribuição de Julio Cesar Saldaña - EPUSP

© Prof. Emilio Del Moral Hernandez

76

76

## Sistemas Implantáveis de Registro Neural e BCIs

77




Figura 1: Imagem extraída do site do pesquisador Benjamin I. Rapoport

Slide - Contribuição de Julio Cesar Saldaña - EPUSP

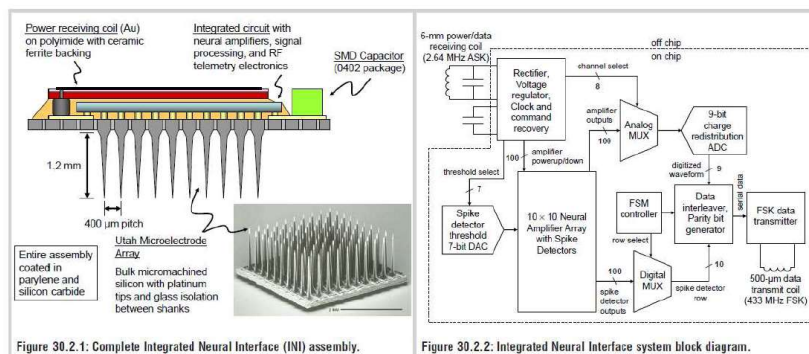
© Prof. Emilio Del Moral Hernandez

77

77

## Sistemas Implantáveis de Registro Neural e BCIs

79



[Harrison et al. 2006], [Harrison et al. 2007]

Slide - Contribuição de Julio Cesar Saldaña - EPUSP

© Prof. Emilio Del Moral Hernandez

79

79

### Separação de impulsos elétricos ou *Spike Sorting*




Figura 6: Extraída do artigo [Karkare, Gibson e Markovic 2013] (JSSC, Set. 2013)

Slide - Contribuição de Julio Cesar Saldaña - EPUSP

© Prof. Emilio Del Moral Hernandez

*Alguns exemplos de projetos de 5º ano em PSI2672 da EC2 de anos anteriores (2011 a 2016); No 5º ano da EC3, temos atividades de projeto similares na eletiva PSI3571.*

© Prof. Emilio Del Moral Hernandez

## Exemplos de projetos concebidos e realizados por alunos da disciplina EC2 PSI-2672 (na EC3, ~ PSI-3571)

82

material  
bibliografia  
exemplos  
2011

**Projetos finais:**

1. Classificação em gêneros musicais ([gr\\_I\\_apresentacao\\_Musicas.pdf](#))
2. Implementação de um sistema para correção da medida de um sensor de pressão diferencial ([gr\\_II\\_Apresentacao\\_rna\\_sensor\\_pressao\\_03\\_01.pdf](#))
3. Análise da qualidade dos vinhos a partir de testes físico-químicos ([gr\\_III\\_apresentacao\\_PSI2672 - Análise de vinhos.pdf](#))
4. Reconhecimento de placas de trânsito ([gr\\_IV\\_apresentacao\\_Reconhecimento\\_de\\_placas.pdf](#))
5. Reconhecedor de alcoolismo ([gr\\_V\\_apresentacao\\_Reconhecedor Alcoolismo.pdf](#))
6. Língua eletrônica ([gr\\_VI\\_apresentacao\\_lingua\\_eletronica.pdf](#))
7. Reconhecimento de dígitos ([gr\\_VII\\_apresentacao\\_Reconhecedor de digitos.pdf](#))

Informações sobre o programa do curso: [Programa\\_PSI2672\\_2011.pdf](#)

© Prof. Emilio Del Moral Hernandez

82

82

## Lembrete – o STOA PSI3471 cresce a cada semana ...

83

PSI3471 - Funda × +

disciplinas.usp.br/course/view.php?id=61009

### Materiais do Prof. Emilio - Parte inicial do curso

- Alguns slides de apoio ao início de PSI3471-2018 - Prof EmilioDMH (Spoiler de slides) **ATENÇÃO: Os MATERIAIS DE ESTUDO NÃO SUBSTITUEM a PRESENÇA e as ATIVIDADES em sala de aula!!**
- [Repositório \(36Mb\) de apresentações finais de PSI2672 ~ 50 projetos de alunos de 5o ano / Prof Emilio Del Moral Hernandez](#)

as.usp.br/course/view.php?id=61009#section-2

83

## Classificação automática de generos musicais


84

### DESCRIÇÃO DO PROBLEMA

Categorizar músicas em gêneros automaticamente baseado em trechos de suas gravações e exemplos rotulados *a priori*

- 1) Blues
- 2) Classical
- 3) Country
- 4) Disco
- 5) Hip-Hop
- 6) Jazz
- 7) Metal
- 8) Pop
- 9) Reggae
- 10) Rock

### A SOLUÇÃO



*projeto de alunos em PSI-2672*

© Prof. Emilio Del Moral Hernandez

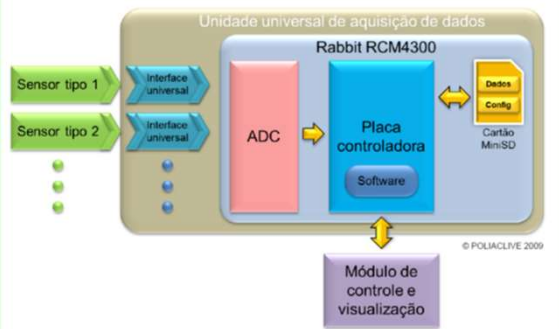
84

## Sistema de fusão de sensores: por exemplo pressão e temperatura

85

### Introdução

Eletrônica embarcada



*projeto de alunos em PSI-2672*

© Prof. Emilio Del Moral Hernandez

85



## Língua Eletrônica para controle de qualidade alimentar e detecção de substâncias nocivas

86



1. Gordura
2. Proteína
3. Lactose
4. pH

- Sistema com 4 sensores;
- Sistema com 5 frequências diferentes em cada sensor;
  - $4 \times 5 = 20$  entradas para a RNA

*projeto de alunos em PSI-2672*

© Prof. Emilio Del Moral Hernandez

86

86

## Seguidor do alvo dos olhos na tela do computador

87

### Eye-tracker – Definição do problema

"Utilizar técnicas neurais para determinar a posição (x,y) para a qual os olhos do usuário estão apontados na tela"



### Coleta de dados



Método semi-automático de coleta de dados:

- Divisão da tela do computador em 25 quadrantes
- Para cada quadrante, tirar 20 fotos do olho (somente do olho, não do rosto todo) apontando para a posição (com ajuda de software para tirar fotos e salvá-las)

Total de elementos da amostra: 500 fotos

### Pré-processamento



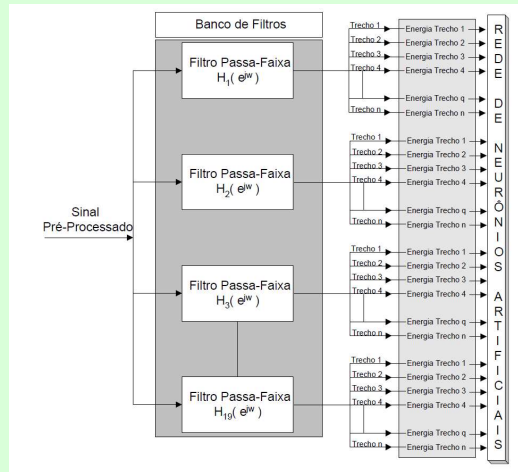
*projeto de alunos em PSI-2672*

87

87

## TCC em Reconhecimento de comandos de voz (Daniel e Gabriel) – sobe, desce, esquerda, direita

88



© Prof. Emilio Del Moral Hernandez

88

88

## Medida de qualidade do reconhecedor de comandos de voz ensaiado ...

89

amostra \ resultado	SOBE	DESCE	ESQUERDA	DIREITA
SOBE	85%	0%	15%	0%
DESCE	0%	100%	0%	0%
ESQUERDA	0%	0%	80%	20%
DIREITA	0%	0%	10%	90%

© Prof. Emilio Del Moral Hernandez

89

89

## Exemplo de modelagem / reconhecimento automático de padrões ... (tese de Liselene / Prof Miguel)

91

### O procedimento de detecção do Vazamento

- \* Haste de escuta
- \* Correlacionador de ruído
- \* Geofone



© Prof. Emilio Del Moral Hernandez


91

91

## Exemplo de modelagem / reconhecimento automático de padrões ... (tese de Liselene / Prof Miguel)

92

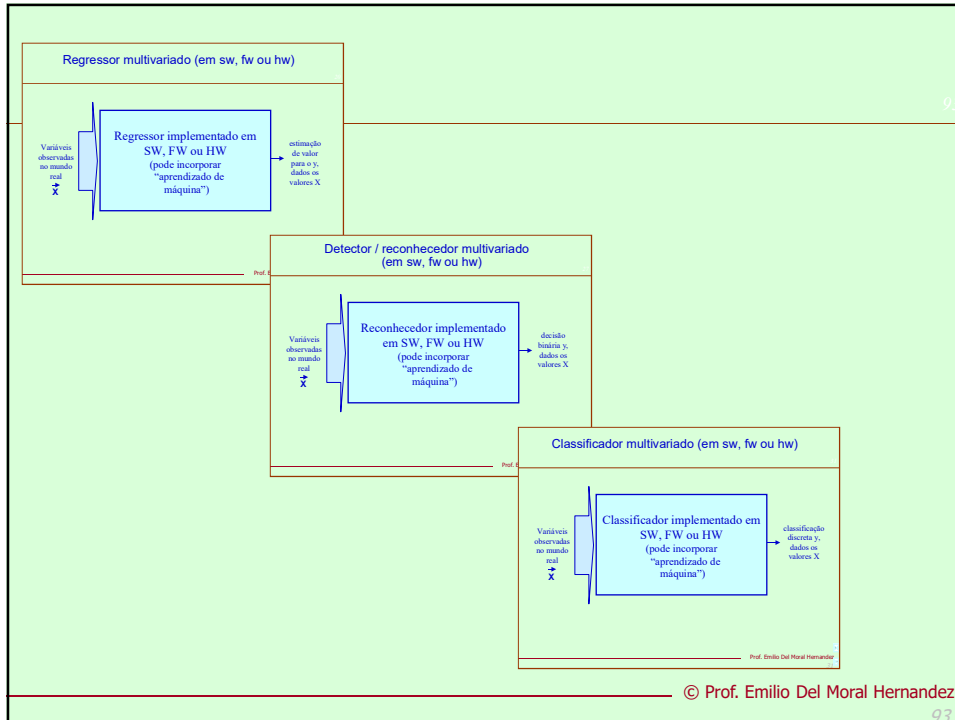
### Sistema de Deteção de Vazamento



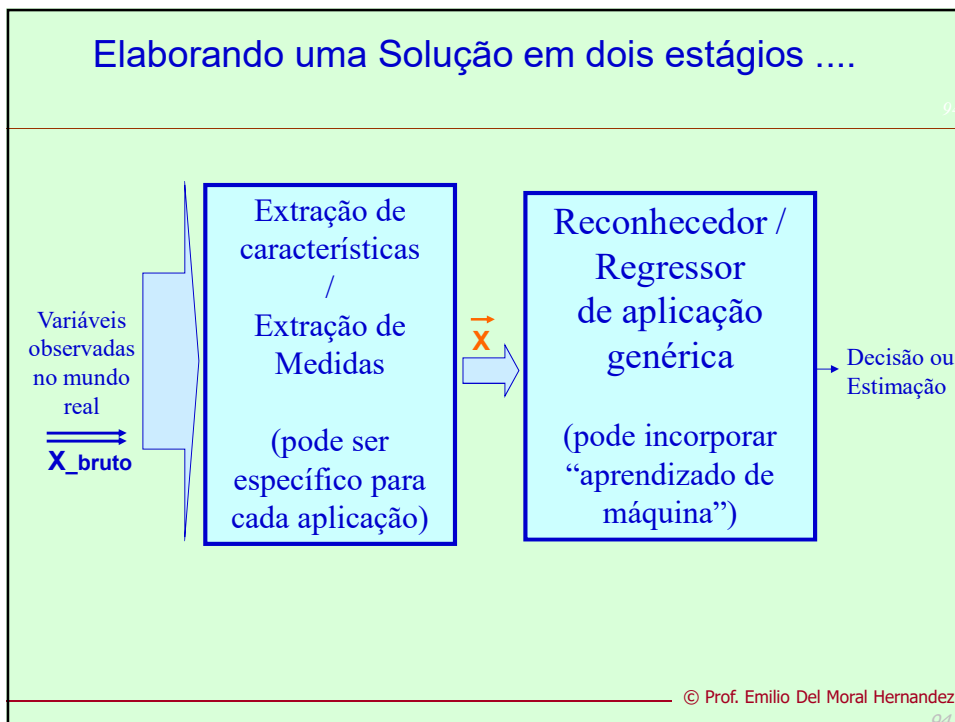
© Prof. Emilio Del Moral Hernandez

92

92



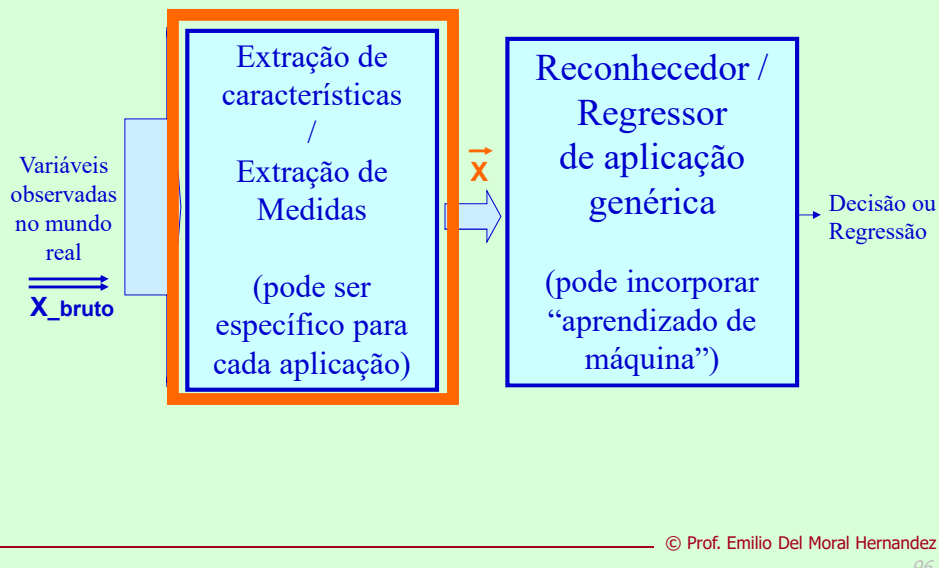
93



94

... O 1o estágio gera um Vetor de Medidas,  $\vec{X}$   
(o segundo estágio operará sobre tal vetor)

96



© Prof. Emilio Del Moral Hernandez

96

96

### Alguns exemplos de grandezas componentes dos vetores de medidas $X$ :

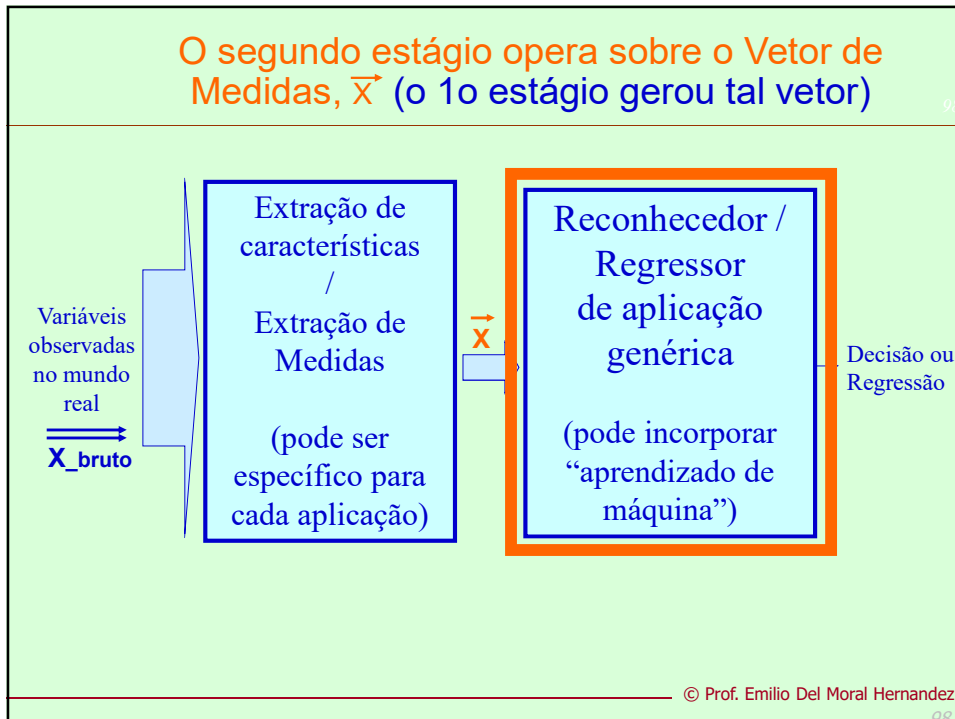
97

- Grandezas macroscópicas como energia do sinal, amplitude, frequência média ...
- Componentes de diversas harmônicas (análise em frequência)
- Componentes de análise tempo-frequência
- Intensidades luminosas ou intensidades em canais de cor (RGB por ex.)
- Histogramas de intensidades
- Principal Components (componentes principais – PCA)
- Medidas sobre séries temporais (médias móveis, por exemplo; medidas de dispersão / instabilidade localizadas)
- Medidas específicas à aplicação, experimentadas em problemas similares ao seu, relatadas na literatura técnica como sendo de sucesso

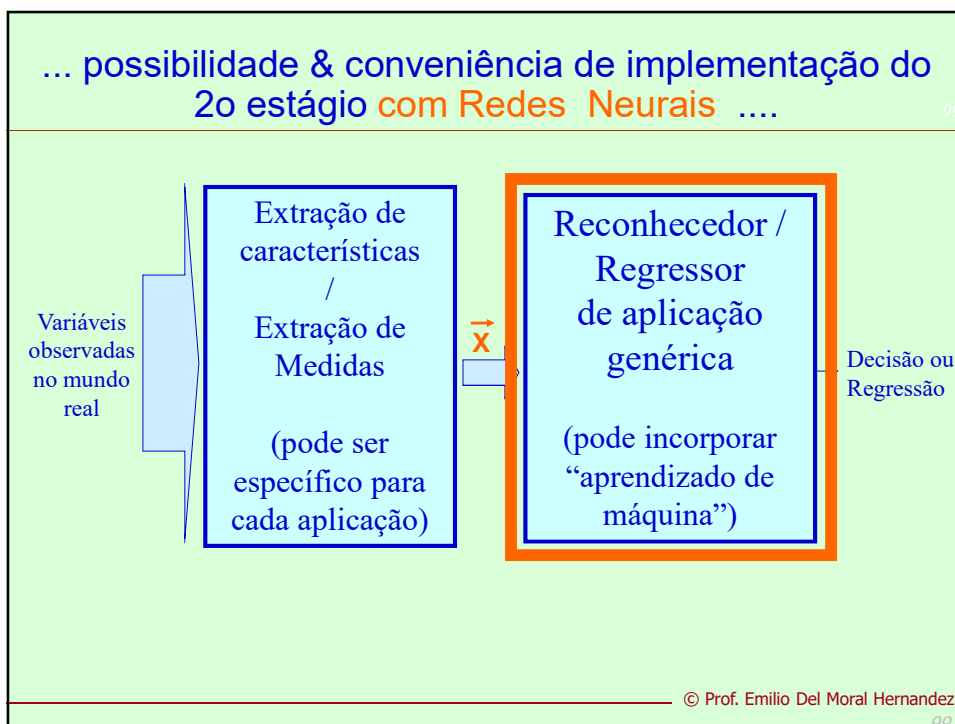
© Prof. Emilio Del Moral Hernandez

97

97




98



99

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

100




© Prof. Emilio Del Moral Hernandez

100

100

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

101




© Prof. Emilio Del Moral Hernandez

101

101

## Computação linear e não linear, com codificação frequencial

102



© Prof. Emilio Del Moral Hernandez

102

102

## Redes Neurais Artificiais

104

**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 – como os neurônios se interligam
- O aprendizado através de exemplos (através de casos)

© Prof. Emilio Del Moral Hernandez


104

104



## Cômputos mais complexos ... são realizados pelo encadeamento de vários neurônios

105



A conexão entre um axônio de um neurônio e um dendrito de outro é denominada **Sinapse**

© Prof. Emilio Del Moral Hernandez

105

105





## Três arquiteturas neurais importantes (abordadas em pósgrad – PSI 5886)

106

1) MLP  
- Multi Layer  
Perceptron

2) Memória  
Associativa  
de Hopfield

3) Mapas Auto-  
Organizáveis  
de Kohonen



© Prof. Emilio Del Moral Hernandez

106

106

## Três arquiteturas neurais importantes

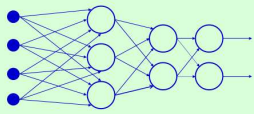
(abordadas em pósgrad – PSI 5886)

**Nosso Foco aqui**

### 1) MLP - Multi Layer Perceptron

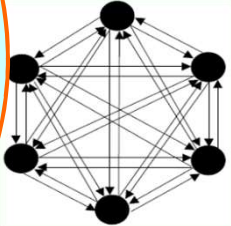
Foco deste Curso: o Multi Layer Perceptron (MLP)

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

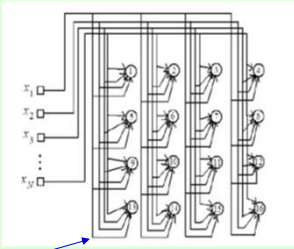


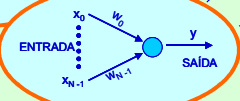
© Prof. Emilio Del Moral Hernandez

### 2) Memória Associativa de Hopfield



### 3) Mapas Auto-Organizáveis de Kohonen





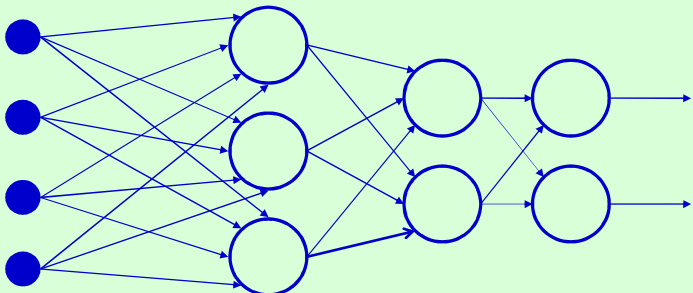
ENTRADA  $x_0$   $w_0$   $y$  SAÍDA  
 $x_{n-1}$   $w_{n-1}$

© Prof. Emilio Del Moral Hernandez

107

## Foco deste Curso: 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

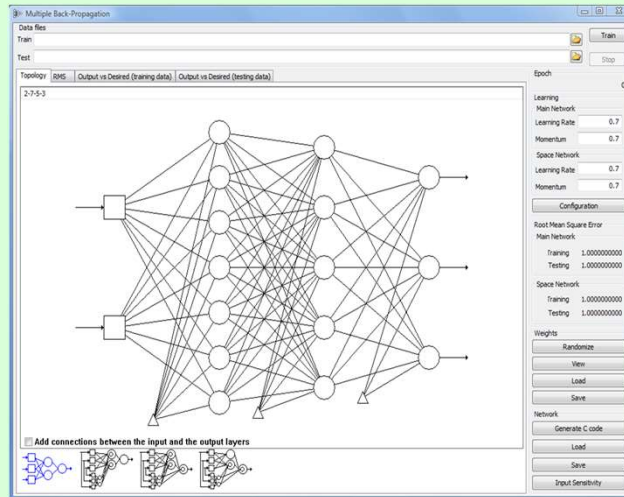


© Prof. Emilio Del Moral Hernandez

109

## Exemplo de tela do ambiente MBP definindo uma Rede Neural do tipo MLP – Topology “2-7-5-3”

110



© Prof. Emilio Del Moral Hernandez

110