

**Prof. Emilio Del Moral Hernandez**  
**Escola Politécnica da Universidade de São Paulo**  
**Departamento de Eng. De Sistemas Eletrônicos**



***emilio\_del\_moral@ieee.org***  
***www.lsi.usp.br/~emilio***

1

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

1

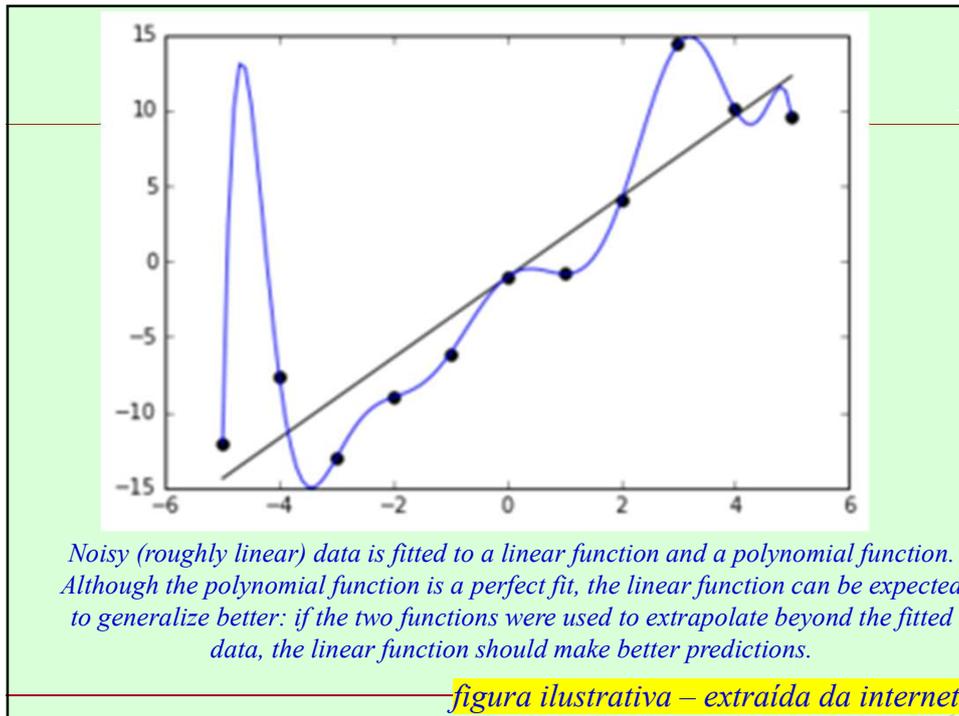
***Um tema importante em M.L.:***

***Sobreapredizado / Sobreajuste***

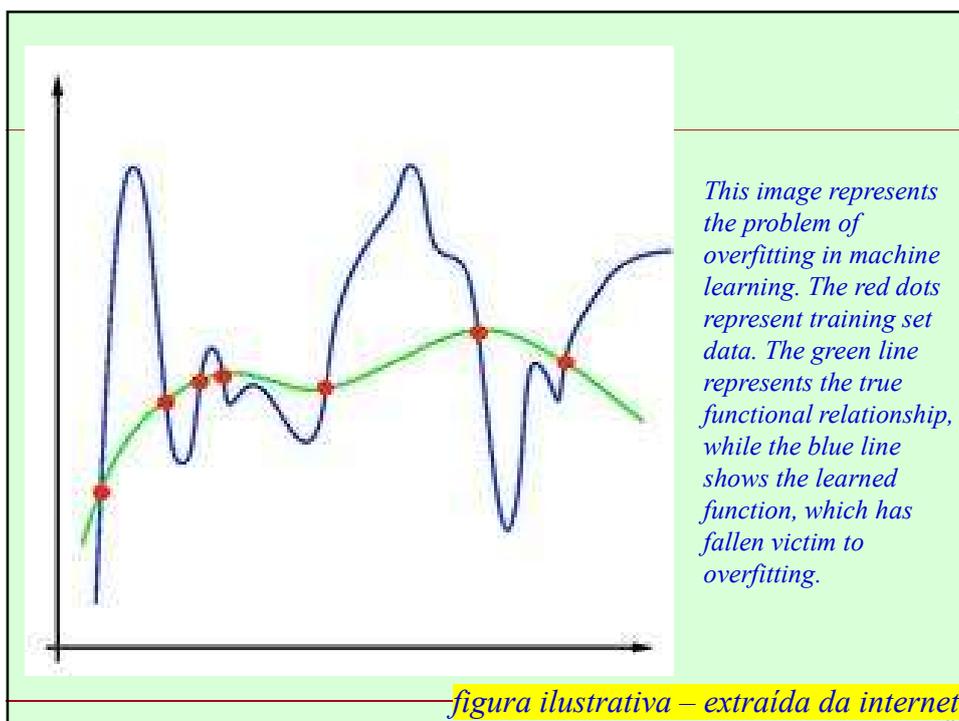
***Conceito, entendimento da sua  
origem e formas de limitá-lo***

© Prof. Emilio Del Moral – EPUSP

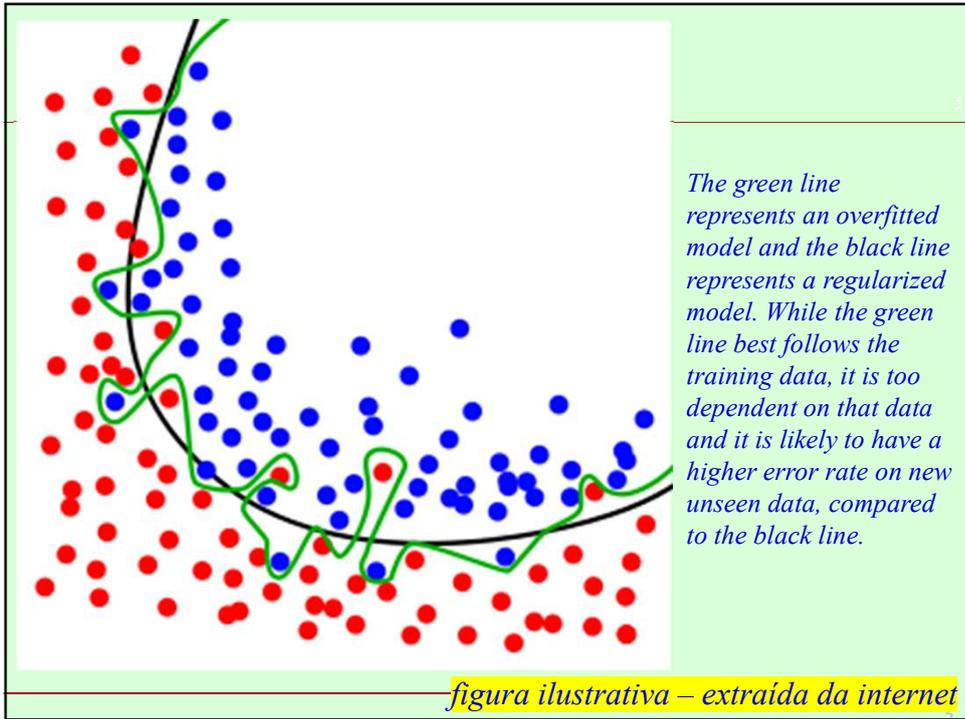
2



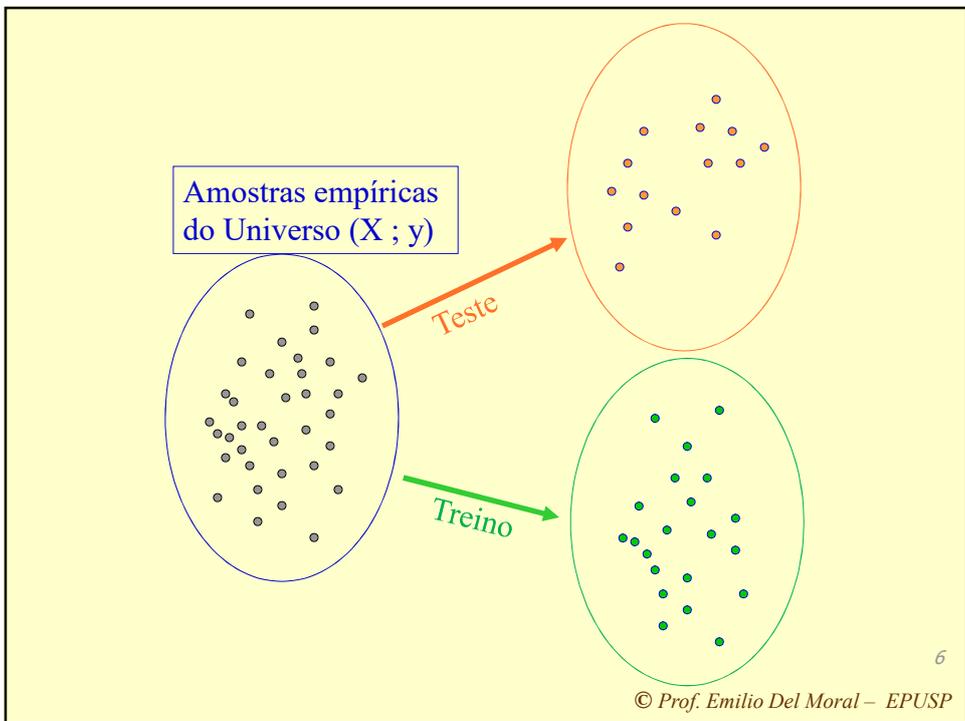
3



4

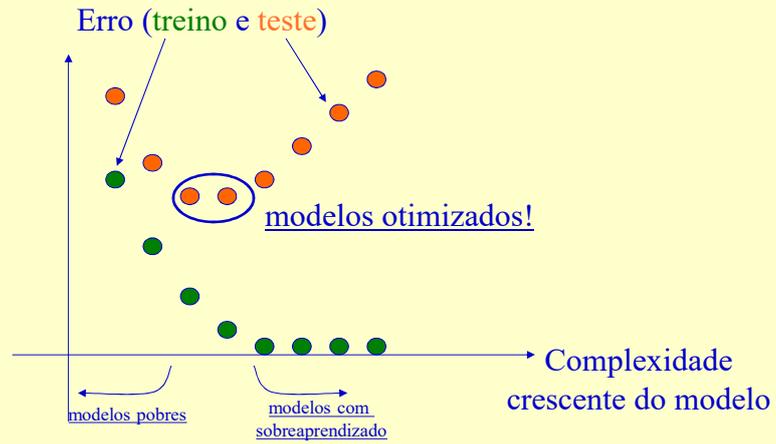


5



6

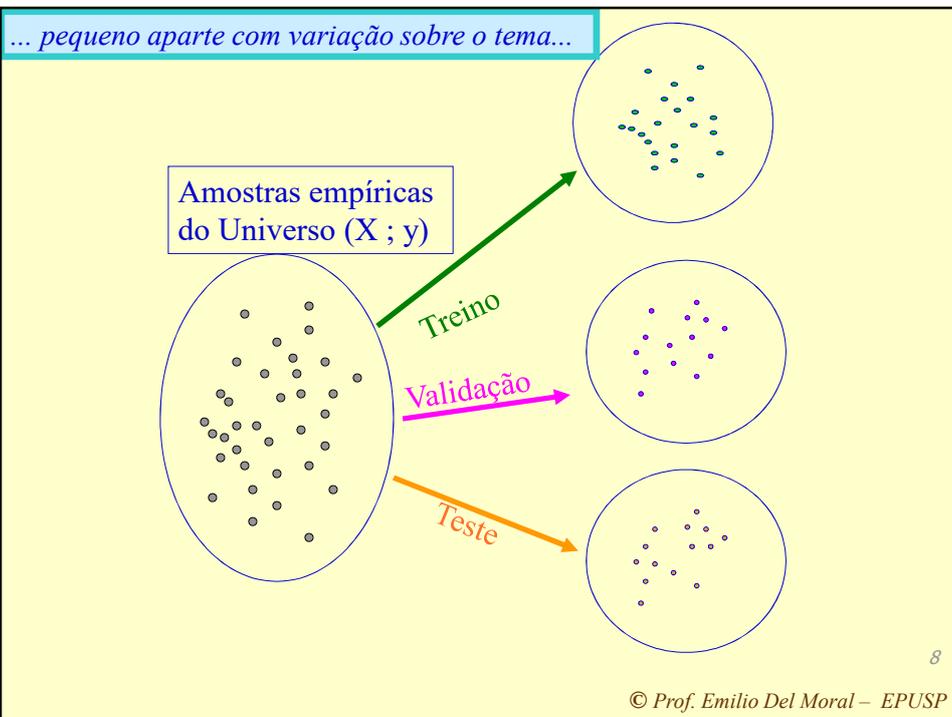
## Sobreaprendizado em “sumário executivo”



7

© Prof. Emilio Del Moral – EPUSP

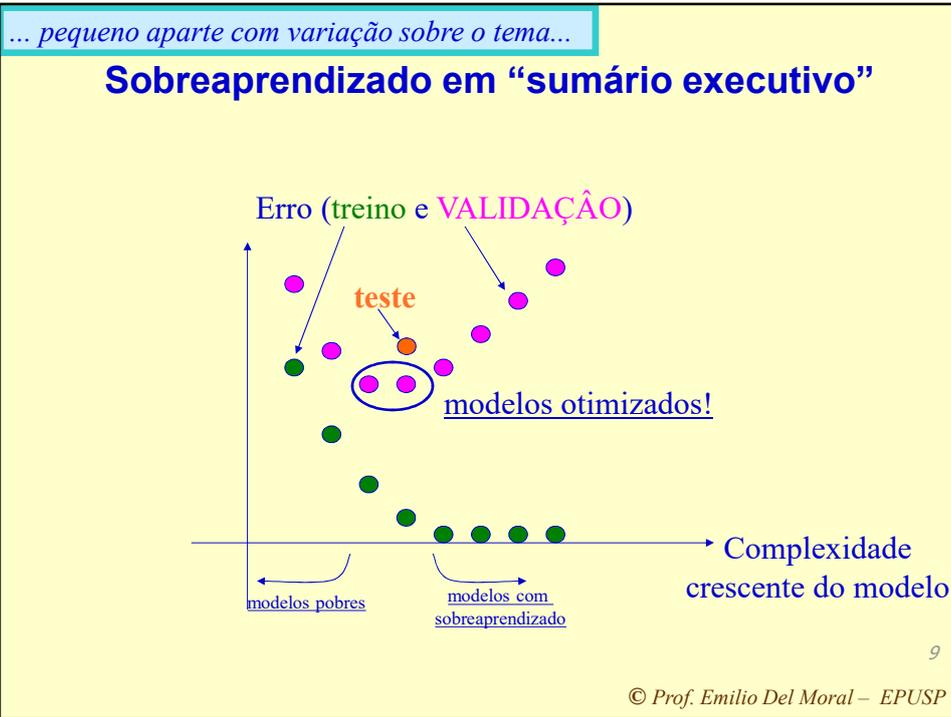
7



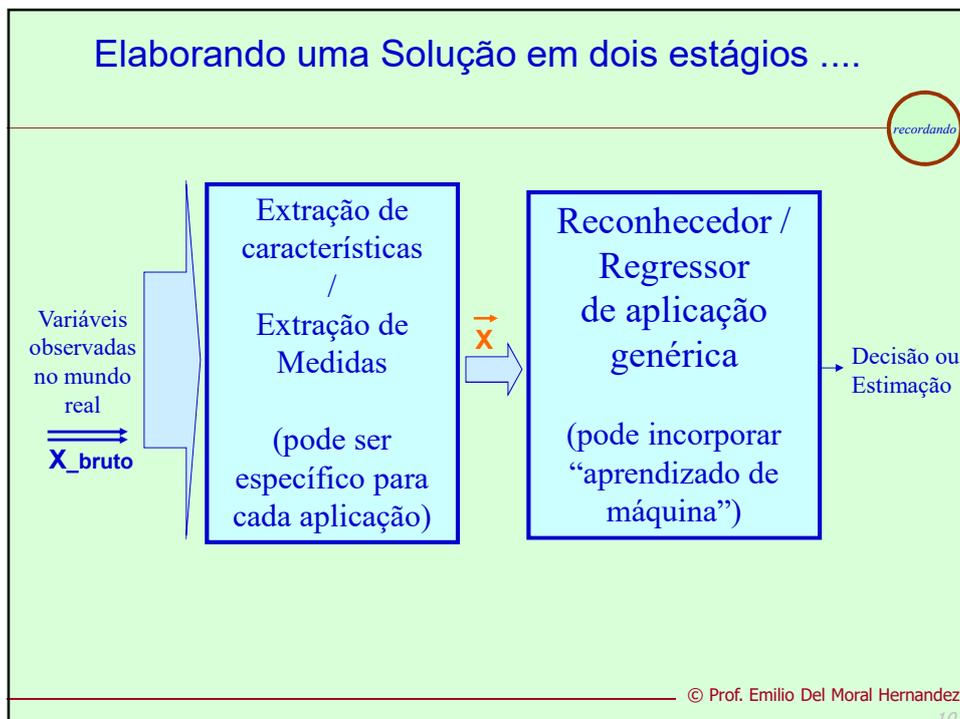
8

© Prof. Emilio Del Moral – EPUSP

8



9



10

## Ligando o sobreaprendizado com dimensão dos objetos de entrada de alta dimensão ...

*- RNAs em problemas de aprendizado de máquina complexos e operando em dados de altíssima dimensão*

- Imagens  $1k \times 1k \times 3 = 3M$  (dimensão do dado de entrada)
- Informação sonora ... também de alta dimensão (dezenas de milhares de amostras temporais em poucos segundos de fala, por exemplo)
- Sinais cerebrais ... Idem (sinal temporal x espaço – vários sensores e centros de atividade neural)

© Prof. Emilio Del Moral Hernandez

11

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

Multiple Back-Propagation Version 2.2.5

Data files:

Train: [Train]

Test: [Stop]

Topology: RMS Output vs Desired (training data) Output vs Desired (testing data)

20-10-5-1

Scale Inputs Epoch 0

Learning

Main Network

Learning Rate 0.7

Momentum 0.7

Space Network

Learning Rate 0.7

Momentum 0.7

Configuration

Network

Generate C code

Load

Save

Input Sensitivity

Weights

Randomize

View

Load

Save

Root Mean Square Error

Main Network

Training 1.000000000

Testing 1.000000000

Space Network

Training 1.000000000

Testing 1.000000000

08:53 sexta-feira 18/05/2018

© Prof. Emilio Del Moral Hernandez

12

*Exemplos de RNAs em problemas de aprendizado de máquina complexos e operando em dados com alta dimensão (trabalhos de orientados no ICONE)*

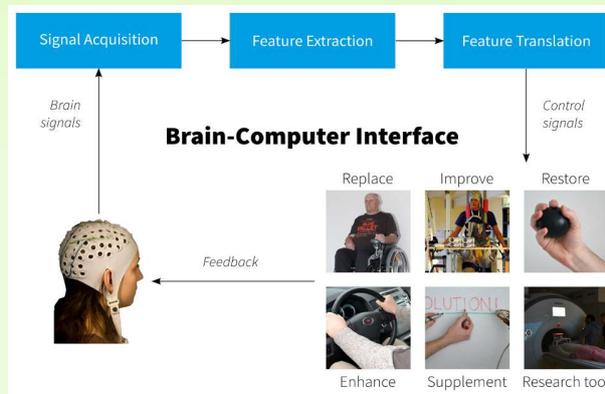
13

**Objetivo:** A pesquisa da utilização de um hardware reconfigurável – FPGA – na tarefa de extração e classificação de características de sinais eletroencefalográficos em Interfaces Cérebro Computador



**Identificação:** Eduardo Mello Nottolini. Mestrando na área de sistemas eletrônicos

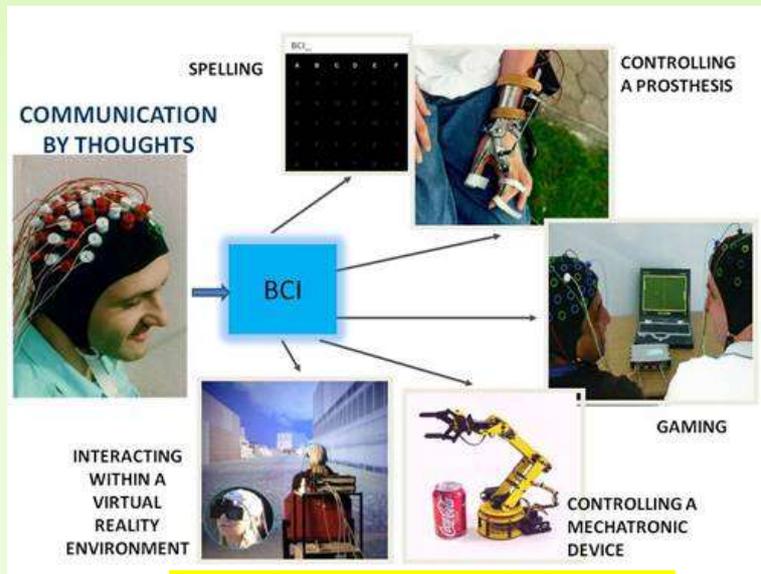
**Pesquisa:** Pesquisa: Interfaces Cérebro Computador – utilização de FPGA na extração e classificação de sinais de eletroencefalografia



*figura ilustrativa – extraída da internet*

14

## Brain Computer Interfaces ...

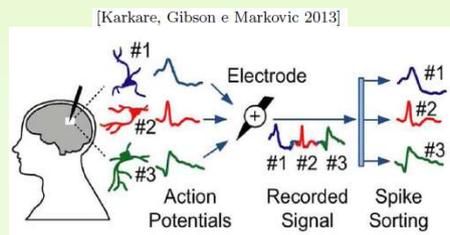


*figura ilustrativa – extraída da internet*

15

## Neural Signal Processing in Analog CMOS IC Neural Spikes Detection

Júlio Cesar Saldaña Pumarica



16





## Classificação automática de generos musicais

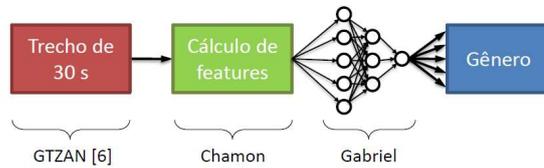
21

### 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*

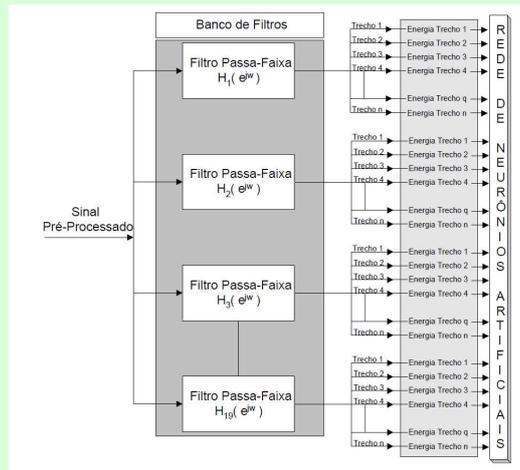
© Prof. Emilio Del Moral Hernandez

21

21

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

22



© Prof. Emilio Del Moral Hernandez

22

22

23

**Alguns destaques para PSI3472-Sinais de Tempo  
Vindos da Tese de Liselene Borges -  
Extração de parâmetros característicos para  
detecção acústica de vazamento de água.  
(URL para baixar no e-disciplinas)**

© Prof. Emilio Del Moral Hernandez

23

24

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

© Prof. Emilio Del Moral Hernandez

24

25

defesa08Abr2011\_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011\_L... x

Fazer logon

Compartilhar

## Extração de parâmetros característicos para detecção acústica de vazamento de água

Aluna: Liselene de Abreu Borges  
Orientador: Miguel Arjona Ramirez

© Prof. Emilio Del Moral Hernandez

25

25

26

defesa08Abr2011\_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011\_L... x

Fazer logon

Compartilhar

## Sumário

- \* Motivação, Objetivos e Contribuições
- \* Detecção Acústica de Vazamento
- \* Sistemas de Detecção e Métodos de Avaliação dos Parâmetros
- \* Extração de Parâmetros Característicos
- \* Desenvolvimento da Pesquisa
- \* Conclusões e Propostas Futuras

© Prof. Emilio Del Moral Hernandez

26

26

27

defesa08Abr2011\_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011\_L... x

Fazer login

5 / 35 63.6%

Compartilhar

## Os Tipos de Vazamentos

\* Tipos de vazamentos: (a) Inerentes, (b) Não Visíveis e (c) Visíveis;

© Prof. Emilio Del Moral Hernandez

27

27

28

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

## O procedimento de detecção do Vazamento

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

© Prof. Emilio Del Moral Hernandez

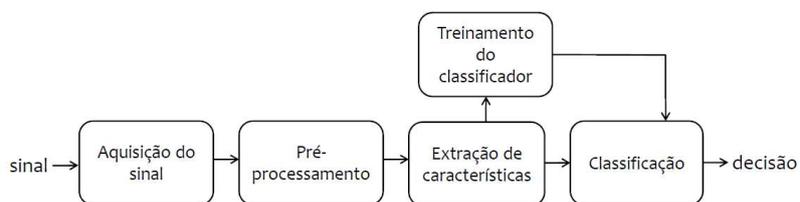
28

28

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

29

### Sistema de Detecção de Vazamento



© Prof. Emilio Del Moral Hernandez

29

29

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

30

### Extração no domínio temporal

- \* Energia de curto Prazo

$$E_p = \sum_{m=0}^{p-1} |x(n)w(n-m)|^2$$

- \* Taxa de Cruzamento por zero

$$Z_p = \sum_{m=0}^{p-1} |\text{sgn}[x(m)] - \text{sgn}[x(m-1)]| w(n-m)$$

© Prof. Emilio Del Moral Hernandez

30

30

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

defesa08Abr2011\_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

defesa08Abr2011\_L... x 63,6%

Início Ferramentas 23 / 35 Fazer logon

### Extração no domínio espectral

- \* Centróide Espectral (Ce)
- \* Largura de Espectro (Le)
- \* Fluxo Espectral
- \* Ponto de Roll-off (Pro)
- \* Taxa de Espalhamento

$$Fe = \sum_{k=1}^M [X(k) - X(m-1)]^2$$

$$Tc = \sqrt{\frac{1}{K-1} \sum_{k=1}^K [X(k) - \mu_x]^2}$$

© Prof. Emilio Del Moral Hernandez

31

defesa08Abr2011\_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

defesa08Abr2011\_L... x 63,6%

Início Ferramentas 30 / 35 Fazer logon

### Estatística\_M geral

Parâmetro característico	original	Pré-ênfase 1	Pré-ênfase 2
Energia de curto prazo	0.21186	0.10927	0.33054
Taxa de cruzamento por zero	0.21189	0.19588	0.32757
Centróide espectral	0.60133	0.80953	0.75399
Largura de espectro	0.83349	0.68455	0.33055
Fluxo espectral	0.89947	0.72221	0.46769
Ponto de roll-off	0.25491	0.06911	0.65232
Taxa de espalhamento	0.39558	0.17637	0.35039
Modelo AR ordem=10			
Dist. máx. Itakura-AR	0.09678	0.24098	0.34357
Dist. méd. Itakura-AR	0.09669	0.23716	0.35607
Dist. máx. espectral-AR	0.02684	0.4213	0.39587
Dist. méd. espectral-AR	0.11491	0.43526	0.48266
Modelo PLP ordem=2			
Dist. máx. Itakura-PLP	0.24388	0.10365	0.13251
Dist. méd. Itakura-PLP	0.1826	0.15835	0.083096
Dist. máx. espectral-PLP	0.23262	0.197	0.20062
Dist. méd. espectral-PLP	0.21759	0.21076	0.072005

© Prof. Emilio Del Moral Hernandez

32

defesa08Abr2011\_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

defesa08Abr2011\_L... x

Fazer login

31 / 35 63.6%

Compartilhar

## Resultado da classificação Individual

Parâmetro Característico	Sinal Original (t)	Sinal pré-ênfase v (t)	Sinal pré-ênfase z (t)
Energia de curto prazo	64.8936	64.8936	64.8936
Taxa de cruzamento por zero	64.8936	85.1064	87.2334
Centróide espectral	77.6596	89.3617	86.1702
Largura de espectro	89.9917	87.2334	91.4894
Fluxo espectral	88.2979	87.2334	78.7334
Ponto de roll-off	86.8511	86.1702	87.2334
Taxa de espalhamento	68.0851	64.8936	69.1489
Dist. máx. Itakura AR (ordem=10)	71.3404	64.8936	82.9782
Dist. méd. Itakura AR (ordem=10)	71.2766	64.8936	84.0416
Dist. máx. espectral AR (ordem=10)	64.8936	71.2766	69.1489
Dist. méd. espectral AR (ordem=10)	61.7021	64.8936	81.9149
Dist. máx. Itakura PLP (ordem=2)	64.8936	71.2766	68.0851
Dist. méd. Itakura PLP (ordem=2)	64.8936	67.0213	65.9574
Dist. máx. espectral PLP (ordem=2)	63.8298	68.0851	67.0213
Dist. méd. espectral PLP (ordem=2)	63.8298	65.9574	69.1489

08:05 segunda-feira 15/10/2018

© Prof. Emilio Del Moral Hernandez

33

defesa08Abr2011\_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

defesa08Abr2011\_L... x

Fazer login

32 / 35 63.6%

Compartilhar

## Resultado do classificação em grupo

Parâmetros característicos(t)	Acuracidade(t)	Sensibilidade(t)	Especificidade(t)
1,2,3,4,2	95.7447	93.9394	96.7213
1,2,3,4,6,7	95.7447	93.9394	96.7213
1,2,3,4,6	95.7447	93.9394	96.7213
1,2,3,4,5	94.6809	93.9394	95.0821
1,2,3,13	95.7447	93.9394	96.7213
1,2,3,12	95.7447	93.9394	96.7213
1,2,3,11	95.7447	93.9394	96.7213
1,2,3,10	95.7447	93.9394	96.7213
1,2,3,9	95.7447	93.9394	96.7213
1,2,3,8	95.7447	93.9394	96.7213
1,2,3,4,13	96.8085	93.9394	98.3607
1,2,3,4,12,13	95.7447	96.9991	98.3607
1,2,3,4,12	96.8085	93.9394	98.3607
1,2,3,4,11	96.8085	93.9394	98.3607
1,2,3,4,10,11	94.6809	87.8788	93.3607
1,2,3,4,10	96.8085	93.9394	98.3607
1,2,3,4,8,9	95.7447	93.9394	96.7213

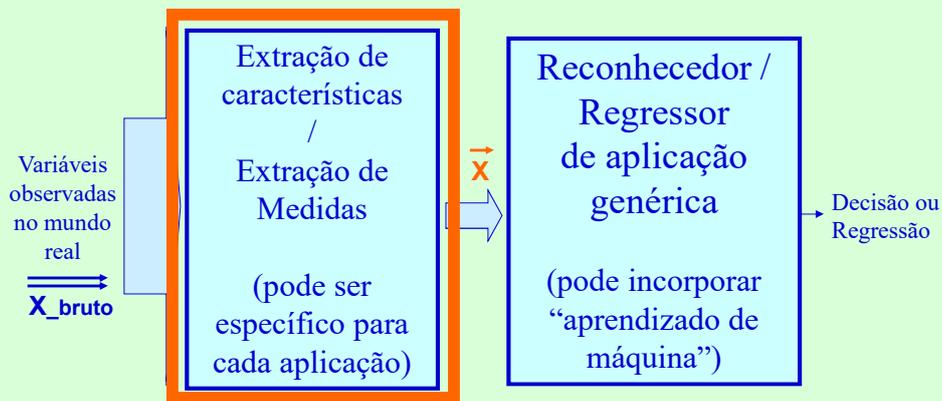
- 1-Centróide espectral
- 2-Largura de espectro
- 3-Fluxo espectral
- 4-Ponto de roll-off
- 5-Taxa de espalhamento
- 6-Dist. máx. Itakura AR
- 7-Dist. méd. Itakura AR
- 8-Dist. máx. espectral AR
- 9-Dist. méd. espectral AR
- 10-Dist. máx. Itakura PLP
- 11-Dist. méd. Itakura PLP
- 12-Dist. máx. espectral PLP
- 13-Dist. méd. espectral PLP

08:07 segunda-feira 15/10/2018

© Prof. Emilio Del Moral Hernandez

34

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

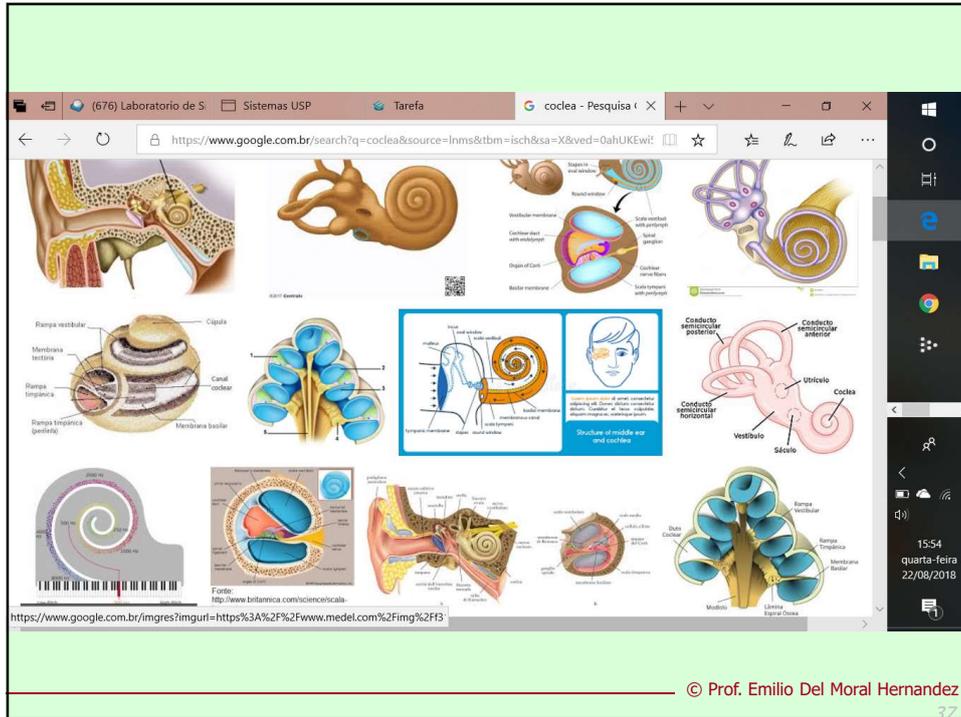


© Prof. Emilio Del Moral Hernandez

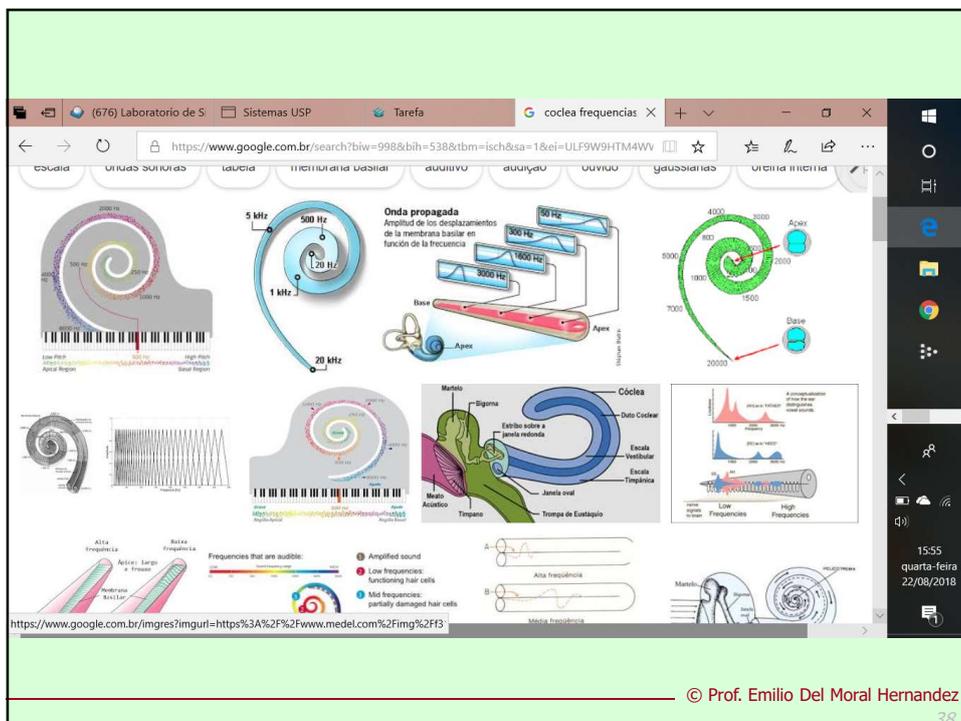
35



36



37



38

676 Laboratorio de S Sistemas USP Tarefa coclea frequencias

https://www.google.com.br/search?biw=998&bih=538&tbm=isch&sa=1&ei=ULF9W9HTM4Wv

© Prof. Emilio Del Moral Hernandez

39

676 Laboratorio de S Sistemas USP Tarefa mel frequency cep

https://www.google.com.br/search?biw=998&bih=538&tbm=isch&sa=1&ei=ULF9W9HTM4Wv

block diagram filter coefficients mfccs mfcc speech recognition coefficients mfcc matlab filterbank

© Prof. Emilio Del Moral Hernandez

40

mel frequency cep

https://www.google.com.br/search?biw=998&bih=538&tbn=isch&sa=1&ej=ULF9W9HTM4Ww

Time Domain Waveform

Spectrogram

MFCC Spectrogram

498 x 276 - music.ece.drexel.edu

Confusions Speech → Frame Blocking → Windowing → FFT → Mel-frequency Wrapping → Cepstrum → MFCC Spectrogram

MFCC

- Natural perception of speech & linear with 1000 and logarithmic from there
- Optimum & Plackett Transform (logarithmic & Plackett Transform) Speech
- Optimum coefficients are efficient than MF and GC version of their filter extraction technique

https://www.google.com.br/imgres?imgurl=http%3A%2F%2Fmusic.ece.drexel.edu%2Ffiles%2

© Prof. Emilio Del Moral Hernandez

41

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

V1-7\_Rec\_VOZ\_2004.EPUSP\_IC\_e\_paper.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas V1-7\_Rec\_VOZ\_200... x Fazer login

7 / 27 124%

Sinal apos retirada da componente DC

Amplitude

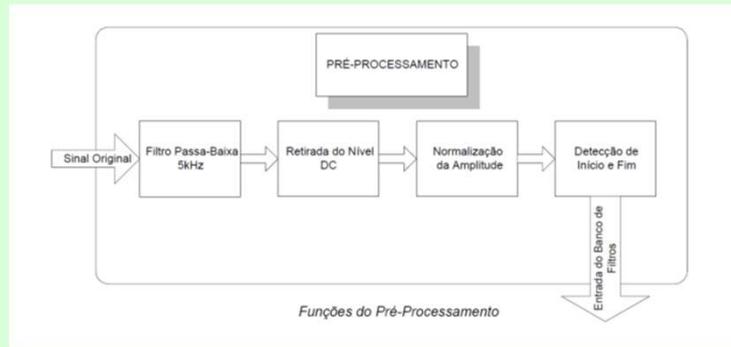
Numero de amostras

© Prof. Emilio Del Moral Hernandez

42

## Exemplo de pré-processamentos num reconhecedor de comandos de voz - TCC de Daniel e Gabriel

43



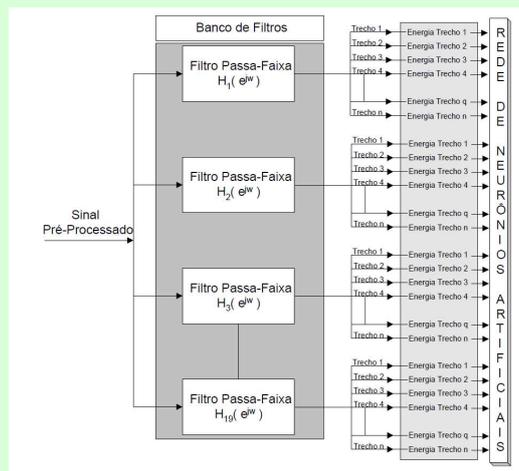
© Prof. Emilio Del Moral Hernandez

43

43

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

44



© Prof. Emilio Del Moral Hernandez

44

44

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

45

© Prof. Emilio Del Moral Hernandez

Frequências centrais e bandas de passagem do banco de filtros	
0	
Filtro 1	$f_{c1} = 90 \text{ Hz}$
	100
Filtro 2	$f_{c2} = 150 \text{ Hz}$
	200
Filtro 3	$f_{c3} = 250 \text{ Hz}$
	300
Filtro 4	$f_{c4} = 350 \text{ Hz}$
	400
Filtro 5	$f_{c5} = 450 \text{ Hz}$
	510
Filtro 6	$f_{c6} = 550 \text{ Hz}$
	630
Filtro 7	$f_{c7} = 700 \text{ Hz}$
	770
Filtro 8	$f_{c8} = 840 \text{ Hz}$
	920
Filtro 9	$f_{c9} = 1000 \text{ Hz}$
	1080
Filtro 10	$f_{c10} = 1170 \text{ Hz}$
	1270
Filtro 11	$f_{c11} = 1370 \text{ Hz}$
	1480
Filtro 12	$f_{c12} = 1600 \text{ Hz}$
	1720
Filtro 13	$f_{c13} = 1850 \text{ Hz}$
	2000
Filtro 14	$f_{c14} = 2150 \text{ Hz}$
	2320
Filtro 15	$f_{c15} = 2400 \text{ Hz}$
	2600
Filtro 16	$f_{c16} = 2600 \text{ Hz}$
	2800
Filtro 17	$f_{c17} = 3400 \text{ Hz}$
	3700
Filtro 18	$f_{c18} = 4000 \text{ Hz}$
	4400
Filtro 19	$f_{c19} = 4800 \text{ Hz}$
	5300

45

## Pinçando alguns projetos (desenvolvidos no PSI em disciplinas de 5º ano) envolvendo reconhecimento de padrões / regressão multivariada que se relacionam com sinais de tempo sonoros ou biomédicos

46

Exemplos 2672 em Sinais Sonoros ou Biomédicos

Extrair para

Este Computador > Downloads > Exemplos 2672 em Sinais Sonoros ou Biomédicos (1) > Exemplos 2672

Nome
2011-PSI2672 - Aprs - gr_I - Generos Musicais
2011-PSI2672 - Aprs - gr_V - Sinais cerebrais e diagnostico
2013-PSI2672 - Aprs - André, Pedro Parra, Rafael - Sinais EEG e Consumo residencial
2013-PSI2672 - Aprs - Viviane, Victor Victor preliminar - Idiomas falados
2015-PSI2672 - Aprs - Allan Mateus e Arthur - Acoes Petrobras Intrumentos musicais Ventilacao inteligente
2015-PSI2672 - Aprs- Pedro H Henrique Carlos - Acordes musicais Caracteres manuscritos Desempenho de CPUs
2016-PSI2672 -GR I - SamAntonioFelipe - Fibrilação Arterial e Cancelador de Ruído
2016-PSI2672 -GR IV - Yeny e Caio - BCI de Intencao de Movimento e Estimador de Acoes
Unselected - Biblio Projetos PSI2672 ate 2016 - Atalho

46

## PSI2672 – Classificação de gêneros musicais

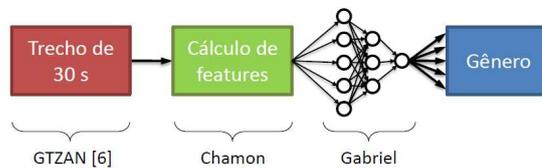
47

### 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

47

47

## PSI2672 – Classificação de gêneros musicais

48

The screenshot shows a presentation slide titled 'FEATURES' with three sections: MFCCs, RMS, and Spectral Centroid. Each section includes a brief description and a mathematical formula.

**20 MFCCs [2]**  
Muito usado em reconhecimento de voz. É uma medida de variações no tom.  
$$MFCC = |\mathcal{F}\{\log[mel(|S(f)|^2)]\}|^2$$

**RMS [2]**  
Usado como medida da energia média da música.  
$$RMS = \sqrt{\frac{1}{T} \int_{-T/2}^{T/2} s^2(t) dt}$$

**Spectral Centroid [2]**  
Uma espécie de centro de massa do espectro, determina uma relação entre altas e baixas frequências.  
$$C = \frac{\sum_{f=0}^M f \cdot |S(f)|^2}{\sum_{f=0}^M |S(f)|^2}$$

© Prof. Emilio Del Moral Hernandez

48

48

## PSI2672 – Classificação de gêneros musicais

49

2011-PSI2672 - Aprs - gr\_1 - Generos Musicais.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2011-PSI2672 - Apr... x Fazer login

6 / 32 72,1%

Introdução Features RNA Resultados

### FEATURES

Spectral bandwidth [2]  
Mede a variação do espectro em torno da centróide espectral.

$$B^2 = \frac{\sum_{f=0}^M (f - C)^2 |S(f)|^2}{\sum_{f=0}^M |S(f)|^2}$$

Zero-crossing [2]  
Representa uma medida do "ruído" de fundo em uma música. Trata-se simplesmente do número de cruzamentos por zero no domínio do tempo.

Band energy ratio [2]  
Razão da energia no primeiro quarto do espectro com relação ao espectro todo.

$$BER = \frac{\sum_{f=0}^{M/4} |S(f)|^2}{\sum_{f=0}^M |S(f)|^2}$$

© Prof. Emilio Del Moral Hernandez

49

49

## PSI2672 – Classificação de gêneros musicais

50

2011-PSI2672 - Aprs - gr\_1 - Generos Musicais.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2011-PSI2672 - Apr... x Fazer login

7 / 32 72,1%

Introdução Features RNA Resultados

### FEATURES

Octave spectral contrast [3]  
Medida da diferença entre espectros em bandas de oitava.

$$Valley_k = \log \left( \frac{1}{\alpha N} \sum_{f=0}^{\alpha N} |S(f)| \right), \quad Peak_k = \log \left( \frac{1}{\alpha N} \sum_{f=0}^{\alpha N} |S(N - f + 1)| \right)$$
$$SC_k = Peak_k - Valley_k$$

Loudness [4]  
Modelo psicoacústico de sensação sonora ("intensidade" percebida).

Sharpness [4]  
Medida de conteúdo espectral de altas frequências. Avaliação psicoacústica do quão "afiado", "agudo" um som é.

© Prof. Emilio Del Moral Hernandez

50

50

## PSI2672 - Gabriel, Maria Luisa e Ricardo - EEG

51

2011-PSI2672 - Aprs - gr\_V - Sinais cerebrais e diagnostico.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2011-PSI2672 - Apr... x Fazer logon

### O EEG

**Eletroencefalograma**

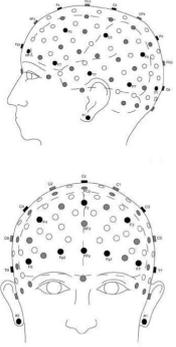
Potenciais elétricos ( $\mu\text{V}$ )

**64 sensores**

↓

Taxa de amostragem 256Hz/canal

**16384 amostras/s**



Fonte: [http://bindcenter.eu/?page\\_id=12](http://bindcenter.eu/?page_id=12) Reconhecedor de Alcoolismo | 7

© Prof. Emilio Del Moral Hernandez

51

## PSI2672 - Gabriel, Maria Luisa e Ricardo - EEG

52

2011-PSI2672 - Aprs - gr\_V - Sinais cerebrais e diagnostico.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2011-PSI2672 - Apr... x Fazer logon

### Pré-processamento

Eliminação de ruídos oculares e musculares

↓

Obtenção da FFT dos sinais temporais

↓

Obtenção dos centróides

↓

Normalização da matriz centróides

Reconhecedor de Alcoolismo | 10

© Prof. Emilio Del Moral Hernandez

52

## PSI2672 – André, Pedro, Rafael - EEG

53

2013-PSI2672 - Aprs - André, Pedro Parra, Rafael - Sinais EEG e Consumo residencial.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2013-PSI2672 - Apr... x Fazer login

9 / 28 72,1%

Introdução Features RNA Resultados 9/28

### Features

Média do desvio-padrão das amplitudes

$$m_j^x = \frac{1}{N^x} \sum_{i=1}^{N^x} |x_i - \bar{x}| \quad (1)$$

Flutuação do desvio-padrão das amplitudes

$$F^x = \frac{1}{n} \sum_{j=1}^n |m_j^x - \bar{m}^x| \quad (2)$$

Média do desvio-padrão do centro de frequência

$$m_j^w = \frac{2}{N^w} \sum_{i=1}^{N^w/2} \frac{\omega_i S(\omega_i)}{S(\omega_i)} \quad (3)$$

Flutuação do desvio-padrão das amplitudes

$$F^w = \frac{1}{n} \sum_{j=1}^n |m_j^w - \bar{m}^w| \quad (4)$$

© Prof. Emilio Del Moral Hernandez

53

53

## PSI2672 – Victor, Victor, Viviane – Idiomas falados

54

2013-PSI2672 - Aprs - Viviane, Victor Victor preliminar - Idiomas falados.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2013-PSI2672 - Apr... x Fazer login

5 / 22 72,1%

### EXTRAÇÃO DE CARACTERÍSTICAS

- Primeiro conjunto de características:
  - RMS[1]: usado como energia média do sinal

$$RMS = \sqrt{\frac{1}{T} \int_{-T/2}^{T/2} s^2(t) dt}$$

- Spectral Centroid[1]: análogo ao centro de massa para o espectro

$$C = \frac{\sum_{f=0}^M f \cdot |S(f)|^2}{\sum_{f=0}^M |S(f)|^2}$$

© Prof. Emilio Del Moral Hernandez

54

54

2015-PSI2672 - Aprs - Allan Mateus e Arthur - Acoes Petrobras Intrumentos musicais Ventilacao inteligente.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2013-PSI2672 - Apr... 2015-PSI2672 - Apr... x Fazer login

### O que é o Cepstrum?

- Eu não sei!
- Definição formal:
 
$$\left| F^{-1} \{ \log_{10} ( | F \{ f(t) \} |^2 ) \} \right|^2$$
- “O módulo ao quadrado da transformada inversa de Fourier calculada sobre logaritmo de base 10 calculada sobre módulo ao quadrado da transformada de Fourier do sinal f(t)!”

27 Escola Politécnica da USP

© Prof. Emilio Del Moral Hernandez

55

2015-PSI2672 - Aprs - Pedro H Henrique Carlos - Acordes musicais Caracteres manuscritos Desempenho de CPUs.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2015-PSI2672 - Apr... x Fazer login

### Reconhecimento de Acordes

1ª iteração: Pré-processamento

#### Downsampling

Fonte: J. de Jesus Guerrero-Turrubiates, S. Gonzalez-Reyna, S. Ledesma-Orozco e J. Avina-Cervantes

© Copyright 2015 - cmori, hogawa, phayashi

PSI2672 - Apresentação final e demonstração de resultados 49/58

© Prof. Emilio Del Moral Hernandez

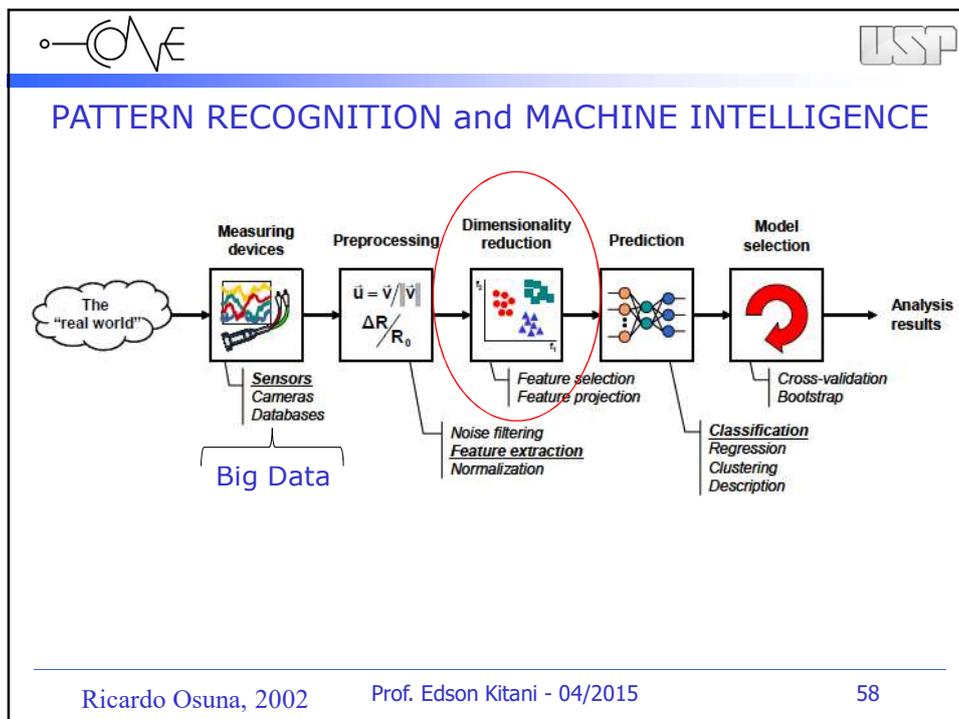
56

*Uma técnica estatística clássica de redução de dimensionalidade do vetor de entradas  $X$  e de extração de características com grande número de aplicações: Principal Component Analysis – PCA – Análise de Componentes Principais*

© Prof. Emilio Del Moral Hernandez

57

57



58



# PCA – Principal Components Analysis

## Teoria e Aplicações

Prof. Dr. Edson C. Kitani

Prof. Dr. Emilio Del Moral Hernandez

59

© Prof. Emilio Del Moral – EPUSP

59



## GRUPO DE INTELIGÊNCIA COMPUTACIONAL, MODELAGEM E NEUROCOMPUTAÇÃO ELETRÔNICA – ICONE-EPUSP

LABORATÓRIO DE SISTEMAS INTEGRADOS –LSI  
DEPARTAMENTO DE ENGENHARIA DE SISTEMAS ELETRÔNICOS – PSI  
ESCOLA POLITÉCNICA DA USP

60

© Prof. Emilio Del Mo

60



Prof. Dr. Edson C. Kitani

<http://buscatextual.cnpq.br/buscatextual/visualizacv.do?id=K4269320J9>

Formação:

- Tecnico em Eletrônica (ETEP – Santo André)
- Tecnólogo em Automação Industrial (Centro Universitário de Santo André)
- Especialista em Mecânica Fina (Universidade São Judas)
- Mestre em Eng. Elétrica (Centro Universitário da FEI)
- Doutor em Ciências (POLI – USP)

Atividade profissional:

- Professor Associado na FATEC- Santo André (Eletrônica Automotiva)
- Chefe do Departamento de Projetos de Máquinas na Mahle Anéis

[ekitani@lsi.usp.br](mailto:ekitani@lsi.usp.br)    [www.lsi.usp.br/~edson](http://www.lsi.usp.br/~edson)

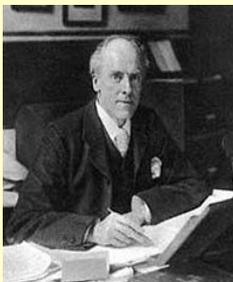
61

© Prof. Emilio Del Moral <sup>61</sup> EPUSP

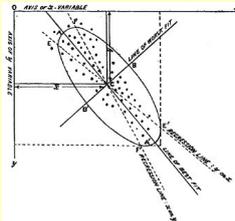
61

## HISTÓRICO DO PCA

Descrito inicialmente por Karl Pearson no artigo, *“On lines and planes of closest fit to systems of points in space”*, *Philosophical Magazine*, 1901.



1857 - 1936



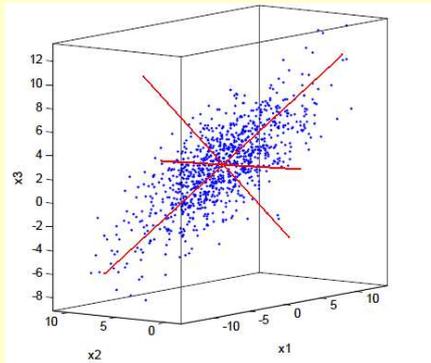
*“In many physical, statistical, and biological investigations it is desirable to represent a system of points in plane, three or higher dimensioned space by the best-fitting straight line or plane” (Pearson, 1901).*

62

Prof. Edson Kitani - 04/2015 © Prof. Emilio Del Moral <sup>62</sup> EPUSP

62

## Para 3 Dimensões



$$\bar{\mathbf{x}} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i$$

$$\Sigma_{\mathbf{x}} = \frac{1}{(N-1)} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T$$

$$\bar{\mathbf{x}} = [0 \quad 5 \quad 2]^T$$

$$\Sigma_{\mathbf{x}} = \begin{bmatrix} 25 & -1 & 7 \\ -1 & 4 & -4 \\ 7 & -4 & 10 \end{bmatrix}$$

63

Extraído de Osuna 2002

Prof. Edson Kitani - 04/2015 © Prof. Emilio Del Moral EPUSP

63

## Exemplo Numérico com Matlab

`x = [1, 2; 3, 3; 3, 5; 5, 4; 5, 6; 6, 5; 8, 7; 9, 8]`

`figure(1)`

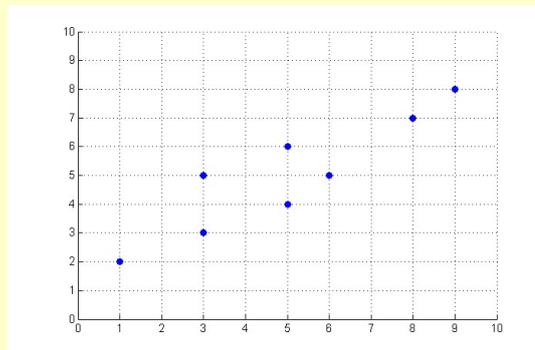
`scatter(x(:,1),x(:,2))`

Media = `mean(x)`

$$\bar{\mathbf{x}} = [5 \quad 5]^T$$

Sigma = `cov(x,1)` Nota

$$\Sigma_{\mathbf{x}} = \begin{bmatrix} 6,25 & 4,25 \\ 4,25 & 3,5 \end{bmatrix}$$



A normalização é realizado para N.

64

Prof. Edson Kitani - 04/2015 © Prof. Emilio Del Moral EPUSP

64



## Autovalores ( $\lambda$ ) e Autovetores ( $v$ )

Associado a cada matriz quadrada  $A = ((a_{ij}))$  de ordem  $n$ , temos uma função

$$f(\lambda) = |A - \lambda I| = \begin{vmatrix} a_{11} - \lambda & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} - \lambda & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{nn} - \lambda \end{vmatrix}$$

chamada de Função Característica da matriz  $A$ . É a função

$$f(\lambda) = |A - \lambda I| = 0,$$

que pode ser expressa na forma polinomial

$$c_0 \lambda^n + c_1 \lambda^{n-1} + \dots + c_{n-1} \lambda + c_n = 0$$

é chamada de Equação Característica da matriz  $A$ .

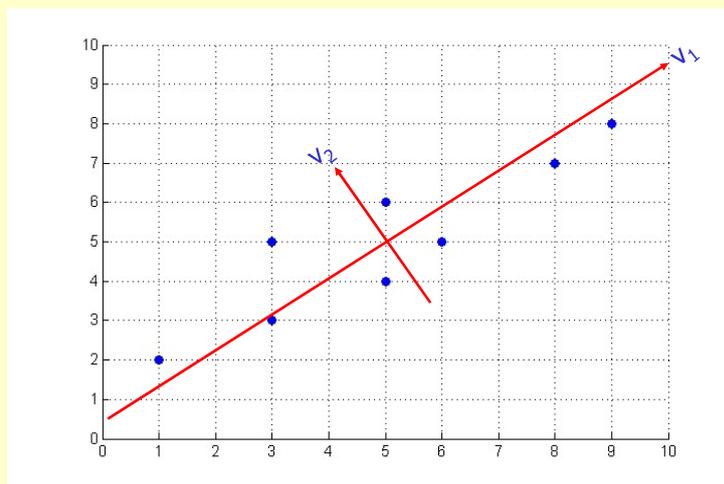
65

Prof. Edson Kitani - 04/2015 © Prof. Emilio Del Moral EPUSP

65



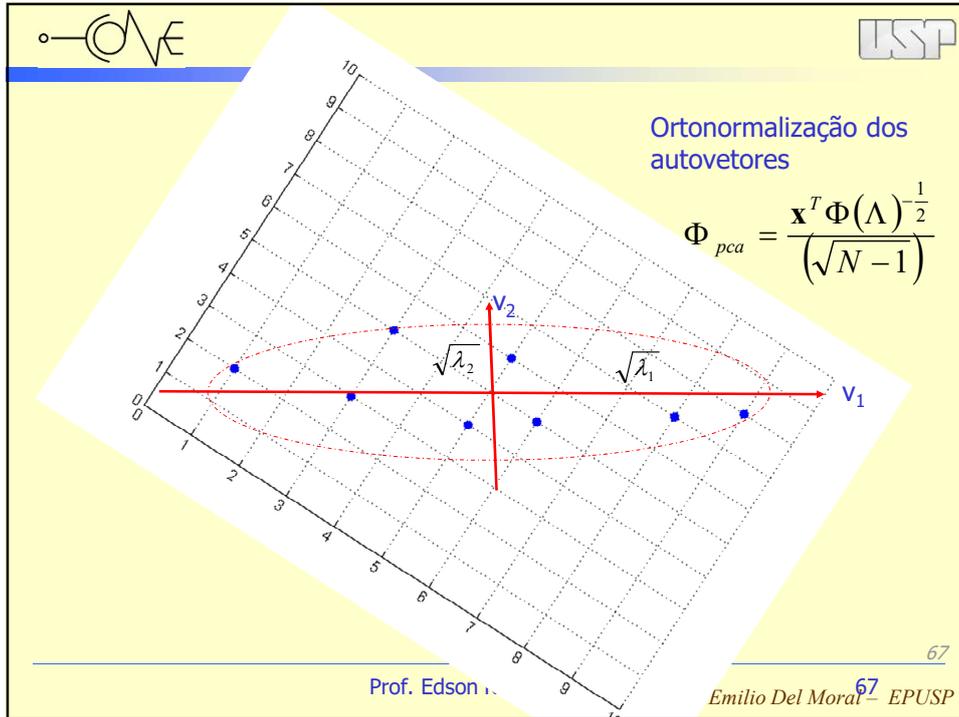
## Exemplo Numérico



66

Prof. Edson Kitani - 04/2015 © Prof. Emilio Del Moral EPUSP

66



67

Mais detalhes matemáticos e algumas referências em PCA podem ser encontradas no seguinte material gerado pelo Dr. Edson C. Kitani (material mais amplo que os slides que foram aqui destacados):

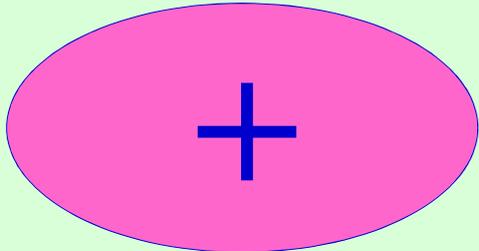
[http://www.lsi.usp.br/icones/psi2672/2011/monitor/PCA\\_Junho\\_2011\\_ECK\\_EdsonKitani\\_PSI2672.pdf](http://www.lsi.usp.br/icones/psi2672/2011/monitor/PCA_Junho_2011_ECK_EdsonKitani_PSI2672.pdf)

68

© Prof. Emilio Del Moral – EPUSP

68

69



- Algumas respostas sendo dadas com ferramentas de Deep Learning

© Prof. Emilio Del Moral Hernandez

69

69

*Uma técnica **neural** para a redução de dimensionalidade do vetor de entradas  $X$  e de extração de características sendo usada no contexto de Deep Learning: Autoencoders (auto-codificadores) e Stacked Autoencoders (vários auto-codificadores encadeados) –*

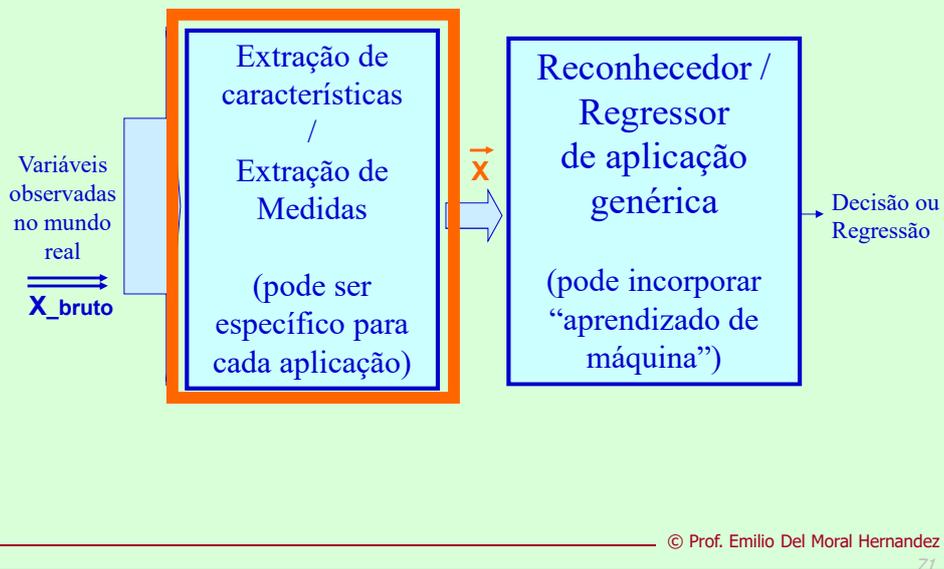
© Prof. Emilio Del Moral Hernandez

70

70

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

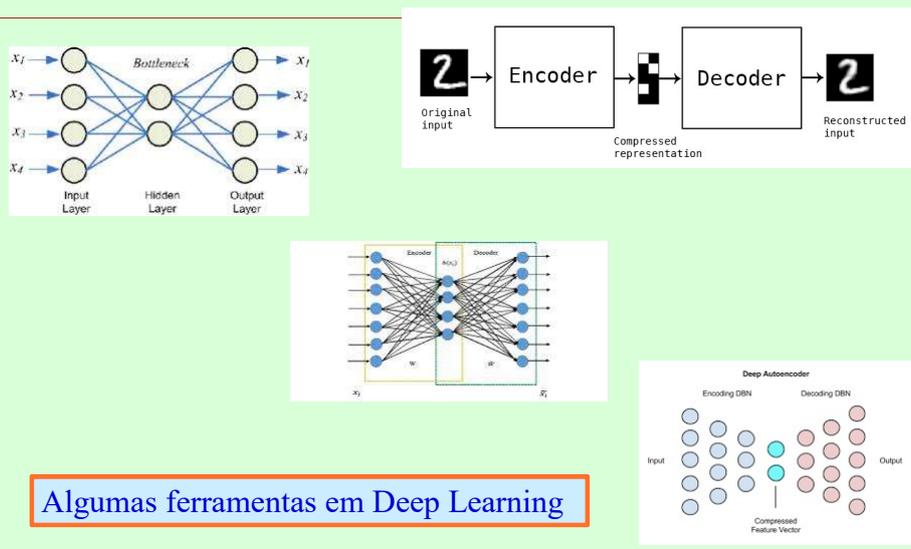
71



71

### Autoencoders e Stacked Auto-encoders (imagens da internet)

72



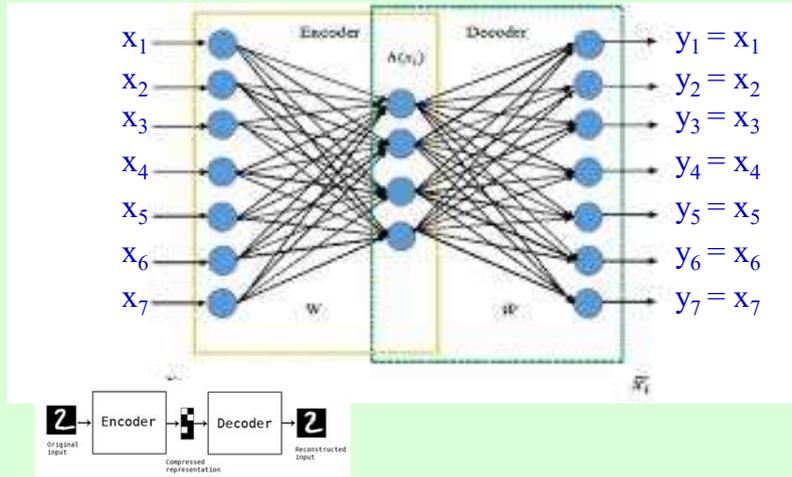
Algumas ferramentas em Deep Learning

© Prof. Emilio Del Moral Hernandez

72

Um autoencoder detalhado  
(imagem da internet, adaptada)

73



Um pouquinho de Deep Learning

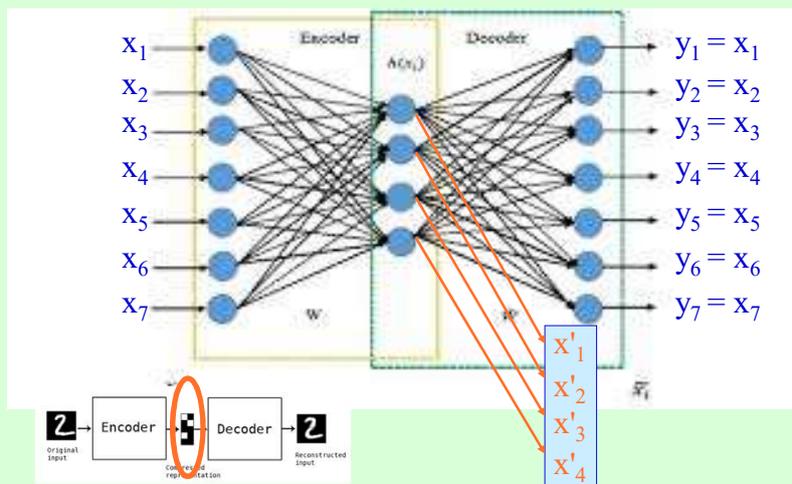
© Prof. Emilio Del Moral Hernandez

73

73

Um autoencoder detalhado  
(imagem da internet, adaptada)

74



Algumas ferramentas em Deep Learning

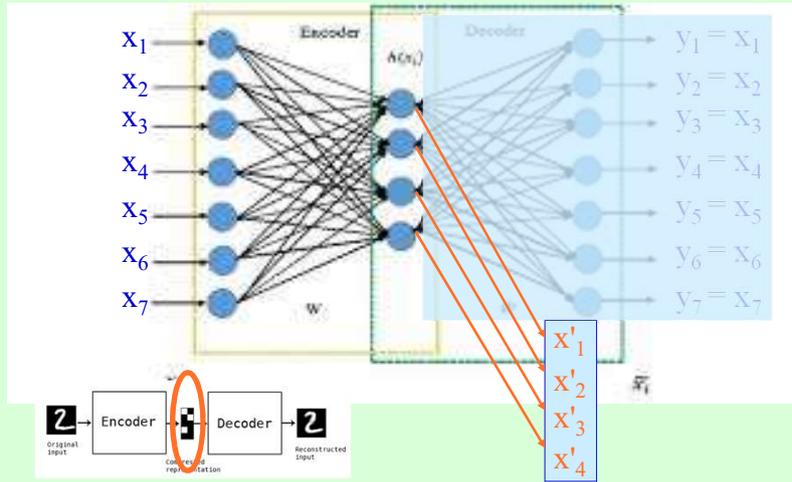
© Prof. Emilio Del Moral Hernandez

74

74

Um autoencoder detalhado  
(imagem da internet, adaptada)

75



Algumas ferramentas em Deep Learning

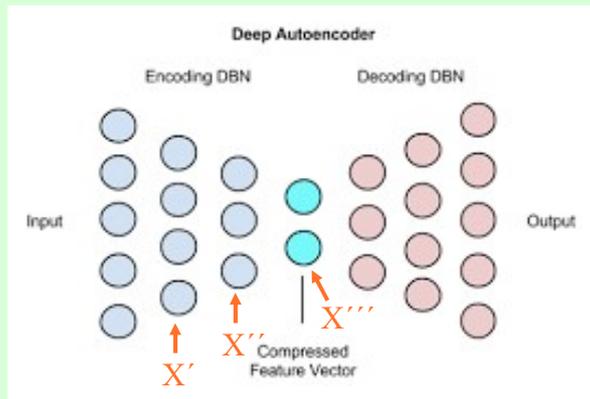
© Prof. Emilio Del Moral Hernandez

75

75

Autoencoders e Stacked Auto-encoders  
(imagens da internet)

76



Algumas ferramentas em Deep Learning

© Prof. Emilio Del Moral Hernandez

76

76

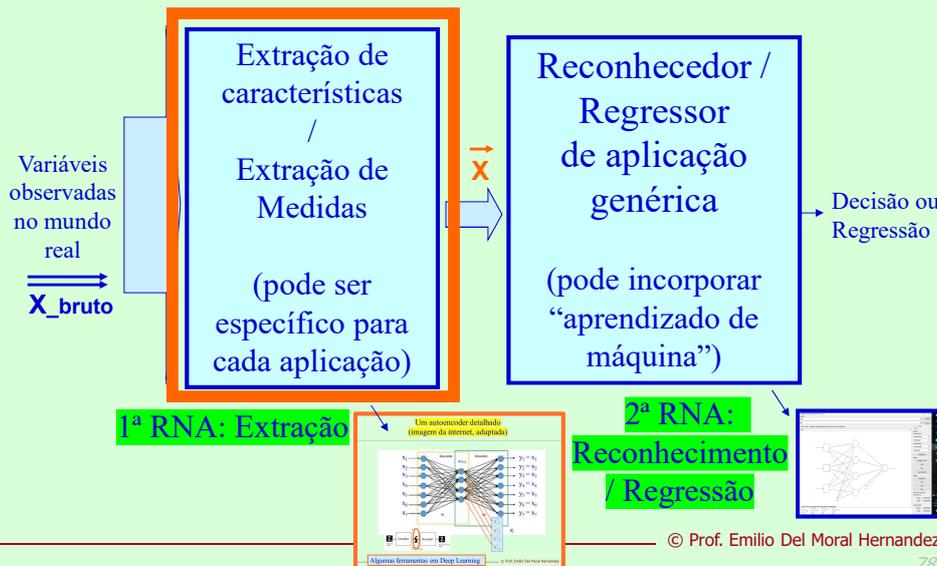
*Note que nesta técnica, o primeiro estágio da “solução em dois estágios” também é uma rede neural (não só o segundo estágio é uma RNA), mas esse primeiro estágio é uma RNA específica, desenhada apenas para a codificação compacta de variáveis; ela não realiza a regressão ou o reconhecimento, que são feitos pela segunda rede neural.*

© Prof. Emilio Del Moral – EPUSP

77

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

78



78