

PSI3472 – Análise de sinais de tempo

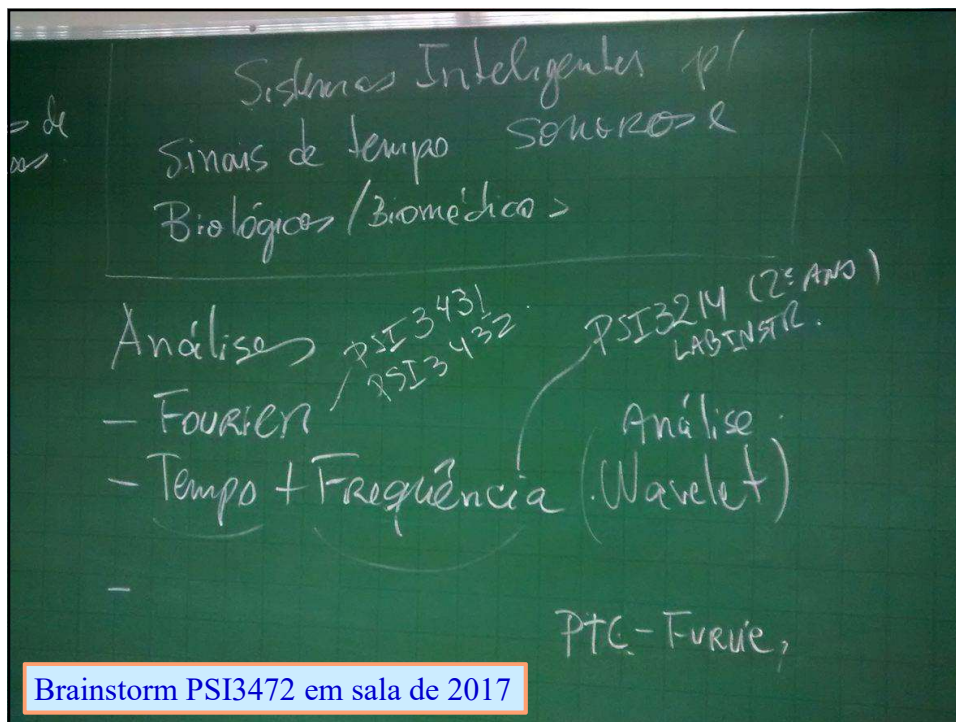
76

*Recordemos alguns aspectos já
abordados neste curso e em cursos
correlatos ...*

© Prof. Emilio Del Moral Hernandez

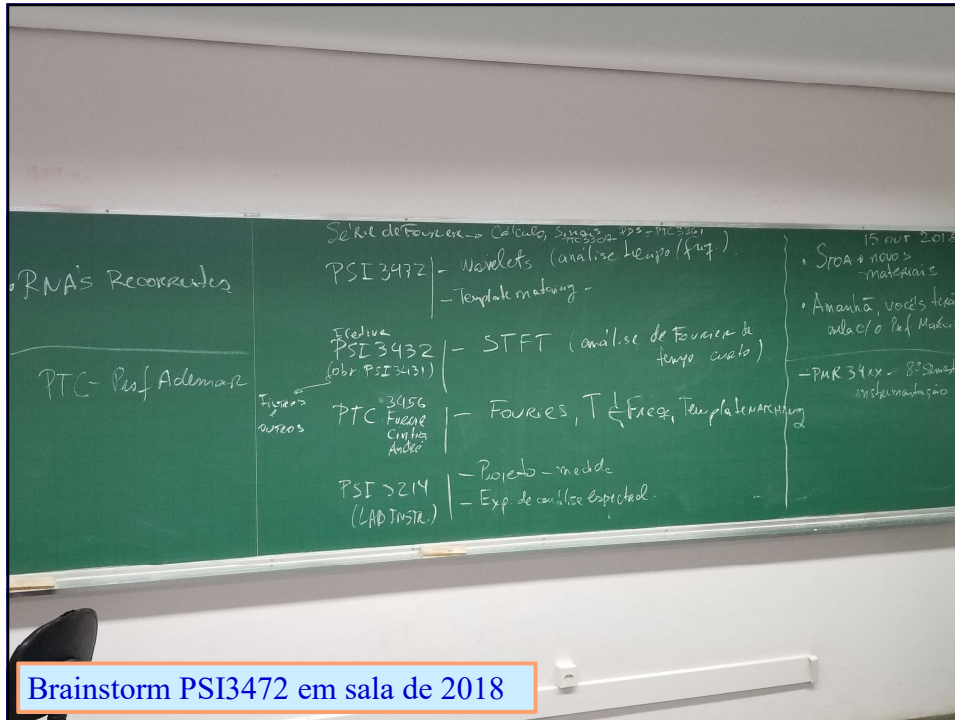
76

76

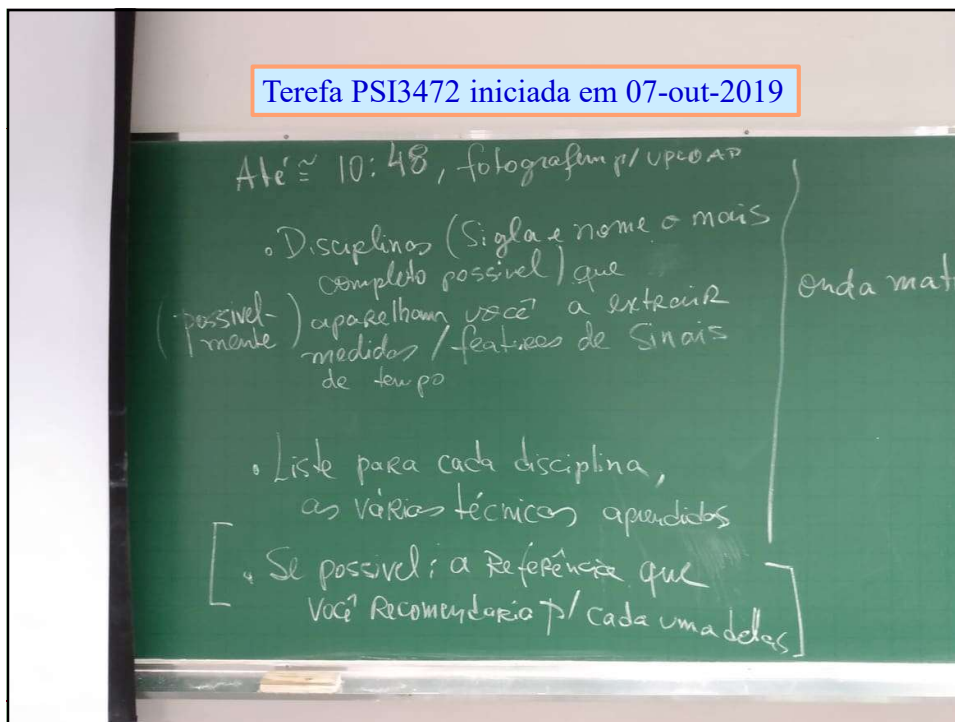


Brainstorm PSI3472 em sala de 2017

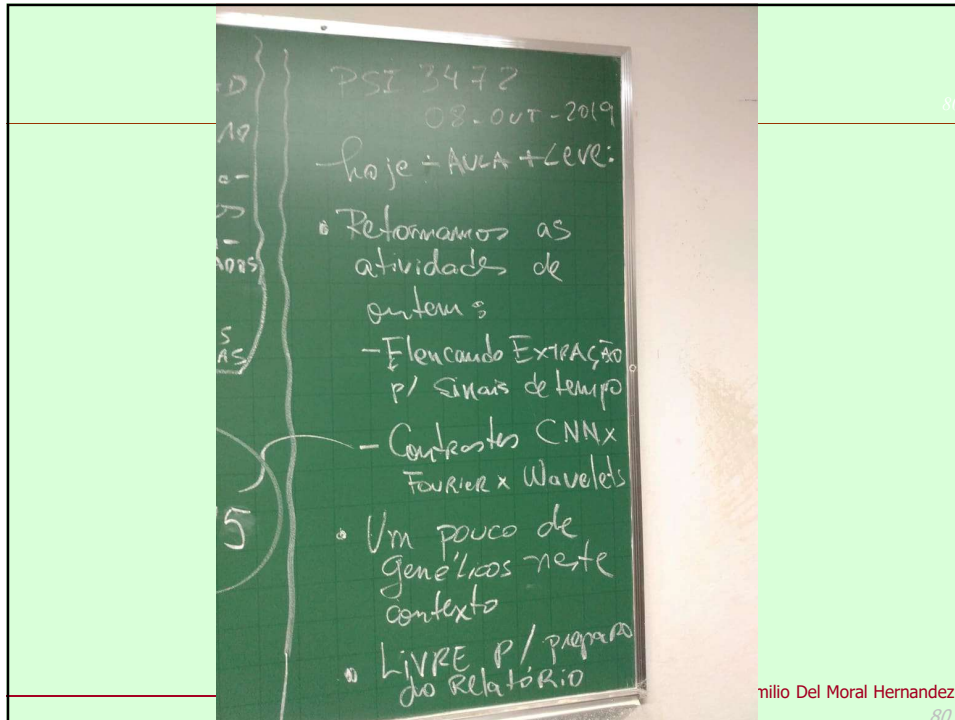
77



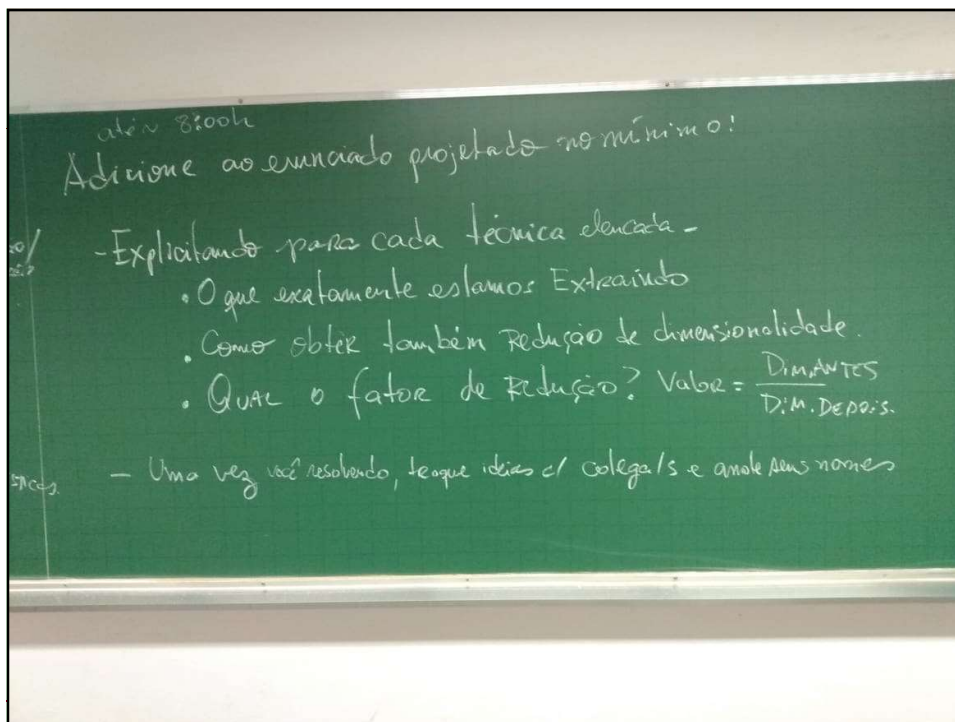
78



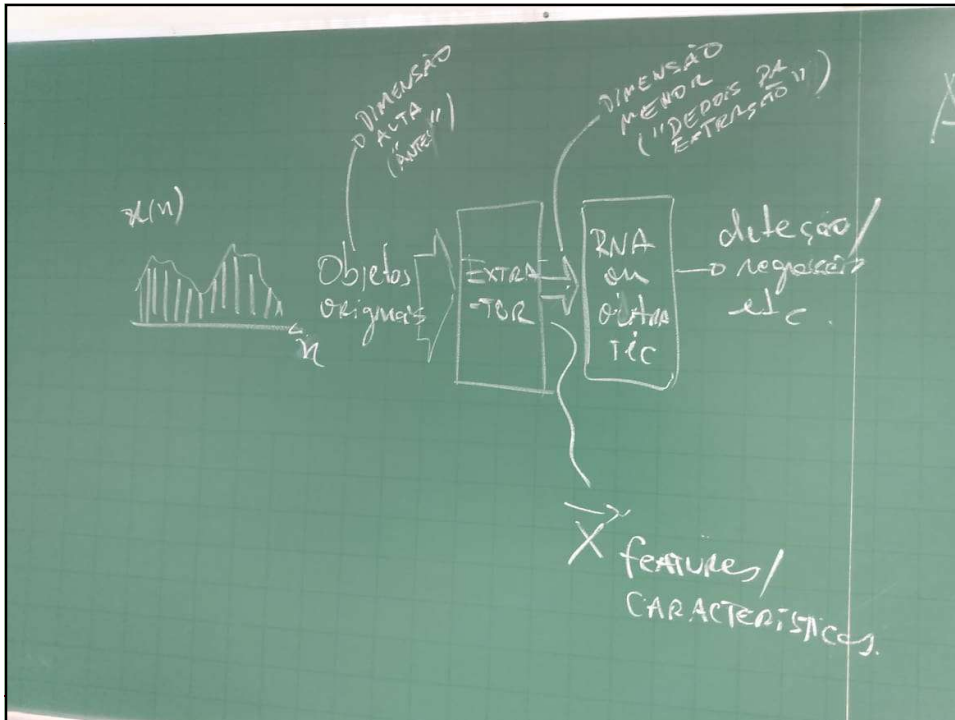
79



80



81



82

Fotografia para UPLOAD
 → ESTE UPLOAD
 será partilhado com todos os
 colegas MATRICULADOS
 ASSIM, TODOS
 APRENDEM COM OS
 COLEGAS

83

Para reflexão (tarefa em sala de aula)

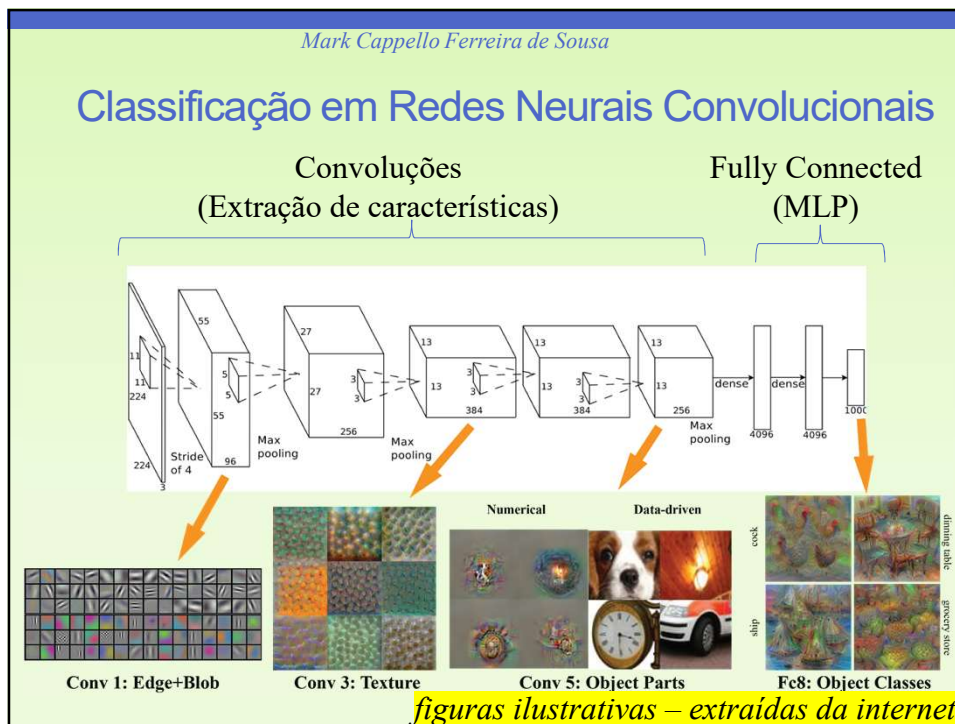
84

- Que semelhanças entre Wavelets e análise de Fourier você consegue explicitar? Escreva.
 - Que diferenças? Escreva.
- Que semelhanças entre Wavelets e CNNs unidimensionais você consegue explicitar? Escreva.
 - Que diferenças? Escreva.
- Que semelhanças entre CNNs e análise de Fourier você consegue explicitar? Escreva.
 - Que diferenças? Escreva.

© Prof. Emilio Del Moral Hernandez

84

84



85

86

Convolutional Neural N

medium.com/@phidacouss/convolutional-neural-networks-cnn-or-convnets-d7c688bda207

Medium

Sign in Get started

Input Volume (pad 1) (7x7x3)	Filter W0 (3x3x3)	Filter W1 (3x3x3)	Output Volume (3x3x2)
$x[1,1,0]$ 0 0 0 0 0 0 0	$w[1,1,0]$ -1 0 1	$w[1,1,0]$ 0 1 -1	$o[1,1,0]$ 2 3 3
0 0 0 1 0 2 0	0 0 1	0 -1 0	3 7 3
0 1 0 2 0 1 0	1 -1 1	0 -1 1	8 10 -3
0 1 0 2 2 0 0	$w[1,1,1]$ -1 0 1	$w[1,1,1]$ 1 0 0	$o[1,1,1]$ -8 [5] -3
0 2 0 0 2 0 0	1 -1 1	1 -1 0	-3 1 0
0 2 1 2 2 0 0	0 -1 0	1 1 0	-3 -8 -5
0 0 0 0 0 0 0	0 -1 0	1 1 0	
$x[1,1,1]$ 0 0 0 0 0 0 0	$w[1,1,2]$ -1 1 -1	$w[1,1,2]$ -1 1 -1	
0 2 1 2 1 1 0	1 1 0	0 -1 -1	
0 2 1 2 0 1 0	0 -1 0	1 0 0	
0 0 2 1 0 1 0	Bias $b_0[1,1,0]$ 1	Bias $b_1[1,1,0]$ 0	
0 1 2 2 2 2 0			
0 0 1 2 0 1 0			
0 0 0 0 0 0 0			
$x[1,1,2]$ 0 0 0 0 0 0 0			
0 2 1 1 2 0 0			
0 1 0 0 1 1 0			
0 0 1 0 0 0 0			
0 1 0 2 1 0 0			
0 2 2 1 1 1 0			
0 0 0 0 0 0 0			

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

Never miss a story from Firdaouss Doukkali, when you sign up for Medium. Learn more

GET UPDATES

© Prof. Emilio Del Moral Hernandez

86

87

Video bem interessante gerado por alunos da PSI5886-Prof Emilio
<https://www.youtube.com/watch?v=2dz4qLq-nMU&feature=youtu.be>

Teoria Redes Convolucionais

Redes Convolucionais – Parte 2

Trabalho final da disciplina
 PSI5886 – Princípios de Neurocomputação

Grupo:
 Bruno Giordano
 Fábio Teixeira
 Wanderson Ferreira
 Bruno Franceschini Canale

Escola Politécnica da Universidade de São Paulo

0:14 / 18:25

© Prof. Emilio Del Moral Hernandez

87

88

Teoria Redes Convolucionais

ConvNets - Convolução

- As redes convolucionais aplicam filtros ao longo da imagem, procurando representações características para então classificá-las

faces

cars

© Prof. Emilio Del Moral Hernandez

88

88

89

Teoria Redes Convolucionais

ConvNets – Convolução

- As camadas são volumes que representam convoluções – imagens são filtradas

CONVOLUTIONAL LINGO

© Prof. Emilio Del Moral Hernandez

89

89

90

Teoria Redes Convolucionais

ConvNets - Convolução

- Os neurônios representam os filtros
- Neurônios que estão no mesmo plano composto pelos eixos da altura e largura, compartilham os mesmos pesos

Largura

Altura

Quantidade de neurônios = filtros

© Prof. Emilio Del Moral Hernandez

90

90

91

Teoria Redes Convolucionais

ConvNets – Convolução

© Prof. Emilio Del Moral Hernandez

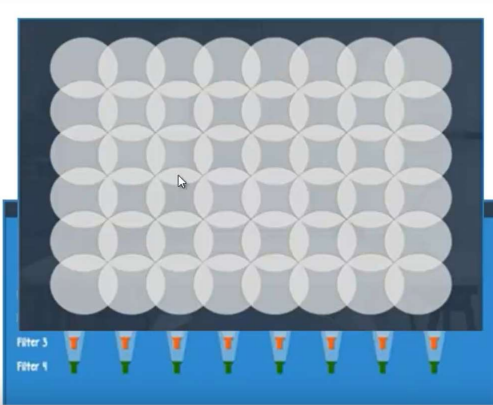
91

91

92

Teoria Redes Convolucionais

ConvNets – Convolução



Filter 3
Filter 1

7:34 / 18:25

© Prof. Emilio Del Moral Hernandez

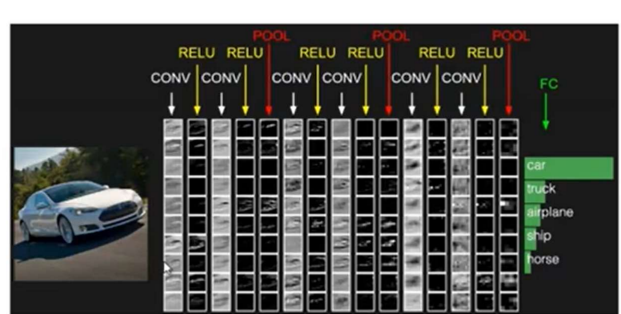
92

92

93

Teoria Redes Convolucionais

Topologia Típica



CONV RELU RELU POOL RELU RELU POOL RELU RELU POOL CONV CONV CONV CONV CONV CONV FC

car
truck
airplane
ship
horse

17:20 / 18:25

© Prof. Emilio Del Moral Hernandez

93

93

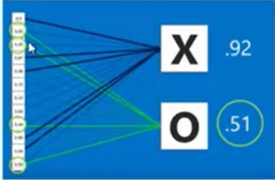
94

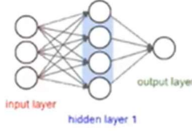
Teoria Redes Convolucionais

ConvNets – FC Layer

- Com a sequência de combinações de camadas de convolução com *pooling*, a dimensão é reduzida até atingir o formato de um vetor, o qual alimenta uma *fully-connected layer*, permitindo assim a classificação:

EXTRAÇÃO DE MEDIDAS





input layer
hidden layer 1
output layer

16:48 / 18:25

© Prof. Emilio Del Moral Hernandez

94

95

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

Extração de características
/
Extração de Medidas

(pode ser específico para cada aplicação)

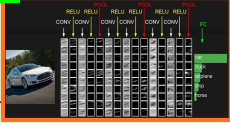
→

Reconhecedor /
Regressor de aplicação genérica

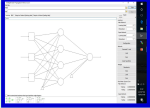
(pode incorporar “aprendizado de máquina”)

Decisão ou Regressão

1ª RNA: Extração, por
Convoluções e
Multicamadas



2ª RNA:
Reconhecimento
/ Regressão



© Prof. Emilio Del Moral Hernandez

95

... E o que estas CNNs para imagens têm a ver com sinais de tempo como voz e similares, que são os que nos interessam no momento ???

Imagem ilustrativa da internet – Sistemas SLIT

Soma de Convolação

- Lembrando:


$$T\{\delta[n]\} = h[n]$$

- $h[n]$ – resposta ao impulso
- E que o sistema é LTI, logo:

$$h[n - k] = T\{\delta[n - k]\}$$

- Substituindo em

$$y[n] = \sum_{k=-\infty}^{\infty} x[k] T\{\delta[n - k]\}$$



- Obtemos a **Soma de Convolação**

$$y[n] = \sum_{k=-\infty}^{\infty} x[k] h[n - k]$$

◦ ou


$$x[n] * h[n] = \sum_{k=-\infty}^{\infty} x[k] h[n - k]$$

- * representa convolação

$$y[n] = x[n] * h[n]$$

Resposta ao Impulso

- Seja o Sistema Linear Invariante no Tempo (LTI)



- $h[n]$ – resposta ao impulso

98

102

*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

102

102

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

103

Curso: PSI3472 - Concepção | Disciplina: PSI2672 do Grup | Sistemas de detecção e clas | Extração de parâmetros

teses.usp.br/teses/disponiveis/3/3142/tde-19072011-110149/pt-br.php

Biblioteca Digital USP Teses e Dissertações

Tese de Doutorado

DOI: 10.11606/T.3.201110a-19072011-110149

Documento: Tese de Doutorado

Autor: Borges, Liselene de Abreu (Catálogo USP)

Nome completo: Liselene de Abreu Borges

E-mail: [redacted]

Unidade da USP: Escola Politécnica

Área do Conhecimento: Sistemas Eletrônicos

Data de Defesa: 2011-10-08

Imprenta: São Paulo, 2011

Orientador: Arjona Ramirez, Miguel (Catálogo USP)

Banca examinadora: Arjona Ramirez, Miguel (Presidente)
Alcain, Abraham
Del Moral Hernandez, Emilio
Figueroa, Ruben Dutra Ribeiro
Queiroz, Marcelo Gomes de

Título em português
Palavras-chave em português
Máquina de vetores de suporte
Predição linear
Processamento de sinais
Vazamento de água

Título em inglês
Palavras-chave em inglês
Linear prediction
Signal processing
Support vector machine
Water leak

Resumo em português
Este trabalho apresenta a pesquisa sobre a extração de parâmetros característicos de sinais acústicos para fins de detecção automática de vazamento de água em tubulações enterradas. Os sinais acústicos foram adquiridos com o auxílio de um geofone eletrônico e também catalogados por técnicos especialistas em detecção acústica. De todos os sinais foram extraídos os modelos de predição linear percipiais de vários ordens, determinando-se como melhor o ordem 2. A partir de um conjunto de modelos de referência de sinais de vazamento, a distância média de Itakura dos outros modelos em relação a estas referências foram calculadas. Em conjunto com estes distâncias quatro características espectrais são também extraídas do sinal e fim de conjunto o vetor de parâmetros característicos do sinal. Parte destes vetores de parâmetros característicos são utilizados para treinar o classificador de máquina de vetores de suporte. O restante dos sinais são então submetidos a este classificador que obteve a taxa de acerto de classificação em torno de 90%. Experimentos anteriores, utilizando modelos de predição linear, de ordem 10, obtiveram uma taxa de acerto em torno de 82%, isso demonstra que estes novos parâmetros característicos propostos alcançam os objetivos deste trabalho, que são algoritmos com melhor taxa de acerto na detecção de vazamentos.

Resumo em inglês
This work presents a research about feature extraction of acoustic signals for detection of water leak in buried pipes. Acoustic signals were acquired by means of an electronic geophone and also labeled by technicians specialized in acoustic water leak detection. For every signal, its linear prediction model was estimated for a range of prediction orders, concluding for the best order 2. Out of this group of models, some key ones are used as reference for calculating the Itakura for a range of prediction orders, concluding for the best order 2. Out of this group of models, some key ones are used as reference for calculating the Itakura for a range of prediction orders, concluding for the best order 2.

© Prof. Emilio Del Moral Hernandez

103

defesa08Abr2011_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011_L... x

Fazer login

Compartilhar

1 / 35 63,6%

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

105

106

defesa08Abr2011_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011_L... x

Fazer logon

2 / 35 63.6%

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

106

106

107

defesa08Abr2011_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011_L... x

Fazer logon

5 / 35 63.6%

Compartilhar

Os Tipos de Vazamentos

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

O diagrama mostra um tubo horizontal com uma superfície superior rotulada como 'superfície'. Três tipos de vazamentos são ilustrados: (a) um vazamento inerente onde o fluido vaza diretamente através da parede do tubo; (b) um vazamento não visível onde o fluido vaza para o interior do tubo e se acumula em uma câmara oculta; (c) um vazamento visível onde o fluido vaza para o exterior do tubo através de uma conexão ou junta.

© Prof. Emilio Del Moral Hernandez

107

107

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

108

O procedimento de detecção do Vazamento

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



© Prof. Emilio Del Moral Hernandez


108

108

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

109

Sistema de Deteção de Vazamento



© Prof. Emilio Del Moral Hernandez

109

109

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

112

defesa08Abr2011_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

defesa08Abr2011_L... x

Fazer login

22 / 35 63,6%

Extração no domínio temporal

- * Energia de curto Prazo

$$E_n = \sum_{m=n}^M [x(n)w(n-m)]^2$$

- * Taxa de Cruzamento por zero

$$Z_n = \sum_{m=n}^M [\text{sgn}[x(m)] - \text{sgn}[x(m-1)]]w(n-m)$$

© Prof. Emilio Del Moral Hernandez

112

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

113

defesa08Abr2011_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

defesa08Abr2011_L... x

Fazer login

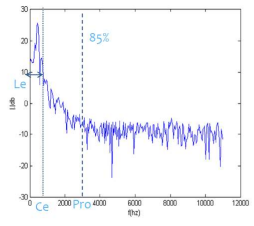
23 / 35 63,6%

Extração no domínio espectral

- * Centróide Espectral (Ce)
- * Largura de Espectro (Le)
- * Fluxo Espectral

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

- * Ponto de Roll-off (Pro)
- * Taxa de Espalhamento

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


© Prof. Emilio Del Moral Hernandez

113

114

defesa08Abr2011_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011_L... x

Fazer logon

13 / 35 63.6%

Compartilhar

Métodos de avaliação dos parâmetros individuais

* Avaliação individual de cada parâmetros característico através da estatística-M

$$\text{estatística}_M = \frac{|\mu_{P_{inc}} - \mu_{P_{exc}}|}{\sigma_{P_{inc}} + \sigma_{P_{exc}}}$$

© Prof. Emilio Del Moral Hernandez

114

114

115

defesa08Abr2011_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011_L... x

Fazer logon

15 / 35 63.6%

Compartilhar

Medidas de desempenho

* Acurácia, Sensibilidade e Especificidade:

$$\text{Sensibilidade} = \frac{\text{Total de Acerto de Vazamentos}}{\text{Total de Vazamentos}}$$

$$\text{Especificidade} = \frac{\text{Total de Acerto de NÃO Vazamentos}}{\text{Total de NÃO Vazamentos}}$$

$$\text{Acurácia} = \frac{\text{Total de Acerto de Vazamento} + \text{Total de Acerto de NÃO Vazamento}}{\text{Total de Vazamento} + \text{Total de NÃO Vazamento}}$$

© Prof. Emilio Del Moral Hernandez

115

115

116

defesa08Abr2011_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011_L... x

Fazer login

16 / 35 63.6%

Compartilhar

Pré-Processamento

Pré-processamento

```

    graph LR
      A[Sub-amostragem] --> B[Normalização]
      B --> C[Pré-ênfase]
      C --> D[Segmentação]
  
```

$x(n) \downarrow 4$

$\tilde{x}(n) = \frac{x(n) - \mu_x}{\sigma_x}$

© Prof. Emilio Del Moral Hernandez

116

116

117

defesa08Abr2011_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011_L... x

Fazer login

27 / 35 63.6%

Compartilhar

Avaliação Individual – sinal original

* Estatística_M = 0.60133

© Prof. Emilio Del Moral Hernandez

117

117

118

defesa08Abr2011_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011_L... x

Fazer login

30 / 35 63.6%

Compartilhar

Estatística_M geral

Parâmetro característico	original	Pré-ênfase 1	Pré-ênfase 2
Energia de curto prazo	0.22186	0.10927	0.33554
Taxa de cruzamento por zero	0.21189	0.76788	0.82757
Centróide espectral	0.80833	0.80953	0.25599
Largura de espectro	0.83449	0.88455	0.33555
Fluxo espectral	0.89947	0.57221	0.46769
Ponto de roll-off	0.75491	0.78911	0.66372
Taxa de espalhamento	0.39558	0.17837	0.35039
Modelo AR ordem=10			
Dist. máx. Itakura-AR	0.09678	0.24098	0.34357
Dist. méd. Itakura-AR	0.076167	0.23716	0.36887
Dist. máx. espectral-AR	0.006084	0.4213	0.35637
Dist. méd. espectral-AR	0.11491	0.43526	0.48266
Modelo PLP ordem=2			
Dist. máx. Itakura-PLP	0.24388	0.10265	0.13351
Dist. méd. Itakura-PLP	0.8326	0.15935	0.083966
Dist. máx. espectral-PLP	0.33263	0.197	0.20062
Dist. méd. espectral-PLP	0.21759	0.21026	0.072005

© Prof. Emilio Del Moral Hernandez

118

118

119

defesa08Abr2011_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011_L... x

Fazer login

31 / 35 63.6%

Compartilhar

Resultado da classificação Individual

Parâmetro Característico	Sinal Original (%)	Sinal pré-ênfase 1 (%)	Sinal pré-ênfase 2 (%)
Energia de curto prazo	64.8936	64.8936	64.8936
Taxa de cruzamento por zero	64.8936	85.1064	87.234
Centróide espectral	72.6596	89.3617	86.2702
Largura de espectro	89.3617	87.234	91.4894
Fluxo espectral	88.2979	87.234	28.234
Ponto de roll-off	88.8911	86.1792	87.234
Taxa de espalhamento	68.8851	64.8936	69.1489
Dist. máx. Itakura AR (ordem=10)	72.3404	64.8936	81.9787
Dist. méd. Itakura AR (ordem=10)	71.2766	64.8936	84.0426
Dist. máx. espectral AR (ordem=10)	64.8936	71.2766	69.1489
Dist. méd. espectral AR (ordem=10)	67.7021	64.8936	81.9449
Dist. máx. Itakura PLP (ordem=2)	64.8936	71.2766	68.8851
Dist. méd. Itakura PLP (ordem=2)	64.8936	67.0213	65.9574
Dist. máx. espectral PLP (ordem=2)	63.8298	68.8851	67.0213
Dist. méd. espectral PLP (ordem=2)	63.8298	65.9574	69.1489

© Prof. Emilio Del Moral Hernandez

119

119

120

Resultado do classificação em grupo

Parâmetros característicos(1)	Acuracidade(1)	Sensibilidade(%)	Especificidade(1)
1,2,3,4,7	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	95,082
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	96,9091	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	87,8288	98,3607
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

© Prof. Emilio Del Moral Hernandez

120

Temas para hoje ...

122

- Onda mãe (um pouco mais a respeito)
- Sistema auditivo, Sistema fonador, Mel-Freq Cepstrum
- Disciplina PSI3501 **MUITOS DILEMAS ...**
(post de Jupiter e Janus – e diversas disciplinas)
- All Features em tese de Liselene / Prof Miguel
(post de trabalho de Liselene)
- Explicitando dilemas de seleção de Características
- Alguns possíveis guias de seleção de características
- Dilemas arquitetura da RNAs ; Dilema de técnicas de extração de características ; Combinatória completa x combinatória parcial
(post de trabalho de Massaki e colegas em Genéticos)
- Disciplinas eletivas de 5º ano e “eletivas de pós” – PSI3501, PSI3571, PSI5880, PSI5886 etc
- Nosso calendário mais imediato em PSI3472

© Prof. Emilio Del Moral Hernandez

122

*Indo além em sistemas multissensores e em
inteligentes e sinais de tempo ...
Conexão com Genéticos por ex, para
refinamentos na fusão de informações e na
seleção de características / harmônicas /
coeficientes wavelet, etc*

Apresentação do projeto de um grupo de PSI5880,
tema: Implementação de um pHmetro através de
Redes Neurais Artificiais e Algoritmos Genéticos.
Alunos: Alexandre Kimiyaki Ligo, César Augusto
Mayor Herrera, Massaki de Oliveira Igarashi e
Tiago Oliveira Weber

Exemplo no STOA de uso de RNAs e Genéticos em Multissensores

126

PSIS880 - Aplicação de Int. Comp. e Téc. de Proc. de Sinais a Sistemas Sensores e Biosensores
Universidade de São Paulo Prof. Emilio Del Moral Hernandez

Implementação de um pHmetro através de Redes Neurais Artificiais e Algoritmos Genéticos

Alexandre Kimiyaki Ligo
César Augusto Mayor Herrera
Massaki de Oliveira Igarashi
Tiago Oliveira Weber

DEZ/2010 1

© Prof. Emilio Del Moral Hernandez

126

126

Exemplo no STOA de uso de RNAs e Genéticos em Multissensores

127

APRESENTAÇÃO

PSIS880 - Aplicação de Int. Comp. e Téc. de Proc. de Sinais a Sistemas Sensores e Biosensores

- 1 • OBJETIVO
 - Medição de pH
- 2 • Redes Neurais Artificiais
 - Algoritmos Genéticos
- 3 • Entradas - Sensores
- 3 • Aquisição
- 3 • Processamento
- 4 • RESULTADOS
- 5 • CONCLUSÕES
- 6 • Perspectivas Futuras

2

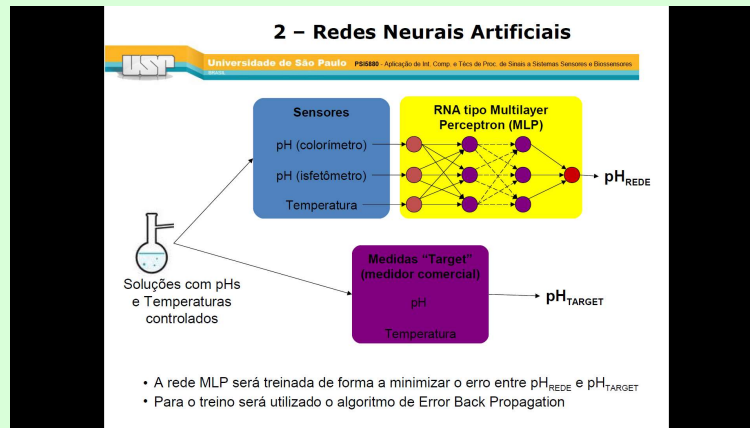
© Prof. Emilio Del Moral Hernandez

127

127

Exemplo no STOA de uso de RNAs e Genéticos em Multissensores

128



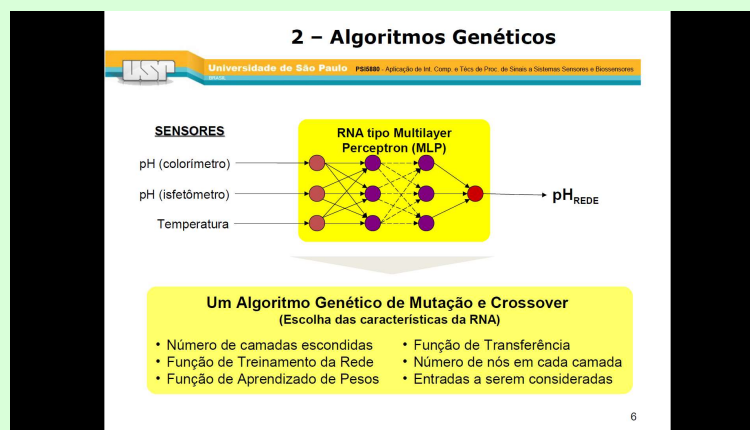
© Prof. Emilio Del Moral Hernandez

128

128

Exemplo no STOA de uso de RNAs e Genéticos em Multissensores

130




© Prof. Emilio Del Moral Hernandez

130

130

Exemplo no STOA de uso de RNAs e Genéticos em Multissensores

131



Universidade de São Paulo **PSIBIO** - Aplicação de Int. Comp. e Téc. de Proc. de Sinais a Sistemas Sensores e Diagnósticos

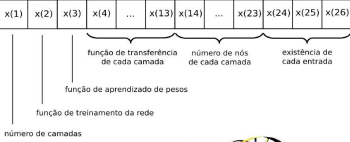
3 - Processamento


Parâmetros do Algoritmo Genético	Valores
Fração de Crossover	0,8
Gerações	10
Tamanho População	50
Nº de Indivíduos Elite	0
Função de criação	<i>Criationuniform</i>

Cromossomo:

- todos os genes são valores inteiros;
- nem todos os genes são utilizados em todas as redes;

x(1)	x(2)	x(3)	x(4)	...	x(13)	x(14)	...	x(23)	x(24)	x(25)	x(26)
------	------	------	------	-----	-------	-------	-----	-------	-------	-------	-------






© Prof. Emilio Del Moral Hernandez

131

131

Exemplo no STOA de uso de RNAs e Genéticos em Multissensores

132



Universidade de São Paulo **PSIBIO** - Aplicação de Int. Comp. e Téc. de Proc. de Sinais a Sistemas Sensores e Diagnósticos

3 - Processamento

- **Número de camadas escondidas:** - pode variar de 1 até 10;
- **Função de Treinamento da Rede:** pode ser
 - *Levenberg-Marquardt backpropagation*;
 - *BFGS quasi-Newton backpropagation*;
 - *Resilient backpropagation (Rprop)*;
 - *Gradiente descendente*;
- **Função de Aprendizado de Pesos:** pode ser
 - Gradiente descendente;
 - Gradiente descendente com momento;
- **Função de Transferência de cada camada:** →

Hyperbolic tangent sigmoid transfer function
 Log-sigmoid transfer function
 Linear transfer function
 Competitive transfer function
 Inverse transfer function
 Radial basis transfer function
 Hard-limit transfer function
 Softmax transfer function
- **Número de nós em cada camada:** pode variar de 1 até 50;
- **Entradas que vai levar em conta:** varia de 0 até 1 para cada entrada;

12

© Prof. Emilio Del Moral Hernandez

132

132