

Iº tópico da agenda PSI3471 de 22 de abril de 2020:

Os Autoencoders do final da aula passada (15 de abril); caso não tenha visto o final daquele vídeo longo para o 15 de abril.

© Prof. Emilio Del Moral Hernandez



*Auto Encoders
(em uma forma simples)*

*Uma técnica de extração similar à PCA e
bastante em uso no universo
do Deep Learning*



Detector / reconhecedor multivariado

Variáveis
observadas
no mundo
real
 \vec{x}

Reconhecedor implementado
com uma rede neural que tem
como entradas as variáveis x_1 ,
 x_2 , x_3 , etc e como saída a
variável y , dependente das
variáveis x_i

decisão
binária y ,
dados os
valores X

© Prof. Emilio Del Moral Hernández



Regressor multivariado

Variáveis
observadas
no mundo
real
 \vec{x}

Regressor implementado com
uma rede neural que tem como
entradas as variáveis x_1 , x_2 , x_3 ,
etc e como saída a variável y ,
dependente das variáveis x_i

estimação
de valor
para o y ,
dados os
valores X

© Prof. Emilio Del Moral Hernández



Em vários projetos de regressão e reconhecimento (embora não em todos) há a necessidade de uma solução em 2 estágios

6

Um primeiro responsável por extração de características / extração de medidas mais relevantes dos objetos “X” brutos, medidas essas normalmente específicas para cada aplicação, e ...

Um segundo estágio atuando sobre o vetor com essas diversas medidas, e que emprega alguma técnica para a regressão / identificação de padrões, independente da aplicação, como é o caso de redes neurais artificiais

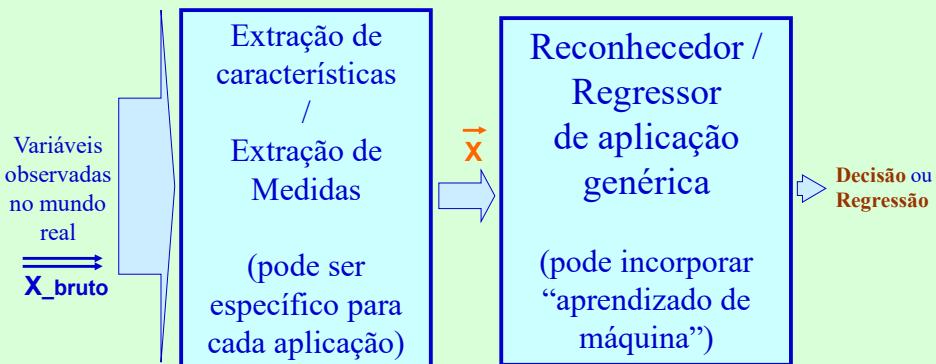
© Prof. Emilio Del Moral Hernández



6

Elaborando uma Solução em dois estágios

7

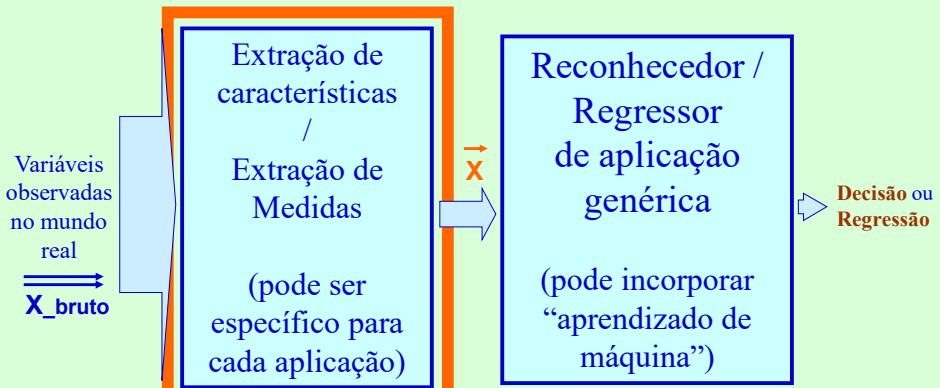


© Prof. Emilio Del Moral Hernández



7

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

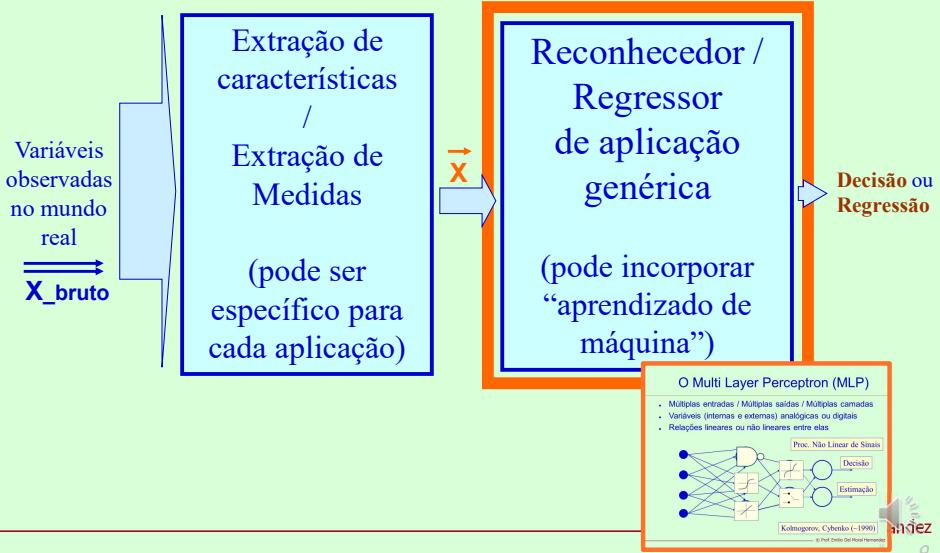


© Prof. Emilio Del Moral Hernández



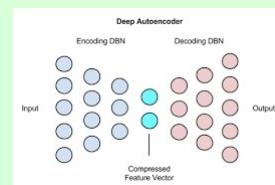
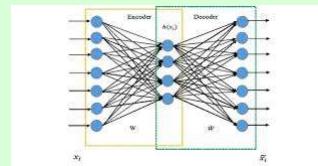
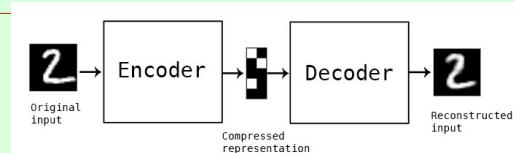
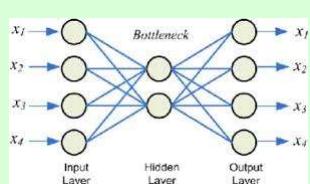
8

O segundo estágio opera sobre o Vetor de Medidas, \vec{X} (o 1º estágio gerou tal vetor)



9

Autoencoders e Stacked Auto-encoders (imagens da internet)



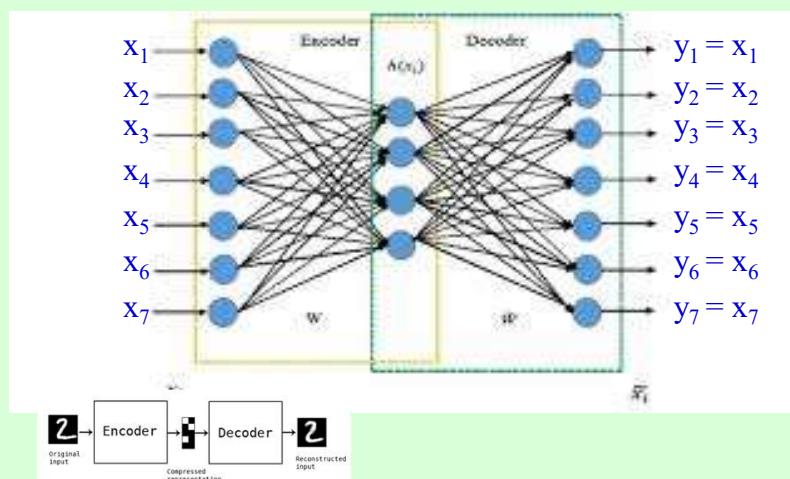
Algumas ferramentas em Deep Learning

© Prof. Emilio Del Moral Hernández



11

Um autoencoder detalhado (imagem da internet, adaptada)



Um pouquinho de Deep Learning

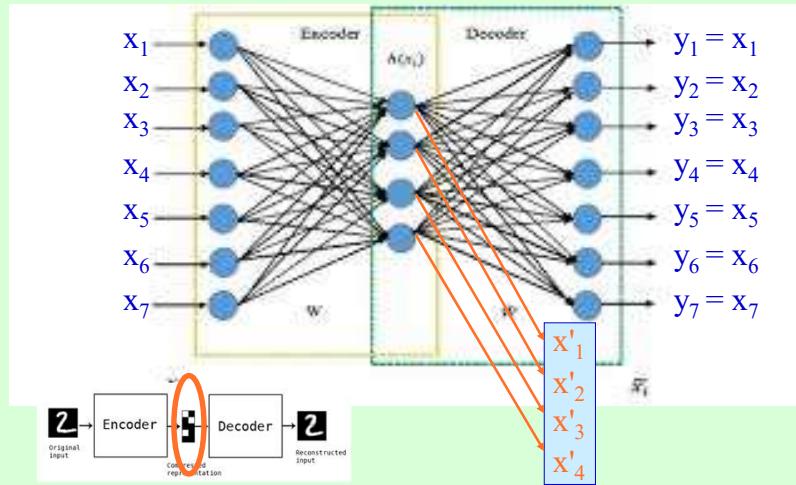
© Prof. Emilio Del Moral Hernández



12

Um autoencoder detalhado (imagem da internet, adaptada)

13



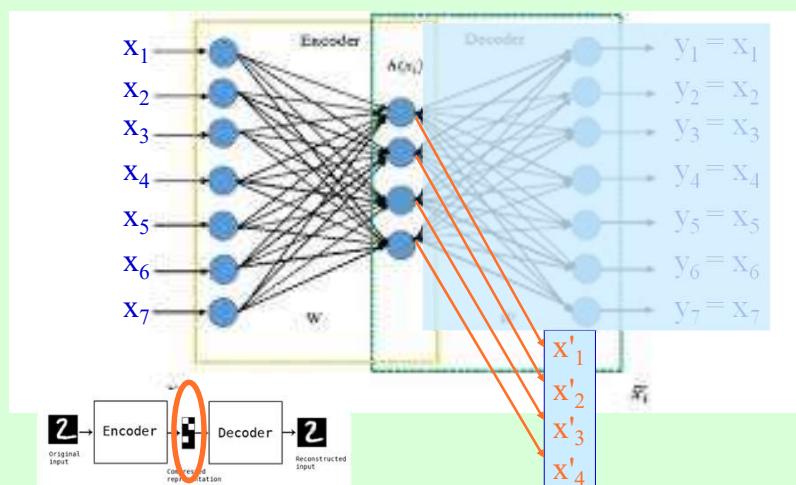
Algumas ferramentas em Deep Learning

© Prof. Emilio Del Moral Hernández

13

Um autoencoder detalhado (imagem da internet, adaptada)

14



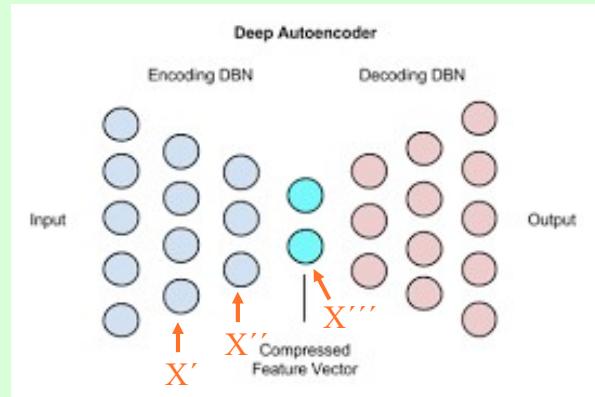
Algumas ferramentas em Deep Learning

© Prof. Emilio Del Moral Hernández

14

Autoencoders e Stacked Auto-encoders (imagens da internet)

15



Algumas ferramentas em Deep Learning

© Prof. Emilio Del Moral Hernández



15

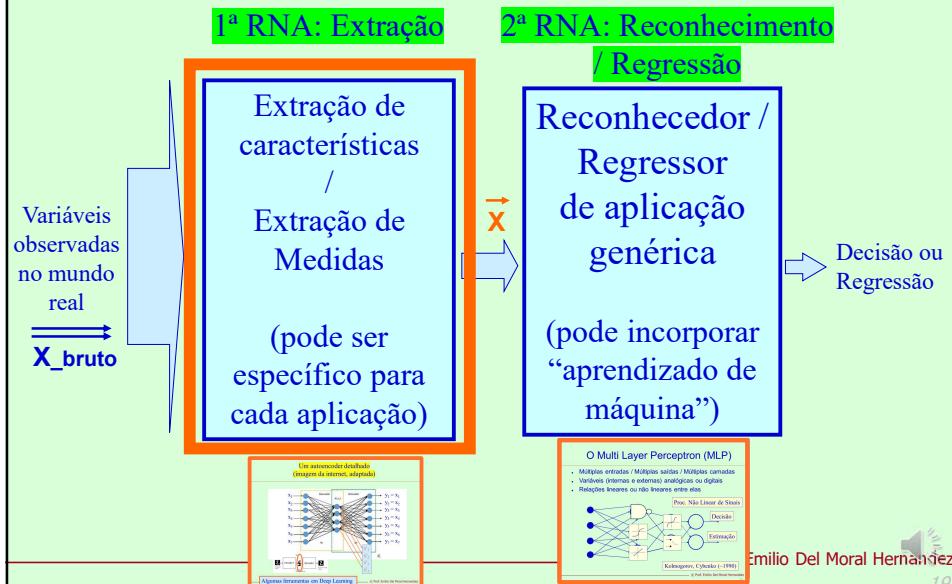
Note que nesta técnica, o primeiro estágio da “solução em dois estágios” também é uma rede neural (não só o segundo estágio é uma RNA), mas esse primeiro estágio é uma RNA específica, desenhada apenas para a codificação compacta de variáveis; ela não realiza a regressão ou o reconhecimento, que são feitos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

© Prof. Emilio Del Moral – EPUSP



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

19



20

2º tópico da agenda PSI3471 de 22 de abril de 2020:

As redes neurais convolucionais:

*Atuando sobre sinais de tempo
Atuando sobre imagens*

© Prof. Emilio Del Moral Hernandez

22

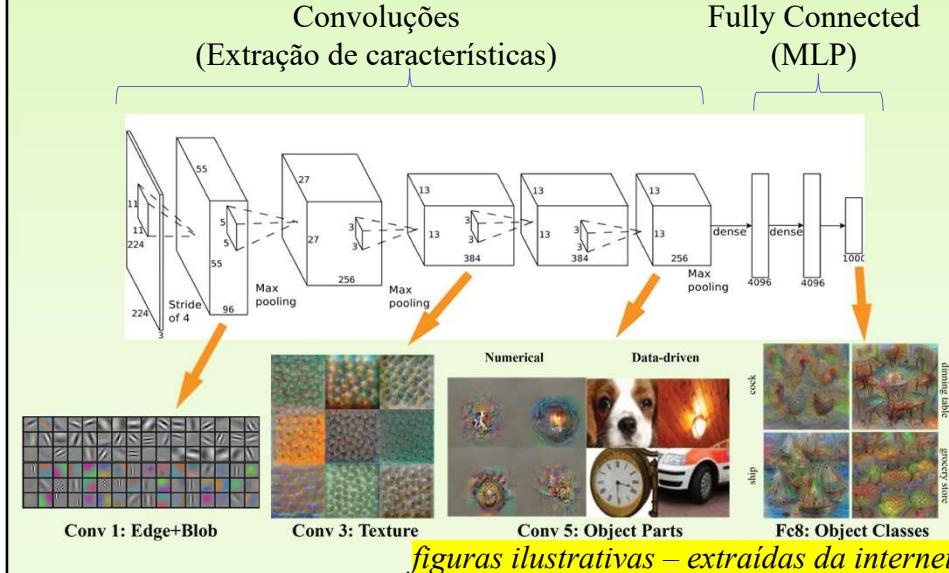
Falemos também sobre as Redes Neurais Convolucionais – ou ConvNets – ou Convolutional Neural Networks

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

© Prof. Emilio Del Moral Hernandez

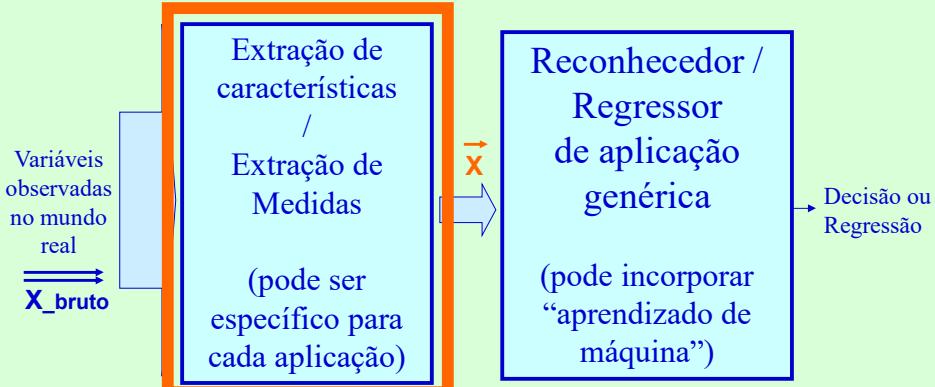
22

Classificação em Redes Neurais Convolucionais



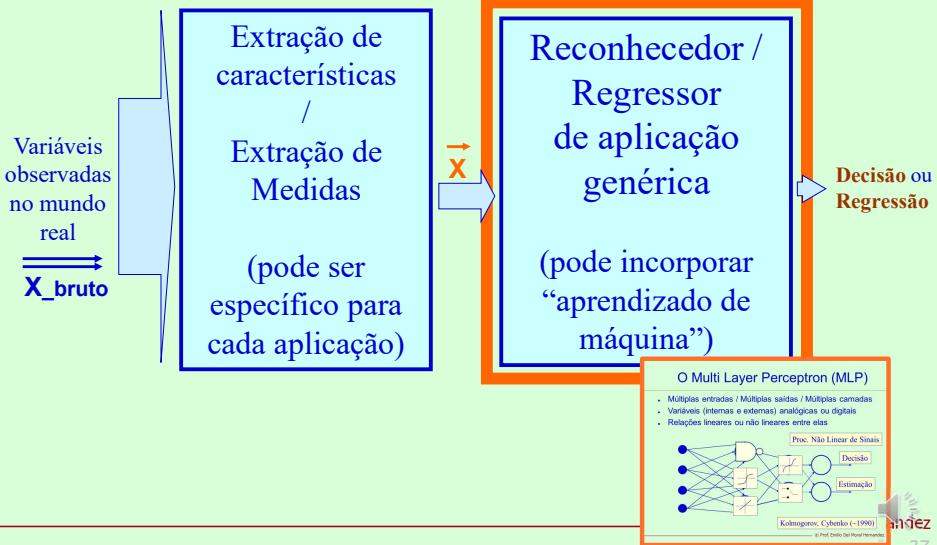
... O 1º estágio gera um Vetor de Medidas, \vec{X}
(o segundo estágio operará sobre tal vetor)

25



O segundo estágio opera sobre o Vetor de Medidas, \vec{x} (o 1º estágio gerou tal vetor)

27



27

um parênteses para aquecer motores ...

29

... as CNNs / ConvNets / CvNNs para imagens se relacionam de alguma forma com sinais de tempo (voz, elétricos e biológicos), cenário que explora já de muito as convoluções em sistemas SLIT ??? (sistemas lineares invariantes no tempo)

© Prof. Emilio Del Moral Hernandez

29

Imagen ilustrativa da internet – Sistemas SLIT

Soma de Convolução

- 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 Convolução**

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

ou

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

* representa convolução

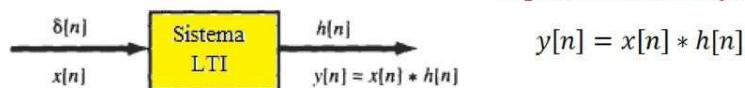
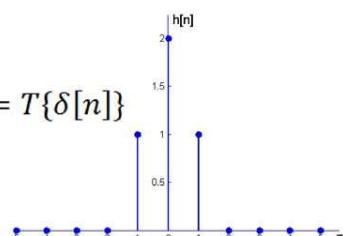
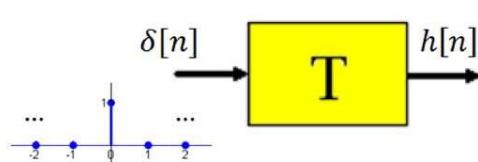


Imagen ilustrativa da internet – Sistemas SLIT

Resposta ao Impulso

- Seja o Sistema Linear Invariante no Tempo (LTI)



- $h[n]$ – resposta ao impulso

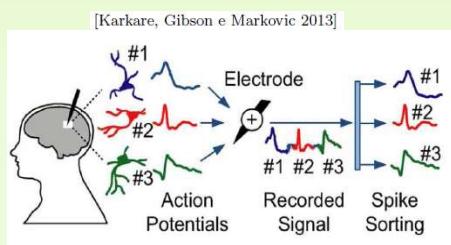
Relação entre Convolução e o conceito de Template matching e Correlação cruzada, em sinais de tempo ...

© Prof. Emilio Del Moral Hernandez

32

Neural Signal Processing in Analog CMOS IC
Neural Spikes Detection

Júlio Cesar Saldaña Pumarica

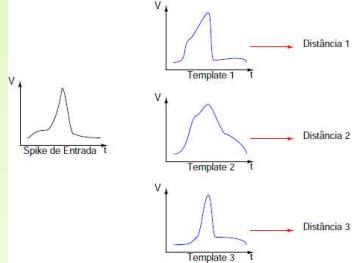


Neural Signal Processing in Analog CMOS IC

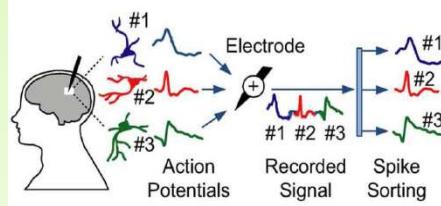
Neural Spikes Detection

Júlio Cesar Saldaña Pumarica

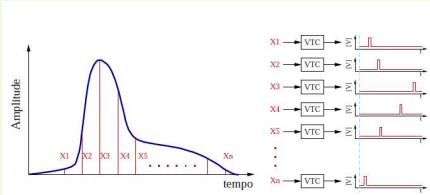
Template Matching based on minimum distance



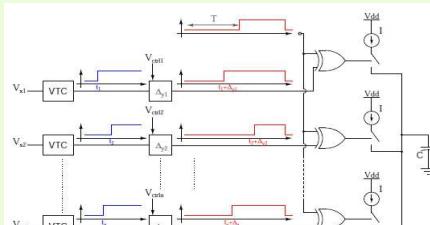
[Karkare, Gibson e Markovic 2013]



Time based encoding



Manhattan Distance



Sistemas Implantáveis de Registro Neural e BCIs

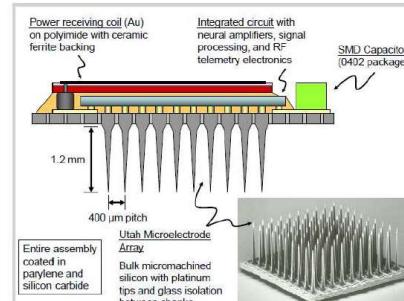


Figure 30.2.1: Complete Integrated Neural Interface (INI) assembly.

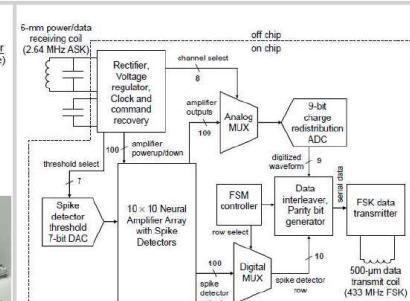


Figure 30.2.2: Integrated Neural Interface system block diagram.

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

Agora, vejamos a aplicação desse conceito do “Template matching / Correlação cruzada / Convolução” na área mais conhecida de uso de Redes Neurais Convolucionais

...

Reconhecimento de Imagens

© Prof. Emilio Del Moral Hernandez

Convolutional Neural Networks (CNN, or ConvNets)

Convolutional Neural networks allow computers to see, in other words, Convnets are used to recognize images by transforming the original image through layers to a class scores. CNN was inspired by the visual cortex. Every time we see something, a series of layers of neurons gets activated, and each layer will detect a set of features such as lines, edges. The high level of layers will detect more complex features in order to recognize what we saw.

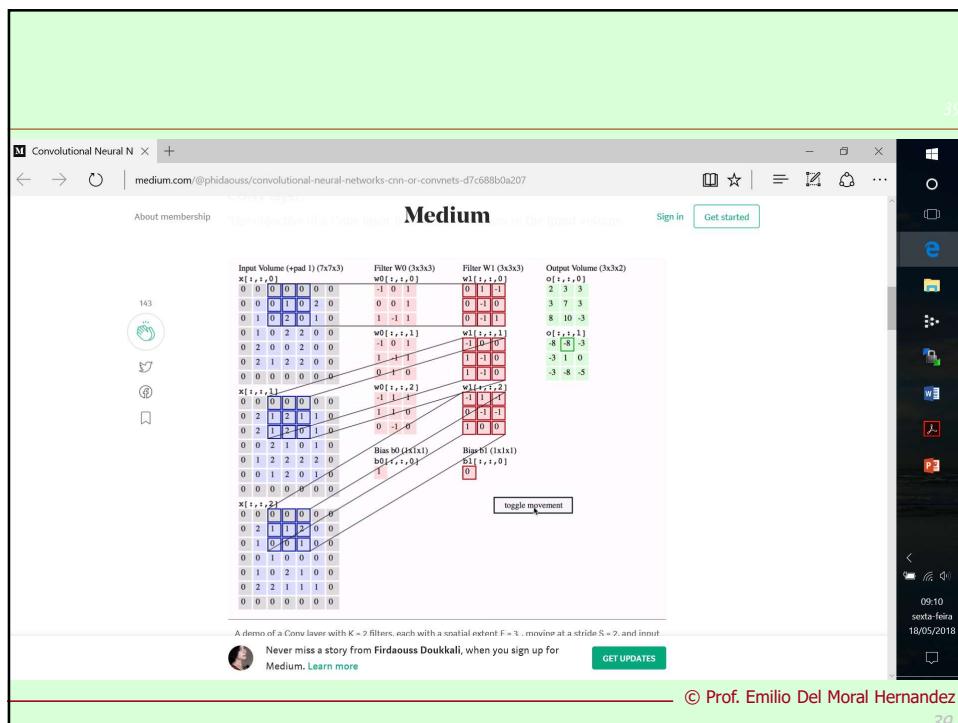
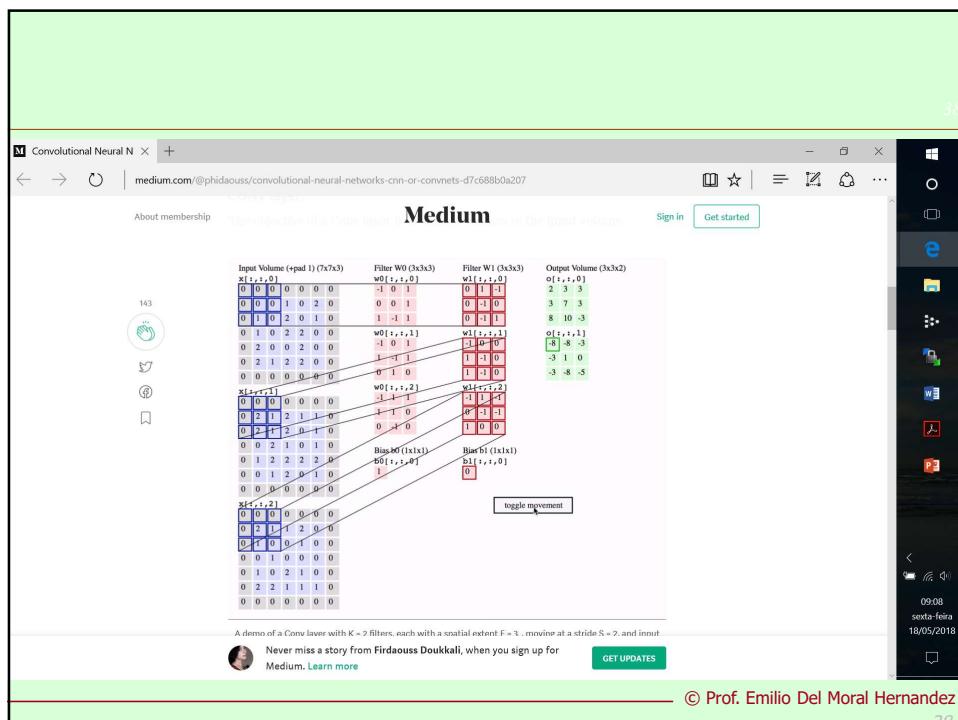
This article will present my brief notes about the elements that constitute Convolutional Neural Networks.

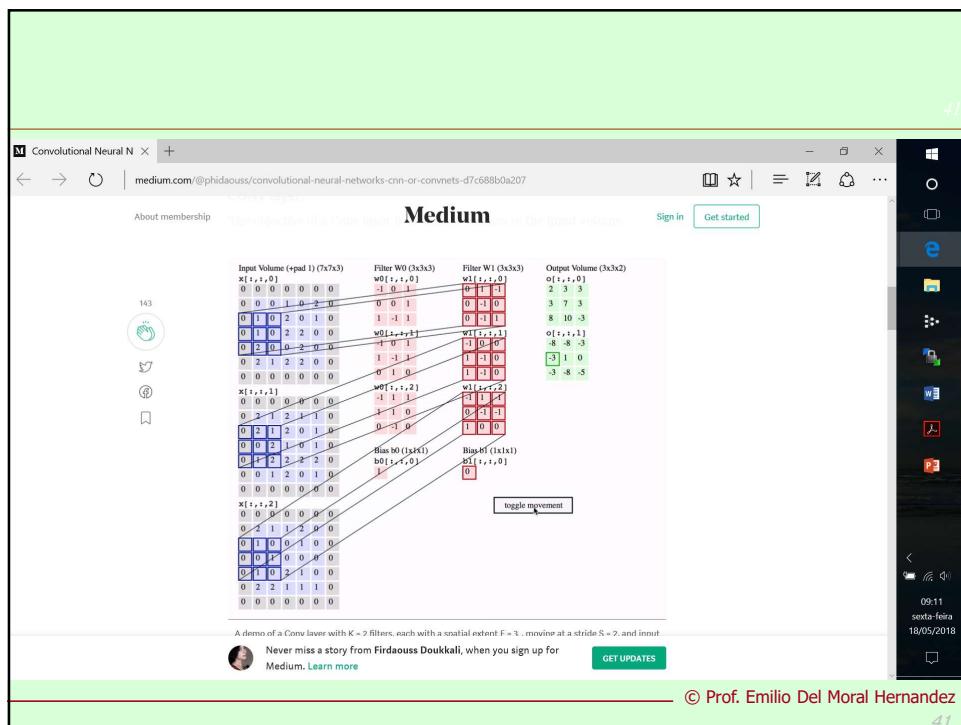
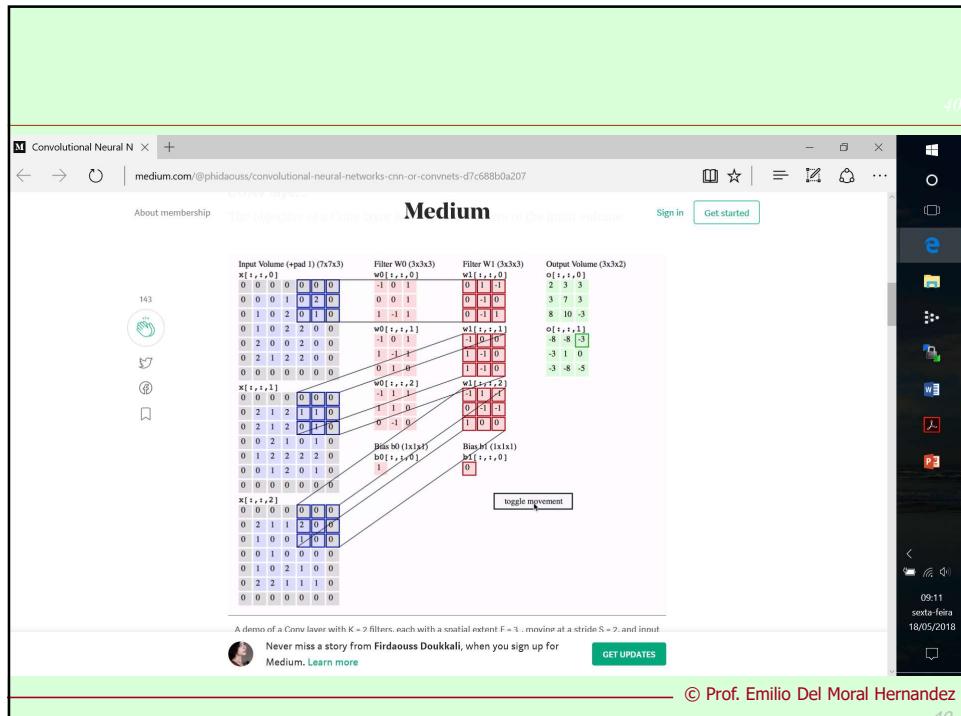
ConvNet has two parts: feature learning (Conv, Relu, and Pool) and classification (FC and softmax).

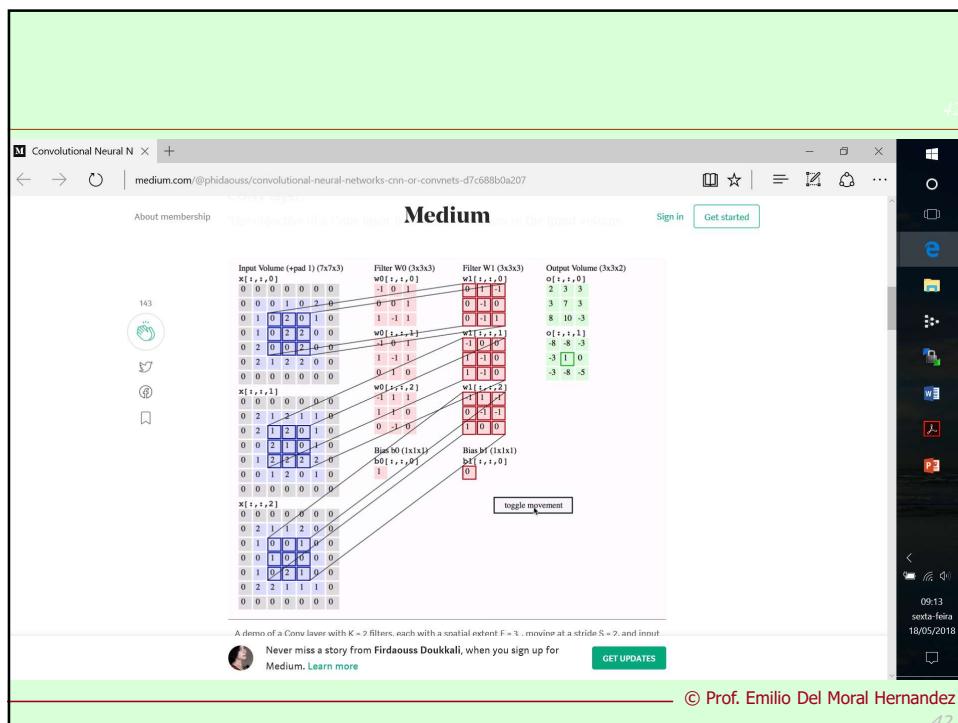
Never miss a story from Firdaouss Doukkali, when you sign up for Medium. [Learn more](#) [GET UPDATES](#)

11:15 quarta-feira
23/05/2018

© Prof. Emilio Del Moral Hernandez





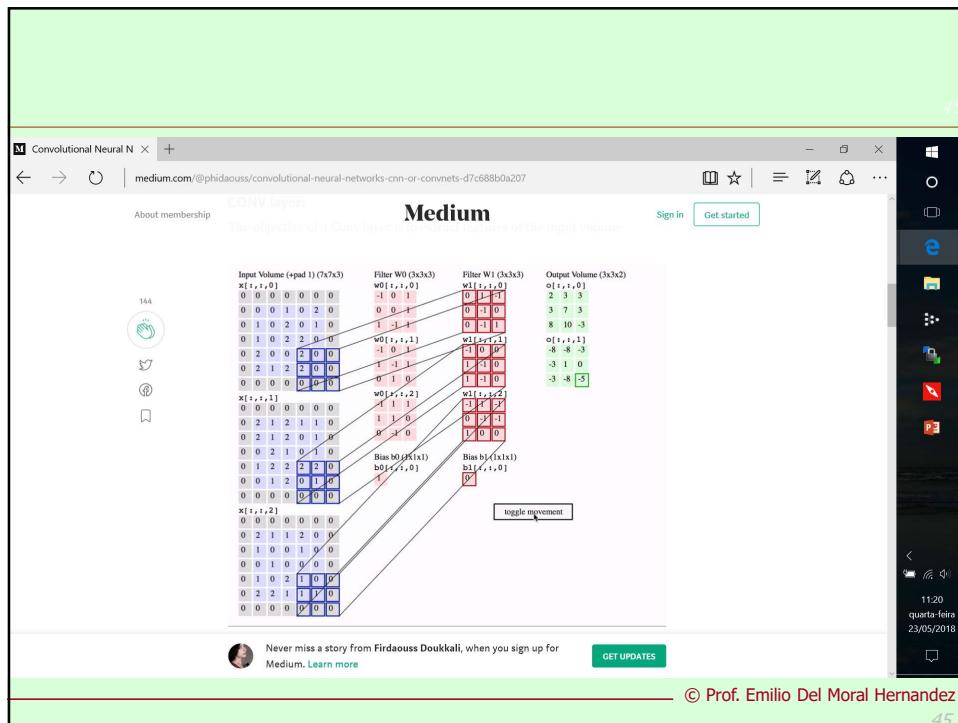
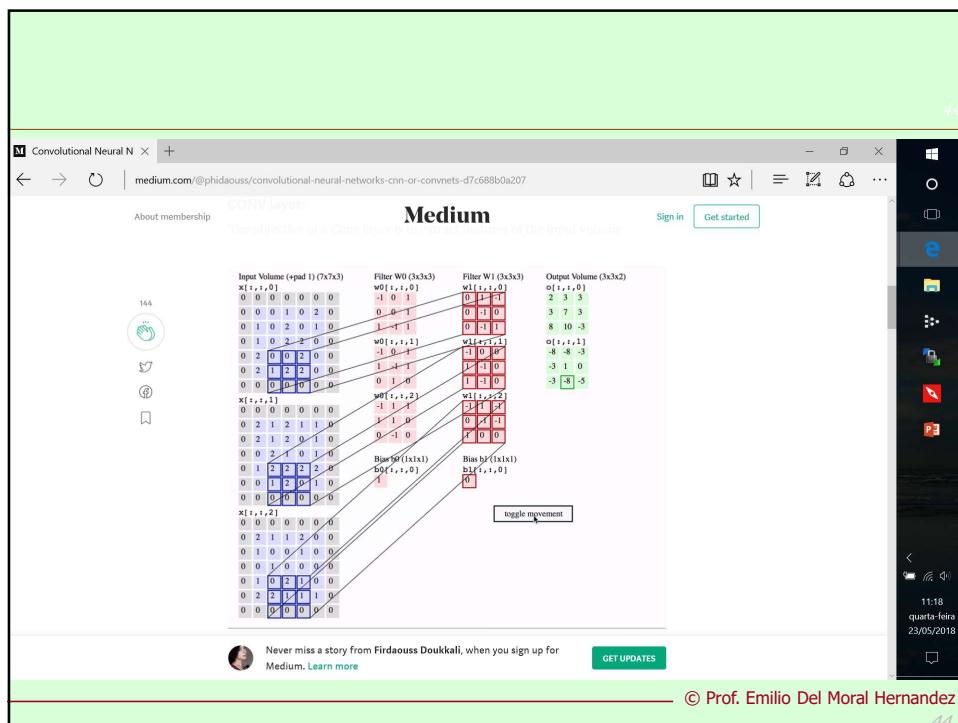


43

... até que a imagem toda seja varrida por um mesmo “filtro / template”.

© Prof. Emilio Del Moral Hernandez

43



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

48

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

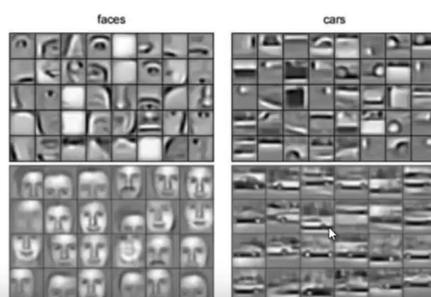
49

Teoria Redes Convolucionais

ConvNets - Convolução



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



2:42 / 18:25

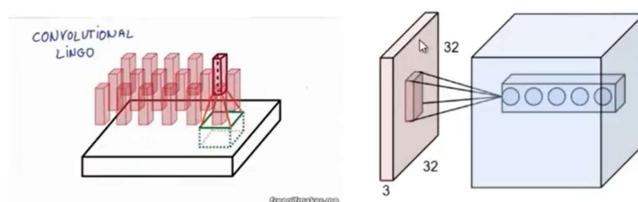
© Prof. Emilio Del Moral Hernandez

50

ConvNets – Convolução



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



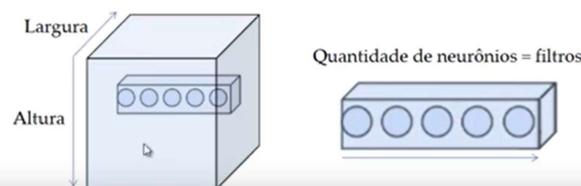
II ▶ 🔍 3:05 / 18:25 ⏹ (C) ⏹

© Prof. Emilio Del Moral Hernandez

ConvNets - Convolução



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

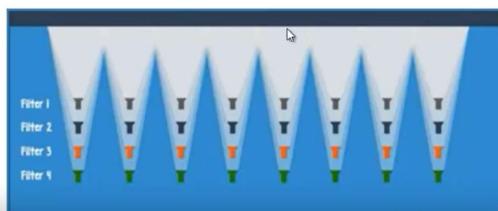


▶ 🔍 6:01 / 18:25 ⏹ (C) ⏹

© Prof. Emilio Del Moral Hernandez

Teoria Redes Convolucionais

ConvNets – Convolução



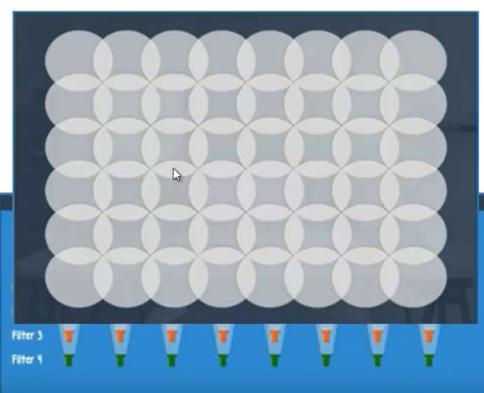
6:59 / 18:25



© Prof. Emilio Del Moral Hernandez

Teoria Redes Convolucionais

ConvNets – Convolução



7:34 / 18:25



© Prof. Emilio Del Moral Hernandez

54

Teoria Redes Convolucionais

ConvNets - Convolução

Hiperparâmetros da camada de convolução

- F = Tamanho do filtro – $F \times F$
- S = Stride – Deslocamento de pixels do filtro na convolução
- K = Quantidade de filtros
- W = Tamanho da entrada – $W \times W$
- P = Zero-Padding – Adiciona zeros na periferia das imagens

Área da Saída!

$$\frac{W - F + 2P}{S} + 1$$

9:26 / 18:25

© Prof. Emilio Del Moral Hernandez

54

55

Teoria Redes Convolucionais

ConvNets – Demais Camadas

Existem outras camadas típicas nas redes convolucionais:

- ReLUs – Rectified Linear Units
- Pooling
- Fully Connected – Layer

11:39 / 18:25

© Prof. Emilio Del Moral Hernandez

55

ConvNets - ReLUs



Camada que aplica operação linear matricial para descartar os valores negativos da convolução entre os filtros e a imagem

Rectified Linear Units (ReLUs)



▶ ▶ ⏴ 12:06 / 18:25 ⏴ ⏴ ⏴

⋮ ⏴ ⏴ ⏴

© Prof. Emilio Del Moral Hernandez

56

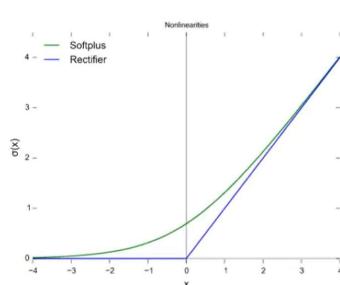
ConvNets - ReLUs



Função de Ativação

$$\hat{f}(x) = \max(0, x)$$

$$f(x) = \begin{cases} x & \text{if } x > 0 \\ 0.01x & \text{otherwise} \end{cases}$$



▶ ▶ ⏴ 12:18 / 18:25 ⏴ ⏴ ⏴

⋮ ⏴ ⏴ ⏴

© Prof. Emilio Del Moral Hernandez

57

ConvNets – Pooling Layer



Camada responsável em identificar os filtros ativados, descartando os valores insignificantes – Diminui as dimensões ao longo da rede.

Pooling

0.77	-0.11	0.11	0.33	0.55	-0.11	0.33
-0.11	1.00	-0.11	0.33	-0.11	0.11	-0.11
0.11	-0.11	1.00	-0.33	0.11	-0.11	0.55
0.33	0.33	-0.33	0.55	-0.33	0.33	0.33
0.55	-0.11	0.11	-0.33	1.00	-0.11	0.11
-0.11	0.11	-0.11	0.33	-0.11	1.00	0.11
0.33	-0.11	0.55	0.33	0.11	-0.11	0.77

max pooling

1.00	0.33	0.55	0.33
0.33	1.00	0.33	0.55
0.55	0.33	1.00	0.11
0.33	0.55	0.11	0.77

▶ ▶ ⏴ 13:34 / 18:25 ⏵ ⏵ ⏵ ⏵

🕒 🔍 ⌂

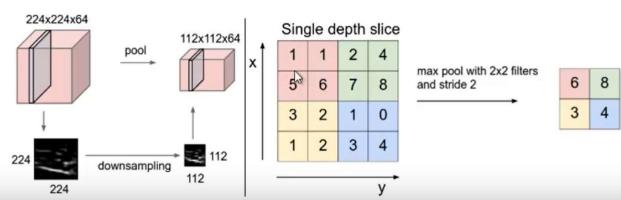
© Prof. Emilio Del Moral Hernandez

58

ConvNets – Pooling Layer



- Camadas com filtros 2×2 ($F = 2$) deslocando dois pixels ao longo da imagem ($S = 2$)
- De cada janela, extrai-se o maior número
- Realizam downsampling nas imagens



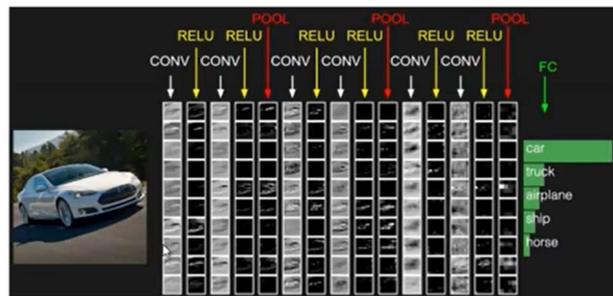
▶ ▶ ⏴ 14:55 / 18:25 ⏵ ⏵ ⏵ ⏵

🕒 🔍 ⌂

© Prof. Emilio Del Moral Hernandez

59

Topologia Típica



▶ ▶ ⏴ 17:20 / 18:25

⋮ ⚙ ⚙

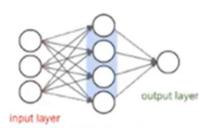
© Prof. Emilio Del Moral Hernandez

61

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:



▶ ▶ ⏴ 16:48 / 18:25

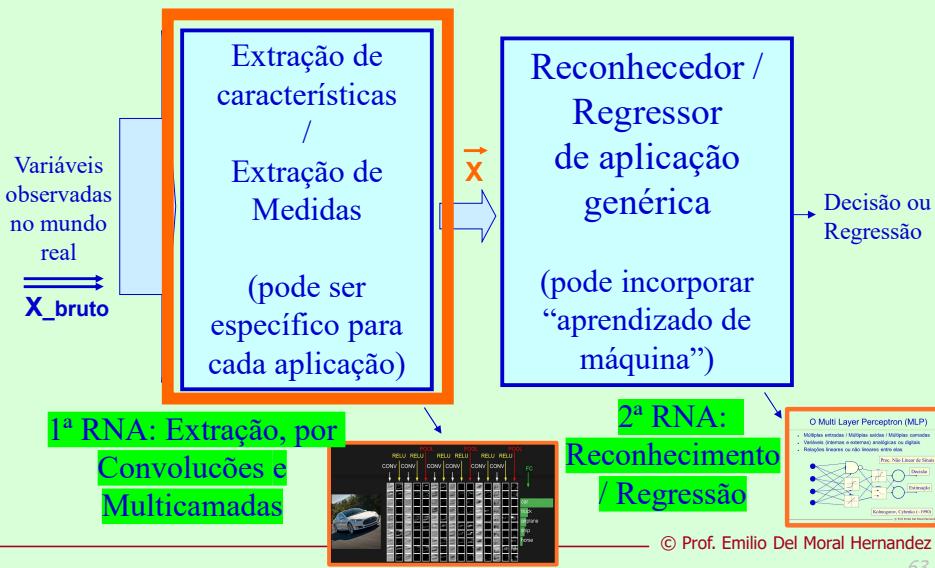
⋮ ⚙ ⚙

© Prof. Emilio Del Moral Hernandez

62

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

63



63

Sugiro fortemente aproveitar este vídeo de 18mins, sobre as ConvNets / CNNs

64

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

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

64

Para refletir e elaborar em escrito ...

66

Vários dos elementos construtivos / de arquitetura e de treinamento e operação / inferência em uma ConvNN como a apresentada, estão diretamente relacionados com tudo o aprendido nas 12 aulas anteriores ... Elenque (e elabore) ao menos um elemento ou dois para cada aula!

© Prof. Emilio Del Moral Hernandez

66

— Aulas do Prof Emilio em PSI3471 da #1 (em 02/março) à #13 (e 22/abril) —

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

#1 (02/março – 2#f) Conceitos em regressão linear e não linear. Regressão univariada e Regressão multivariada; Contrastes com técnica mais simples já conhecida: a regressão linear univariada (reta média). Diferenças principais entre 1) a Regressão e 2) o Reconhecimento / Detecção / Identificação de Padrões Multivariados. Conceitos em Reconhecimento / Detecção / Identificação de Padrões. Entendendo primeiro as ferramentas de modelagem mais simples: as ferramentas lineares mutivariadas ... elementos matemáticos em regressão linear multivariada e em discriminadores lineares multivariados. Dados empíricos para calibração de parâmetros em regressores e em discriminadores; o aprendizado supervisionado.
#2 (04/março – 4#f) Neurônios biológicos como base para os neurônios artificiais; equações e propriedades matemáticas do neurônio artificial isolado; relação do neurônio isolado com os regressores e com os discriminadores lineares multivariados.
#3 (09/março – 2#f) Foco nas Redes de Neurônios Artificiais (RNAs) concatenando múltiplos neurônios; arquiteturas neurais diversas; arquiteturas MLP – Multi Layer Perceptron; Relação de RNAs com a implementação de regressores e reconhecedores NÃO LINEARES MULTIVARIADOS. O ensaio computacional de redes neurais – ambientes simples como o MBP – Multiple Back Propagation – e ambientes mais complexos alternativos, de sua escolha.
#4 (11/março – 4#f) Grafos da computação em redes neurais do tipo MLP; notação matemática para pesos sinápticos, variáveis de entrada, saída e variáveis intermediárias no MBP; exemplares empíricos / observações empíricas para o treinamento supervisionado em MLPs; aprendizado com base na propagação reversa do erro (EBP – Error Back Propagation).

© Prof. Emilio Del Moral Hernandez

67

#5 (16/março – 2 ^º f) Foco no aprendizado da Rede Neural MLP – O Gradiente descendente e a otimização de pesos sinápticos com base no conjunto de treino e EBP; dedução das fórmulas do EBP, em sala de aula e em conjunto com os alunos: trabalho focado num peso sináptico específico da rede, escolhido pelo professor para máxima complexidade da dedução.
#6 (18/março – 4 ^º f) Discussão da extensão simples das deduções do EBP para demais pesos sinápticos; redundâncias nos cálculos dos diversos pesos da rede neural e otimização do esforço computacional. Regra “Delta” de aprendizado de Widrow, para neurônio isolado; Aprendizado por EBP recursivo, camada a camada.
#7 (23/março – 2 ^º f) Foco em Reconhecedores – Circuitos lógicos genéricos e suas implementações através de computação neural; relação com discriminadores. Construindo reconhecedores de padrões com fronteiras de separação genéricas: separadores lineares; bancos de separadores lineares como aproximadores efetivos de fronteiras genéricas.
#8 (25/março – 4 ^º f) Técnicas de medida de qualidade em reconhecedores de padrões: matriz de confusão, conceitos de falsos positivo e negativo, especificidade e sensibilidade. Curvas ROC.
#9 (30/março – 2 ^º f) Foco agora em Regressores - Casos simples de aproximação de funções univariadas. Teorema de Cybenko: o MLP como aproximador universal de funções multivariadas; implicações práticas do teorema para a implementação de regressores e reconhecedores de padrões não lineares multivariados genéricos.
#10 (01/abril – 4 ^º f). Medidas de qualidade diversificadas para regressores multivariados (distintas do erro quadrático médio); Flutuação do desempenho do modelo com as particulares amostras de treino e de teste e técnicas de reamostragem; técnica de validação cruzada, k-fold cross validation e leave one out. Sobreajuste / sobreaprendizado / perda de generalização em regressão polinomial e em redes neurais; limitação do número de nós neurais para evitar o sobreajuste e otimizar a generalização da rede neural; partição do volume de observações em conjuntos de treino, validação e teste.

06 e 08 de abril: Semana Santa – não há aula

© Prof. Emilio Del Moral Hernandez

06 e 08 de abril: Semana Santa – não há aula
#11 (13/abril – 2 ^º f) Soluções em reconhecimento e em regressão empregando dois estágios: primeiro estágio para extração de características / extração de medidas e para a redução de dimensionalidade + segundo estágio MLP como reconhecedor / regressor genérico; técnicas diversas de extração de características em projetos concretos. Extensões de análise harmônica (Fourier) para a extração de características; conceitos básicos em análise tempo-frequência. PCA - Análise de Componentes Principais como extrator de características.
#12 (15/abril – 4 ^º f) Aprofundando a conexão dos temas que aprendemos com o Deep Learning: conexão com redes neurais convolucionais; camadas convolucionais, Autoencoders e Autoencoders em cascata como extractores de características e redutores de dimensionalidade. Apanhado das temáticas aprendidas e troca de ideias sobre a “A4 de consulta” + sessão de dúvidas p/ P1;
22 de abril (4 ^º f) e 27 de abril (2 ^º f): P1 em PS13471 – ou seja, dentro da semana de provas P1 da Elétrica (em 20 de abril, pela ponte de Tiradentes, não há aula na 2 ^º feira)
#13 (22/abril – 4 ^º f) 1) Parte das temáticas e atividades desta aula após a P1 serão definidas mais adiante no semestre, de acordo com a evolução das aulas anteriores; 2) Conexão do aprendido até o momento com as próximas temáticas no curso.

© Prof. Emilio Del Moral Hernandez