Algumas respostas em reconhecimento de padrões e processamento de informação sendo dadas com ferramentas de Deep Learning

36

Uma técnica <u>neural</u> 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 Autoeconders (vários auto-codificadores encadeados) –

37

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

Variáveis observadas no mundo real

X_bruto

Extração de características / Extração de Medidas (pode ser específico para cada aplicação)	$\vec{X}$	Reconhecedor / Regressor de aplicação genérica (pode incorporar "aprendizado de máquina")	Decisão ou Regressão

© Prof. Emilio Del Moral Hernandez

38

Um autoencoder detalhado
(imagem da internet, adaptada)

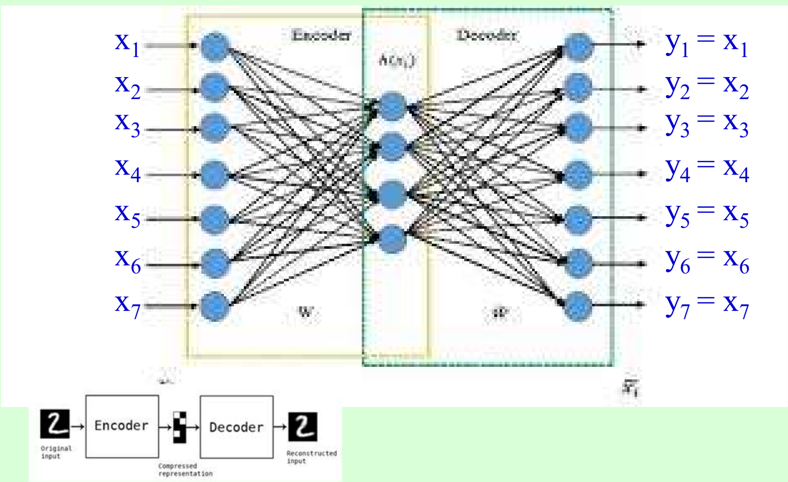

Um pouquinho de Deep Learning

© Prof. Emilio Del Moral Hernandez

40

Um autoencoder detalhado (imagem da internet, adaptada)

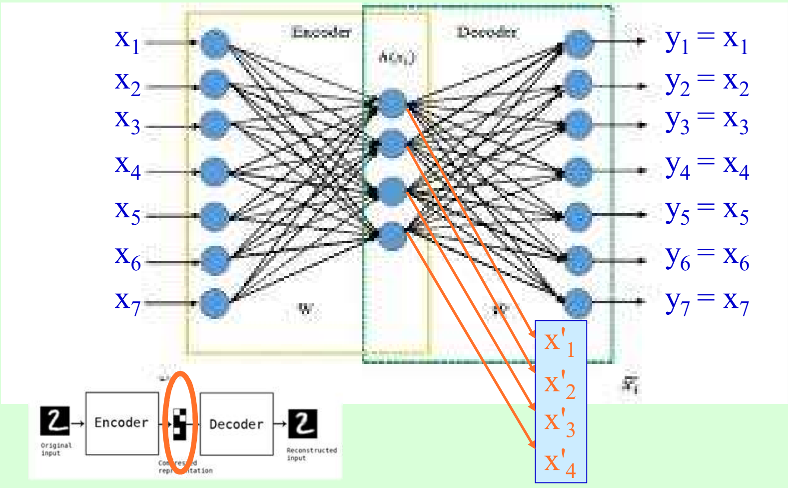

Algumas ferramentas em Deep Learning

41

Um autoencoder detalhado (imagem da internet, adaptada)

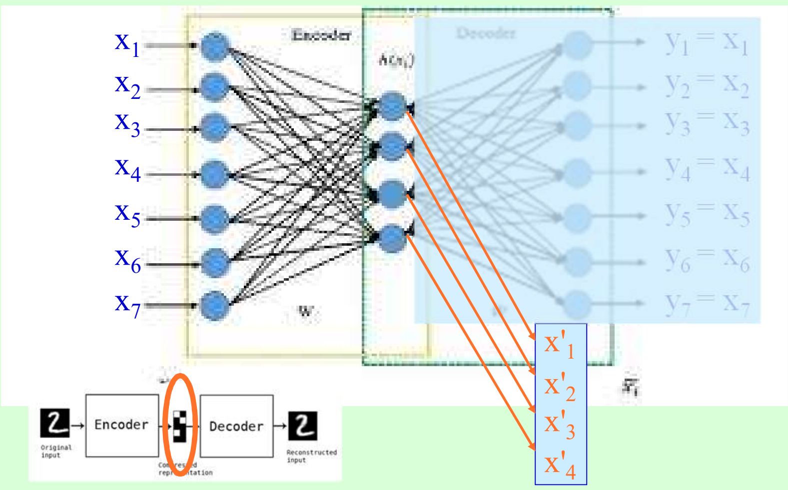

Algumas ferramentas em Deep Learning

42

Autoencoders e Stacked Auto-encoders
(imagens da internet)

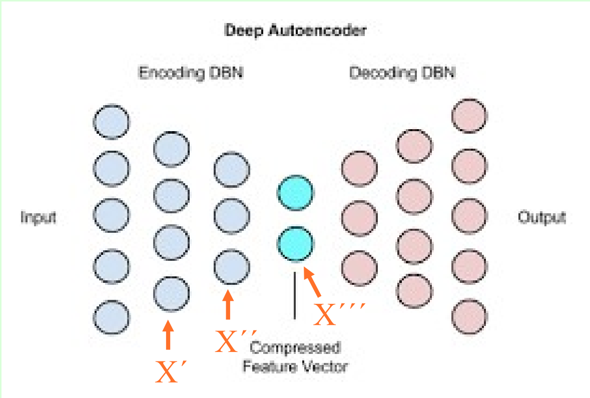

Algumas ferramentas em Deep Learning

43

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.

44

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

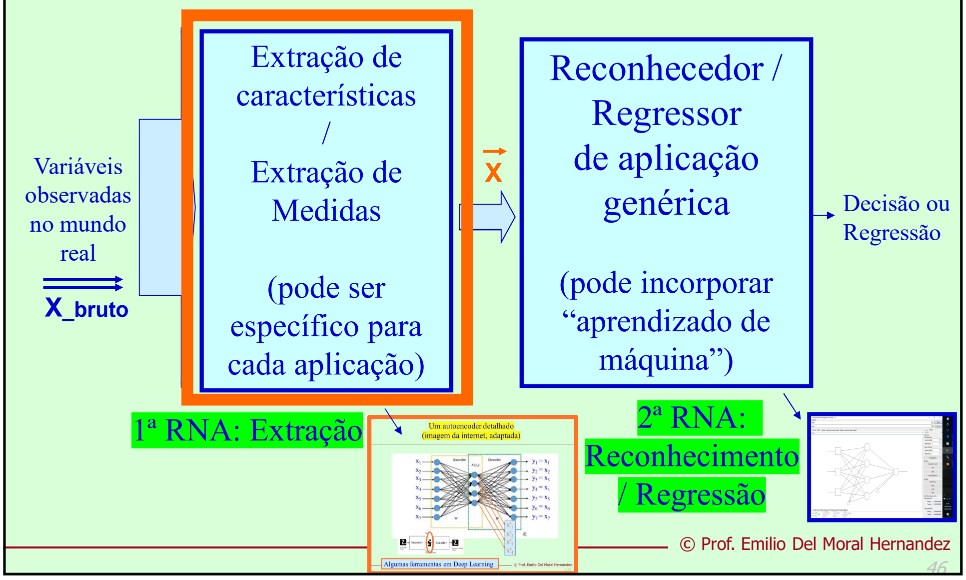

46

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 sobreaprednizado em aplicações de alta dimensão de entrada

47

Mark Cappello Ferreira de Sousa

Classificação em Redes Neurais Convolucionais

Convoluções
(Extração de características)

Fully Connected
(MLP)

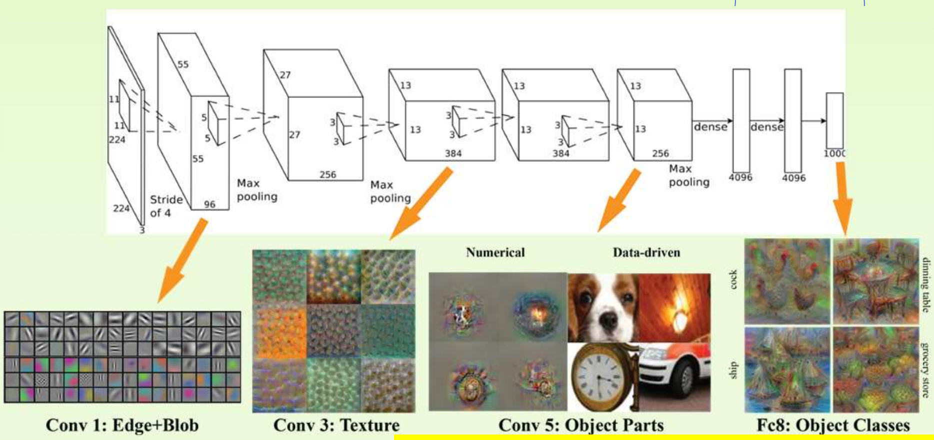

figuras ilustrativas – extraídas da internet

48

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

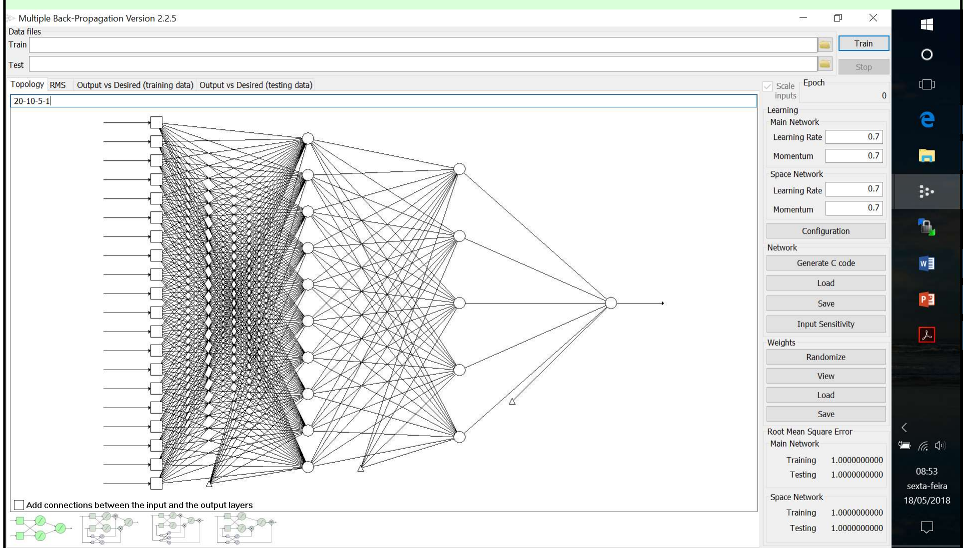

© Prof. Emilio Del Moral Hernandez

51

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

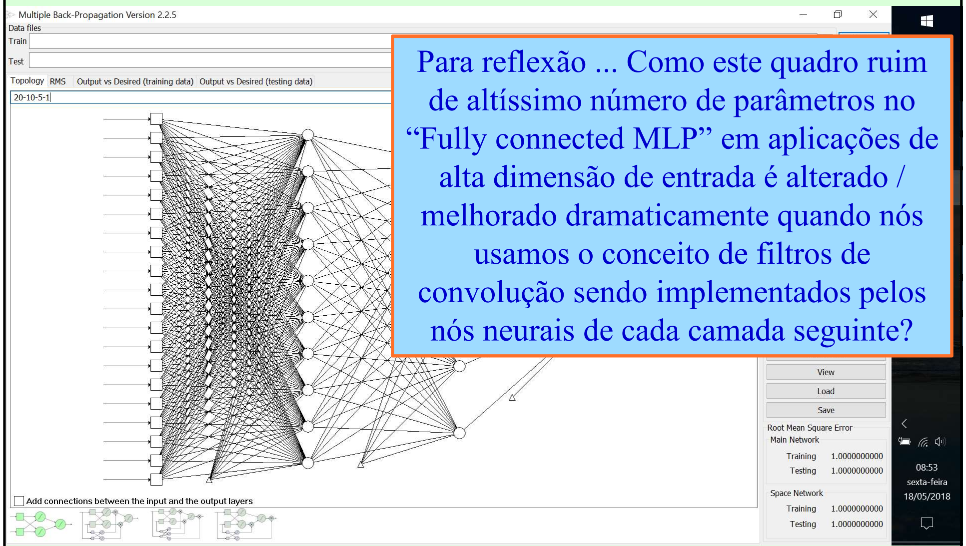

Para reflexão ... Como este quadro ruim de altíssimo número de parâmetros no “Fully connected MLP” em aplicações de alta dimensão de entrada é alterado / melhorado dramaticamente quando nós usamos o conceito de filtros de convolução sendo implementados pelos nós neurais de cada camada seguinte?

52

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

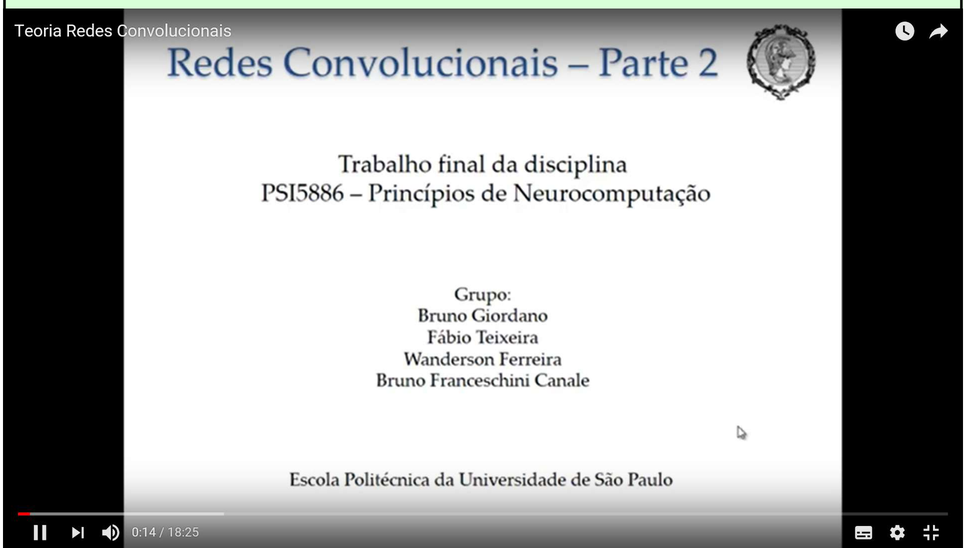

53


Teoria Redes Convolucionais
ConvNets - Convolução
• As redes convolucionais aplicam filtros ao longo da imagem, procurando representações características para então classificá-las
faces
cars
2:42 / 18:25

54

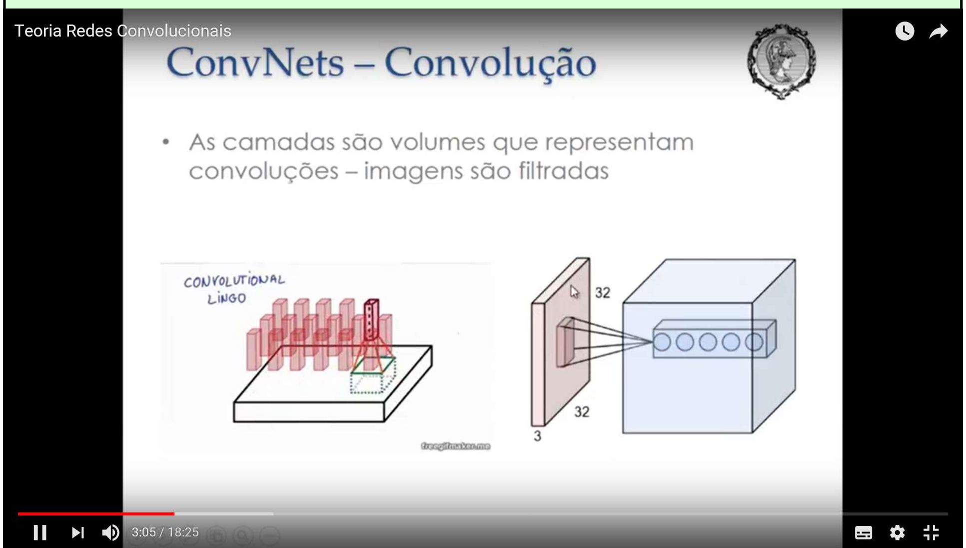
Teoria Redes Convolucionais
ConvNets – Convolução
• As camadas são volumes que representam convoluções – imagens são filtradas
CONVOLUTIONAL
LINGO
32
32
3
3:05 / 18:25

55

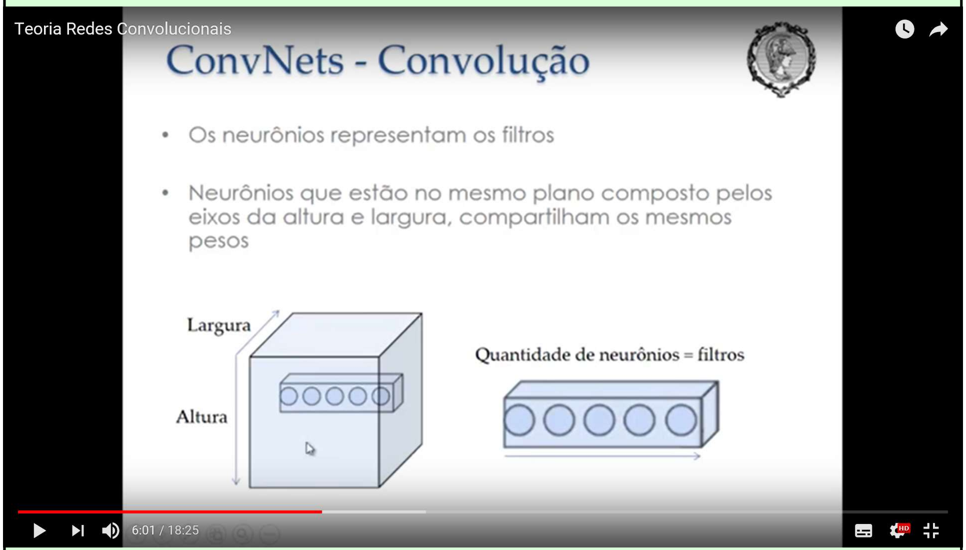
Teoria Redes Convolucionais
ConvNets - Convolução
• Os neurônios representam os filtros
• Neurônios que estão no mesmo plano composto pelos eixos da altura e largura, compartilham os mesmos pesos
Largura
Altura
Quantidade de neurônios = filtros
6:01 / 18:25

56

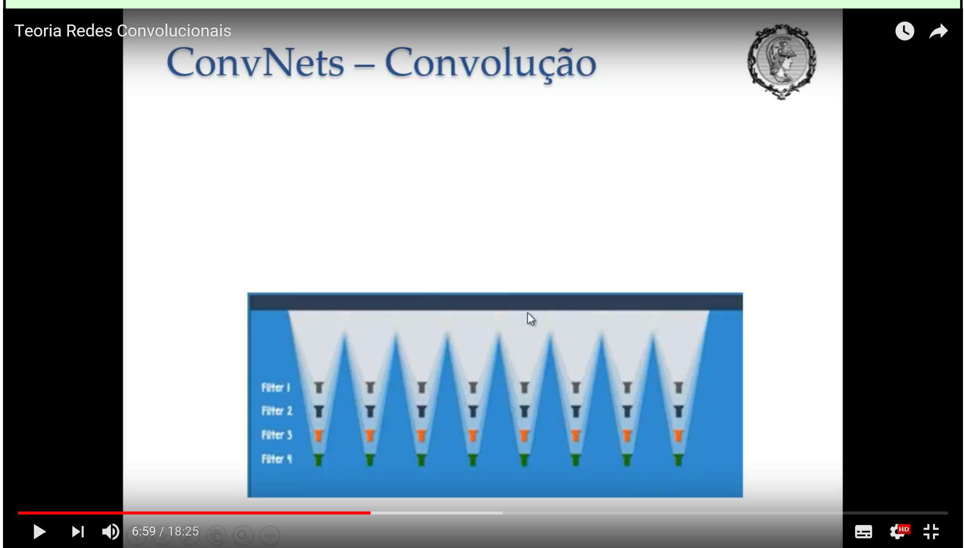
Teoria Redes Convolucionais
ConvNets – Convolução
Filter 1
Filter 2
Filter 3
Filter 4
6:59 / 18:25

57

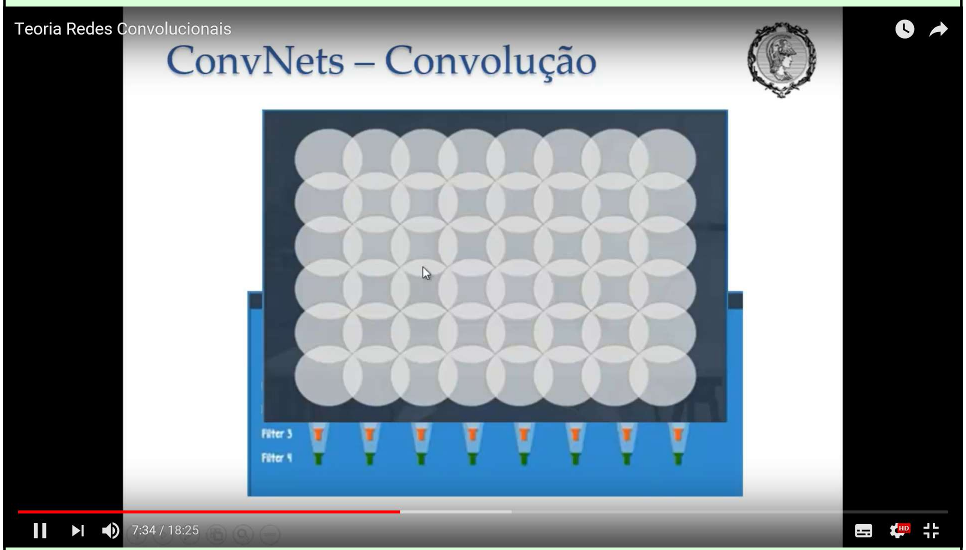
Teoria Redes Convolucionais
ConvNets – Convolução
Filter 3
Filter 4
7:34 / 18:25

58

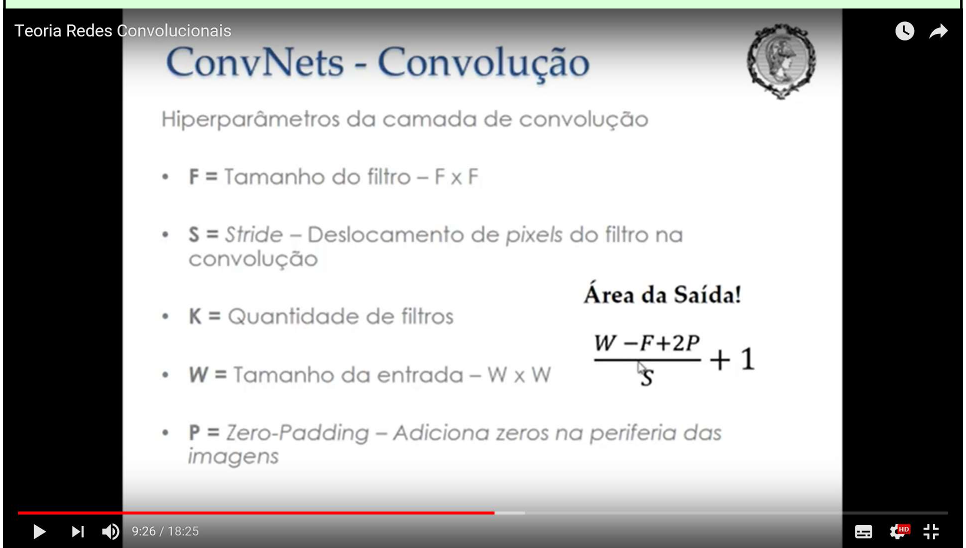
Teoria Redes Convolucionais
ConvNets - Convolução
Hiperparâmetros da camada de convolução
F = Tamanho do filtro – F x F
S = Stride – Deslocamento de pixels do filtro na convolução
K = Quantidade de filtros
W = Tamanho da entrada – W x W
P = Zero-Padding – Adiciona zeros na periferia das imagens
Área da Saída!
$\frac{W - F + 2P}{S} + 1$
9:26 / 18:25

60

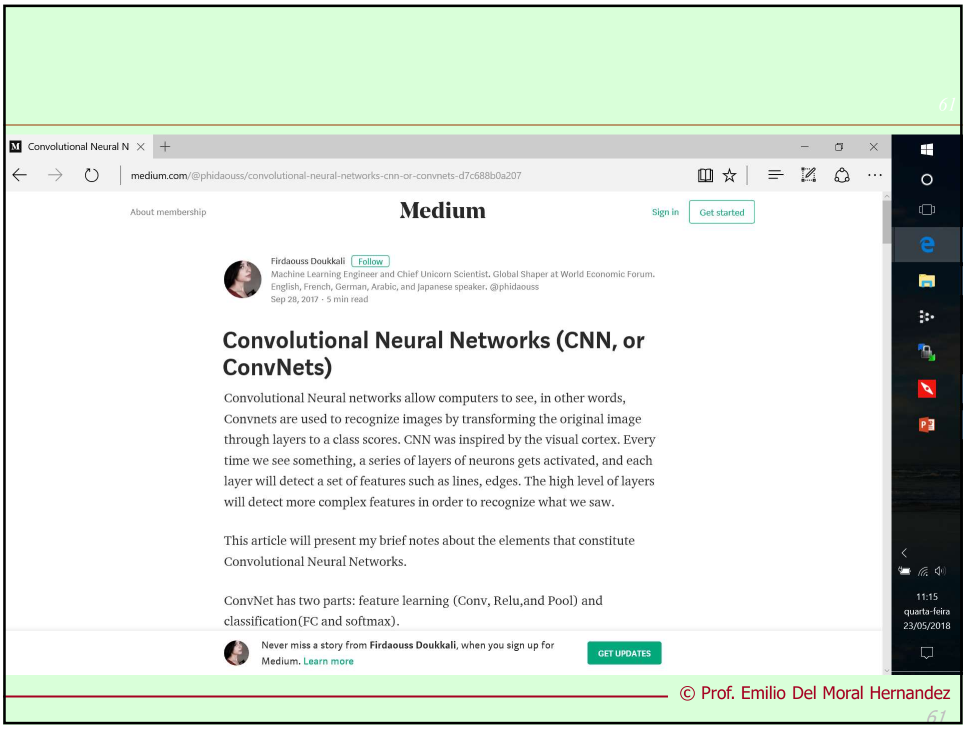

Convolutional Neural N
medium.com/@phidaouss/convolutional-neural-networks-cnn-or-convnets-d7c688b0a207
About membership
Medium
Sign in
Get started
Firdaouss Doukkali Follow
Machine Learning Engineer and Chief Unicorn Scientist. Global Shaper at World Economic Forum. English, French, German, Arabic, and Japanese speaker. @phidaouss
Sep 28, 2017 · 5 min read
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

61

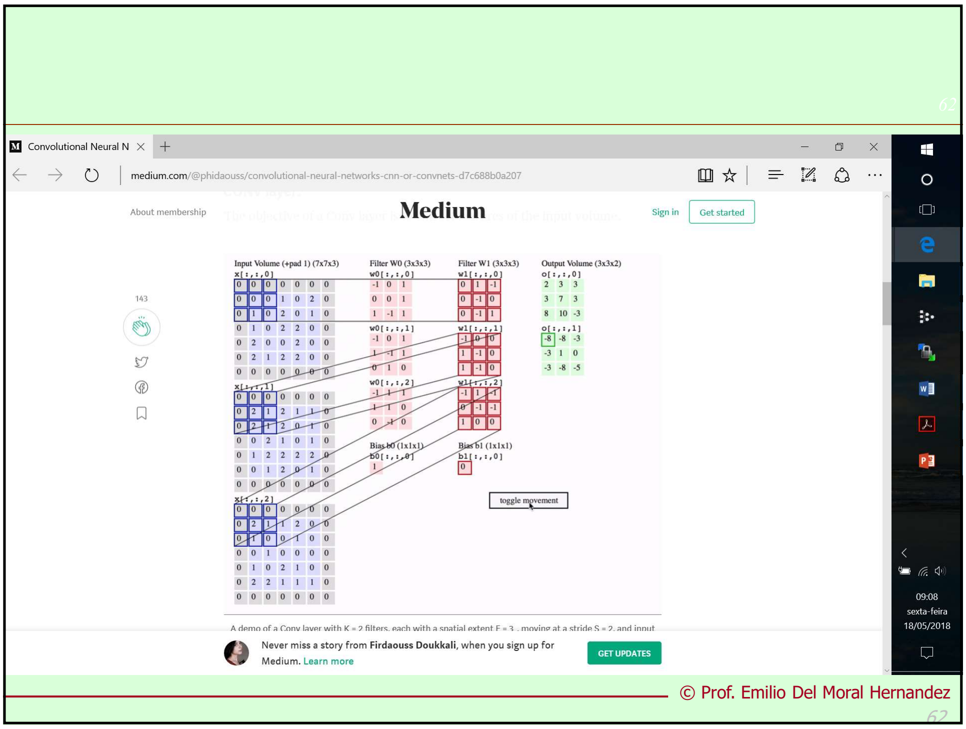

Convolutional Neural N
medium.com/@phidaouss/convolutional-neural-networks-cnn-or-convnets-d7c688b0a207
About membership
Medium
Sign in
Get started
Input Volume (+pad 1) (7x7x3)
Filter W0 (3x3x3)
Filter W1 (3x3x3)
Output Volume (3x3x2)
Bias b0 (1x1x1)
Bias b1 (1x1x1)
toggle movement
143
Never miss a story from Firdaouss Doukkali, when you sign up for Medium. Learn more
GET UPDATES
09:08
sexta-feira
18/05/2018
© Prof. Emilio Del Moral Hernandez

62

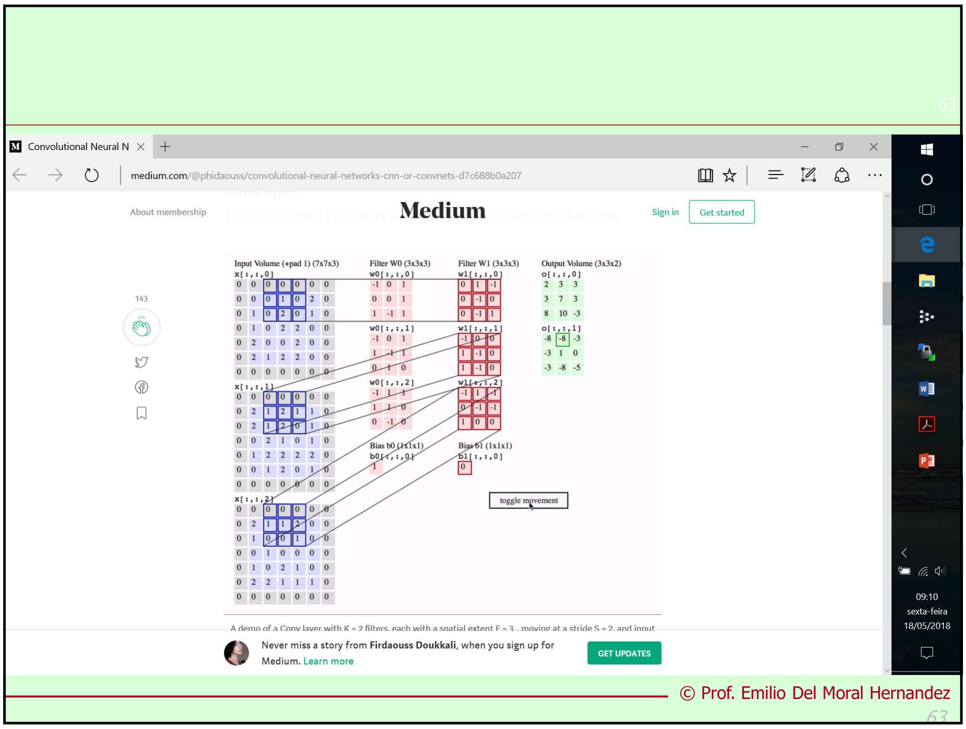
Convolutional Neural N
medium.com/@phidaouss/convolutional-neural-networks-cnn-or-convnets-d7c688b0a207
About membership
Medium
Sign in
Get started
Input Volume (+pad 1) (7x7x3)
Filter W0 (3x3x3)
Filter W1 (3x3x3)
Output Volume (3x3x2)
Bias b0 (1x1x1)
Bias b1 (1x1x1)
toggle movement
Never miss a story from Firdaouss Doukkali, when you sign up for Medium. Learn more
GET UPDATES
09:10
sexta-feira
18/05/2018
© Prof. Emilio Del Moral Hernandez

63

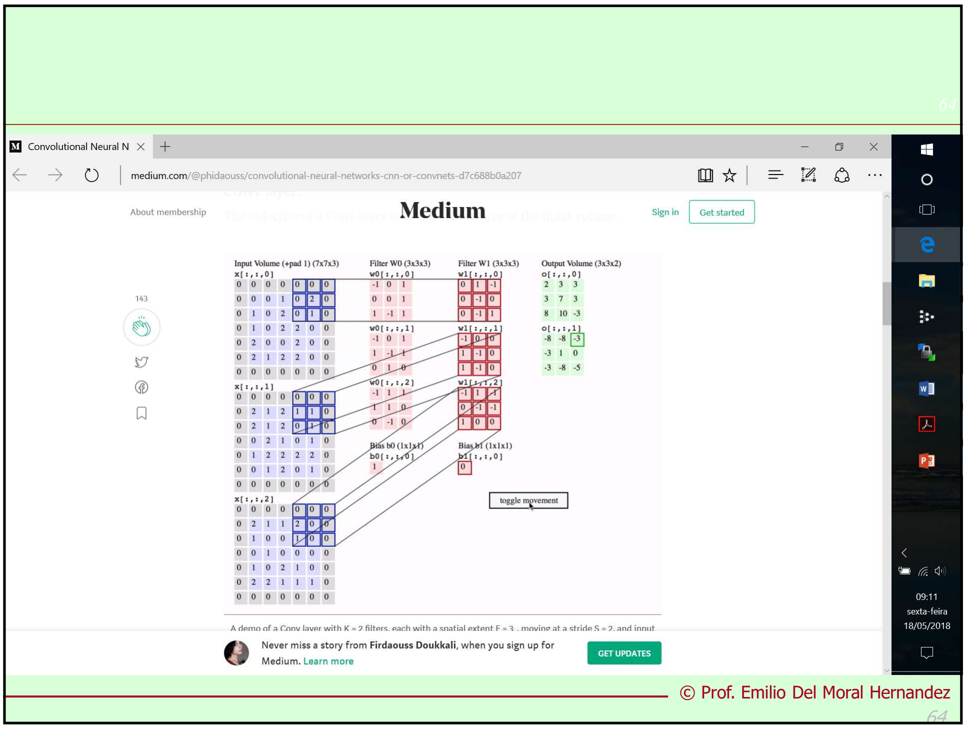
Convolutional Neural N
medium.com/@phidaouss/convolutional-neural-networks-cnn-or-convnets-d7c688b0a207
About membership
Medium
Sign in
Get started
Input Volume (+pad 1) (7x7x3)
Filter W0 (3x3x3)
Filter W1 (3x3x3)
Output Volume (3x3x2)
Bias b0 (1x1x1)
Bias b1 (1x1x1)
toggle movement
Never miss a story from Firdaouss Doukkali, when you sign up for Medium. Learn more
GET UPDATES
09:11
sexta-feira
18/05/2018
© Prof. Emilio Del Moral Hernandez

64

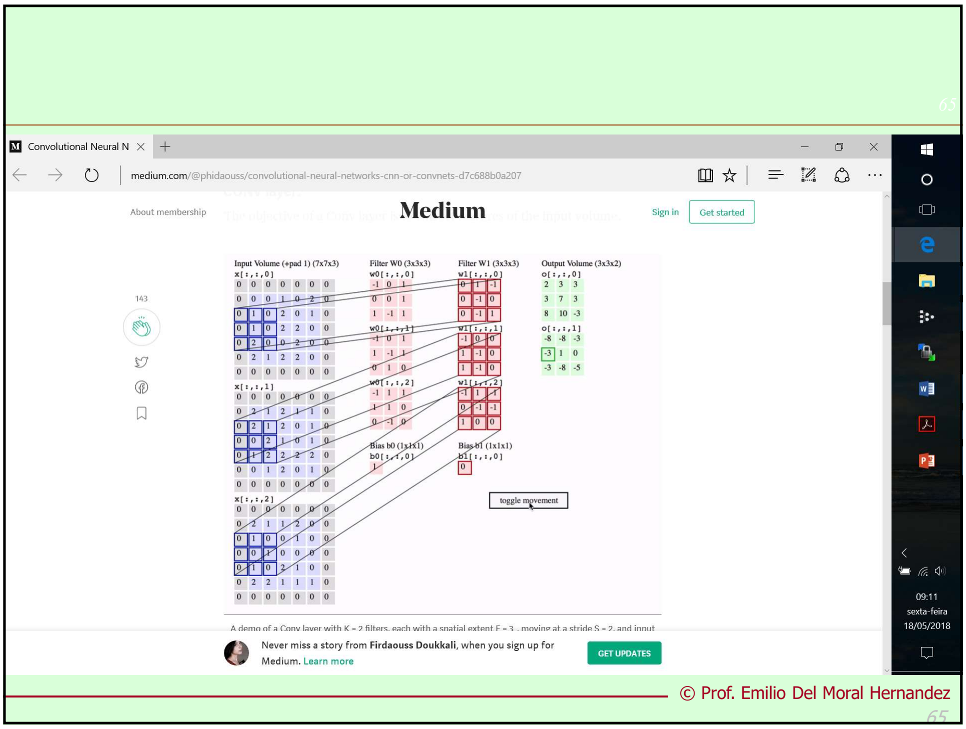
Convolutional Neural N
medium.com/@phidaouss/convolutional-neural-networks-cnn-or-convnets-d7c688b0a207
About membership
Medium
Sign in
Get started
Input Volume (+pad 1) (7x7x3)
Filter W0 (3x3x3)
Filter W1 (3x3x3)
Output Volume (3x3x2)
Bias b0 (1x1x1)
Bias b1 (1x1x1)
toggle movement
A demo of a Conv layer with K = 2 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
09:11
sexta-feira
18/05/2018
© Prof. Emilio Del Moral Hernandez

65

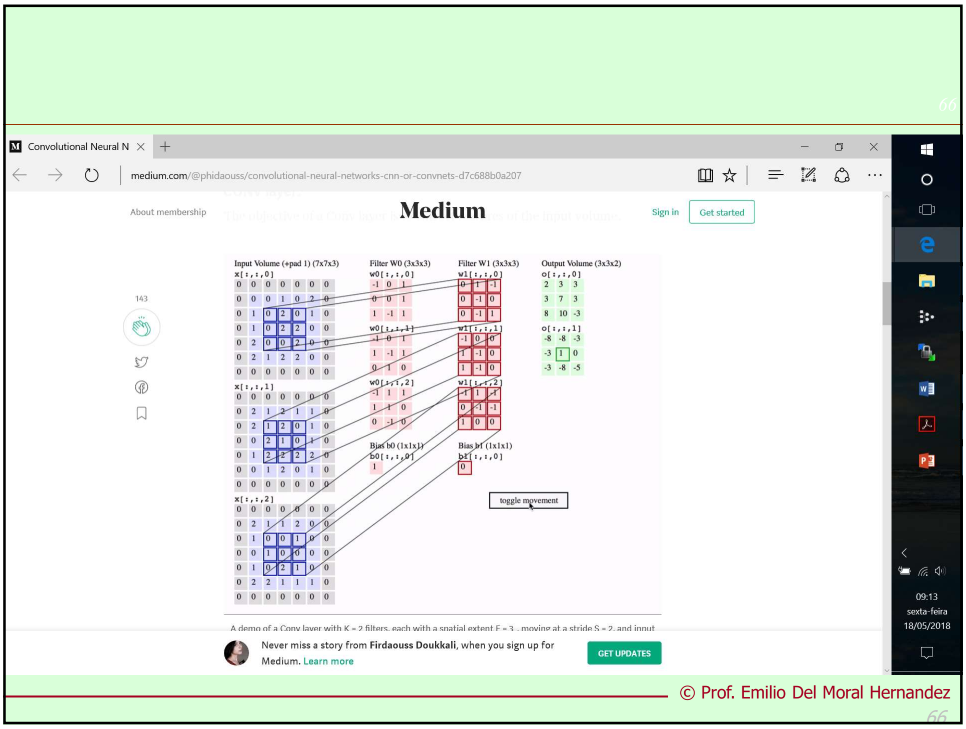
Convolutional Neural N
medium.com/@phidaouss/convolutional-neural-networks-cnn-or-convnets-d7c688b0a207
About membership
Medium
Sign in
Get started
Input Volume (+pad 1) (7x7x3)
Filter W0 (3x3x3)
Filter W1 (3x3x3)
Output Volume (3x3x2)
Bias b0 (1x1x1)
Bias b1 (1x1x1)
toggle movement
A demo of a Conv layer with K = 2 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
09:13
sexta-feira
18/05/2018
© Prof. Emilio Del Moral Hernandez

66

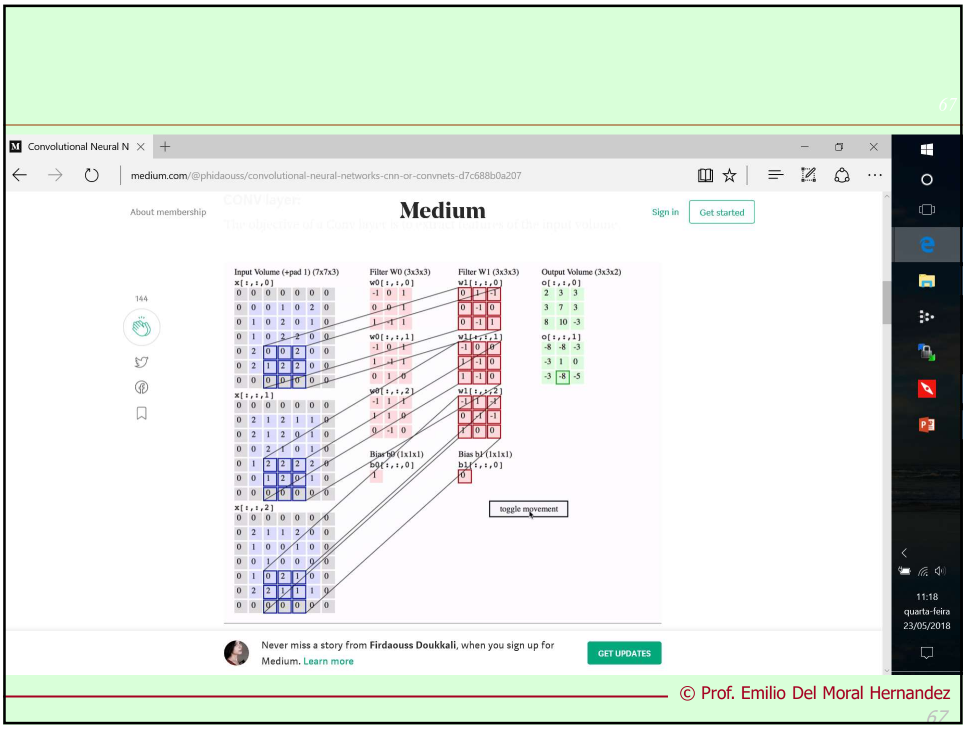
Convolutional Neural N
medium.com/@phidaouss/convolutional-neural-networks-cnn-or-convnets-d7c688b0a207
About membership
Medium
Sign in
Get started
Input Volume (+pad 1) (7x7x3)
Filter W0 (3x3x3)
Filter W1 (3x3x3)
Output Volume (3x3x2)
Bias b0 (1x1x1)
Bias b1 (1x1x1)
toggle movement
Never miss a story from Firdaouss Doukkali, when you sign up for Medium. Learn more
GET UPDATES
11:18
quarta-feira
23/05/2018
© Prof. Emilio Del Moral Hernandez

67

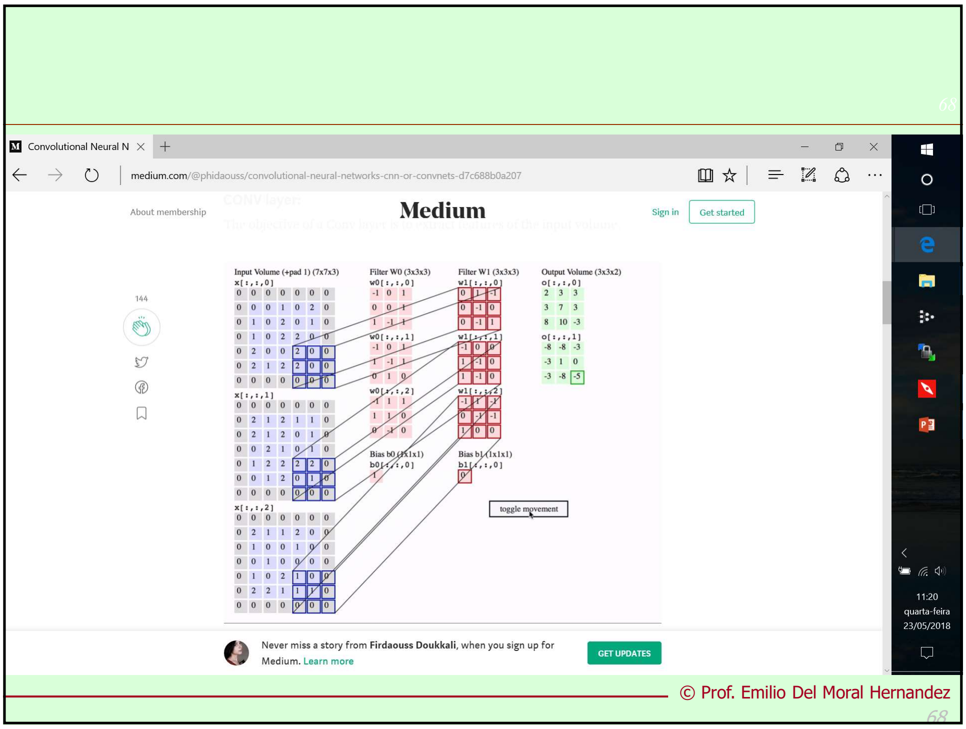
Convolutional Neural N
medium.com/@phidaouss/convolutional-neural-networks-cnn-or-convnets-d7c688b0a207
About membership
Medium
Sign in
Get started
Input Volume (+pad 1) (7x7x3)
Filter W0 (3x3x3)
Filter W1 (3x3x3)
Output Volume (3x3x2)
Bias b0 (1x1x1)
Bias b1 (1x1x1)
toggle movement
Never miss a story from Firdaouss Doukkali, when you sign up for Medium. Learn more
GET UPDATES
11:20
quarta-feira
23/05/2018
© Prof. Emilio Del Moral Hernandez

68

... a imagem toda é varrida por um mesmo filtro, que atua a cada passo da varredura num campo receptivo restrito dentro da imagem

69

um parênteses ...

... as CNNs 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)

71

Imagem 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

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

  - ou

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

  - * representa convolução

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

72

Imagem ilustrativa da internet – Sistemas SLIT

Resposta ao Impulso

- Seja o Sistema Linear Invariante no Tempo (LTI)

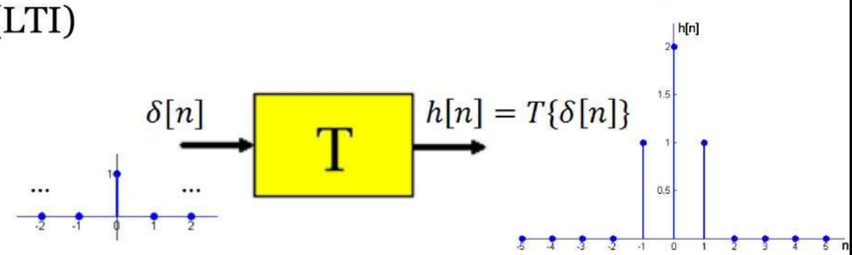

- h[n] – resposta ao impulso

73

Retomando ...

74

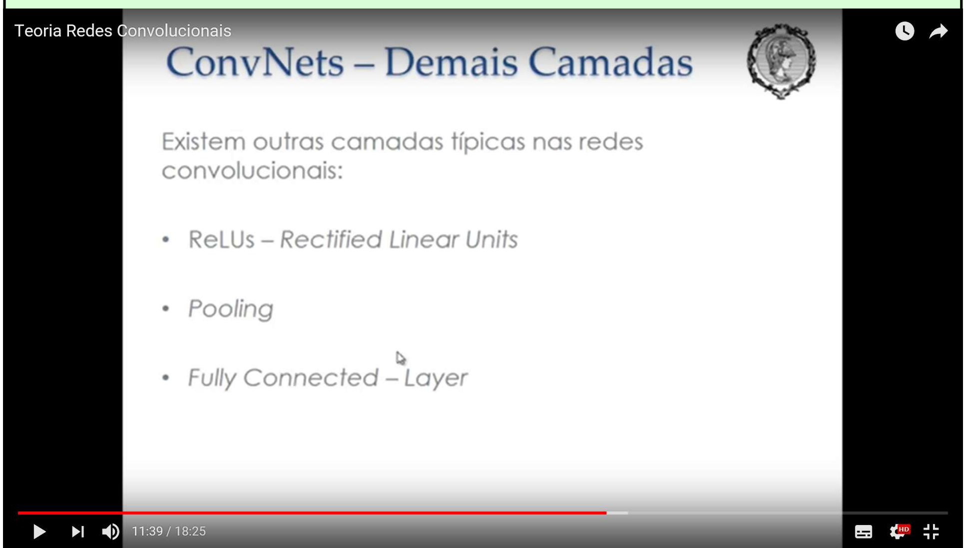

75


Teoria Redes Convolucionais
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

76

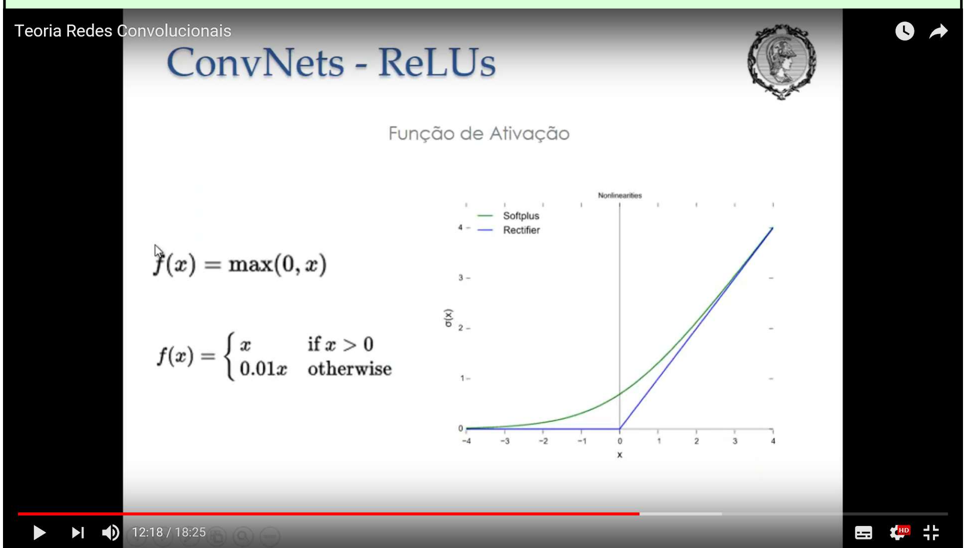
Teoria Redes Convolucionais
ConvNets - ReLUs
Função de Ativação
$f(x) = \max(0, x)$
$f(x) = \begin{cases} x & \text{if } x > 0 \\ 0.01x & \text{otherwise} \end{cases}$
Nonlinearities
Softplus
Rectifier
σ(x)
x
12:18 / 18:25

77

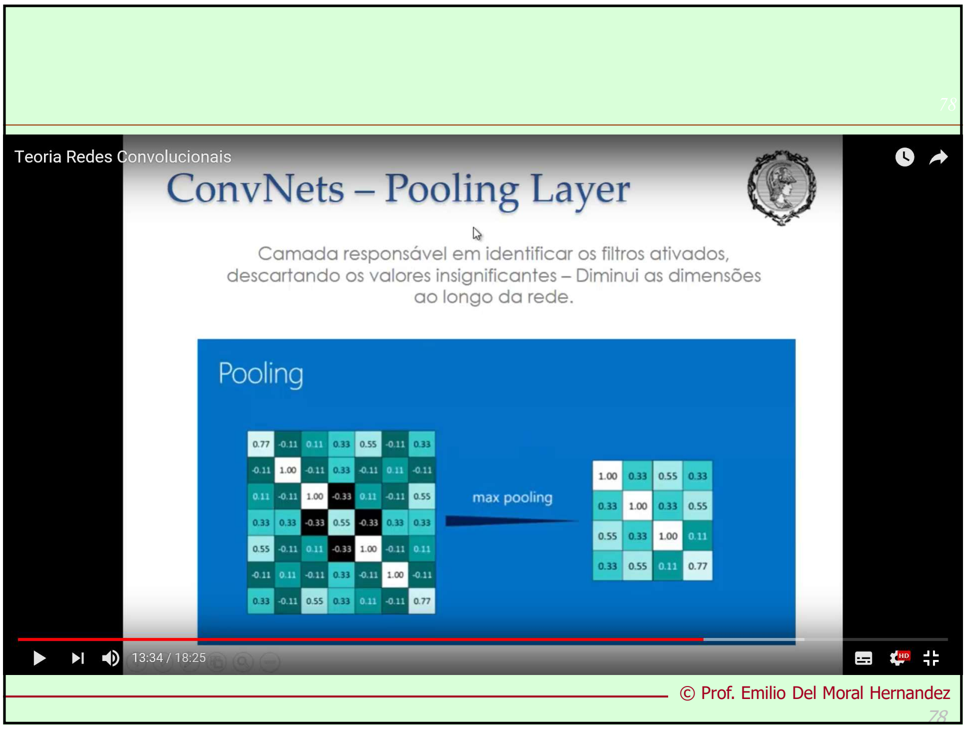
Teoria Redes Convolucionais
ConvNets – Pooling Layer
Camada responsável em identificar os filtros ativados, descartando os valores insignificantes – Diminui as dimensões ao longo da rede.
Pooling
max pooling
13:34 / 18:25
© Prof. Emilio Del Moral Hernandez

78

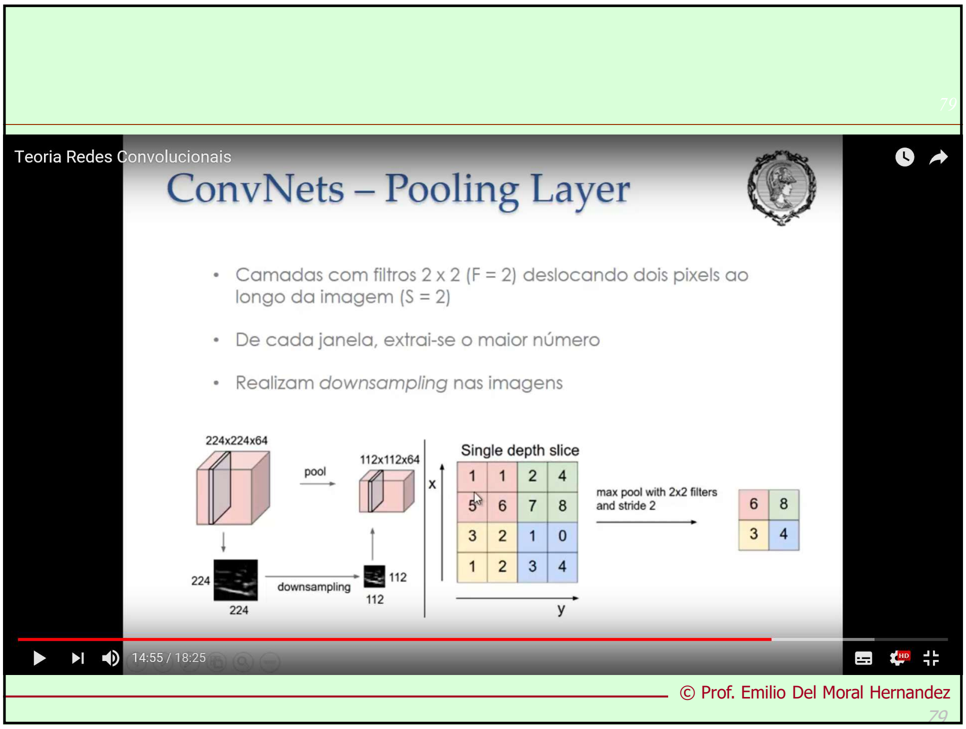
Teoria Redes Convolucionais
ConvNets – Pooling Layer
Camadas com filtros 2 x 2 (F = 2) deslocando dois pixels ao longo da imagem (S = 2)
De cada janela, extrai-se o maior número
Realizam downsampling nas imagens
224x224x64
pool
112x112x64
224
224
downsampling
112
112
Single depth slice
x
y
max pool with 2x2 filters and stride 2
14:55 / 18:25
© Prof. Emilio Del Moral Hernandez

79

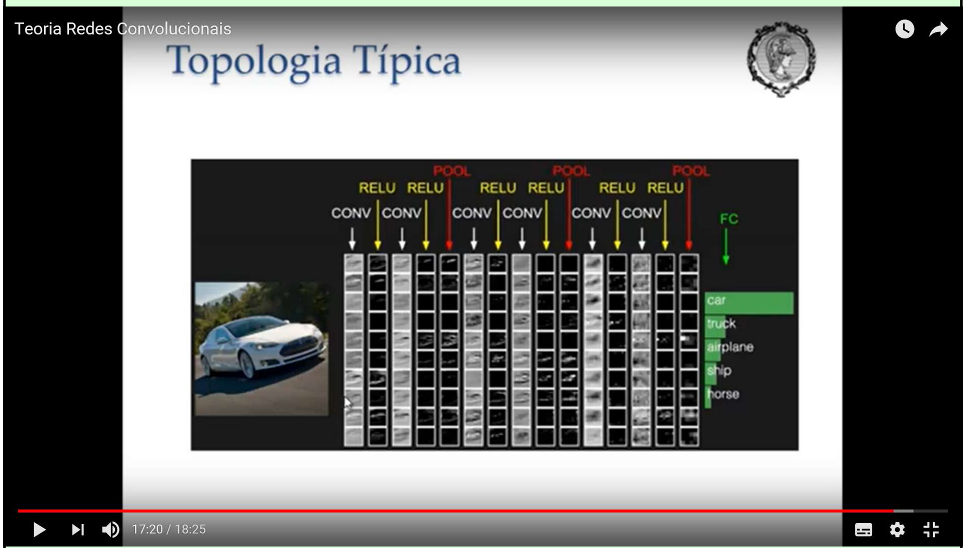
Teoria Redes Convolucionais
Topologia Típica
POOL POOL POOL
RELU RELU RELU RELU RELU RELU
CONV CONV CONV CONV CONV CONV
FC
car
truck
airplane
ship
horse
17:20 / 18:25

81

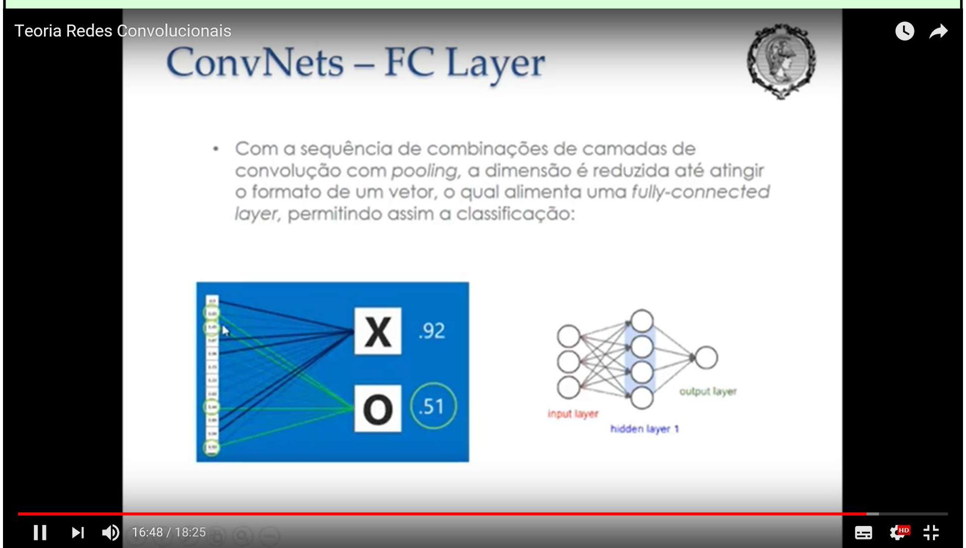
Teoria Redes Convolucionais
ConvNets – FC Layer
• Com a sequência de combinações de camadas de convolução com *pooling*, a dimensão é reduzida até atingir o formato de um vetor, o qual alimenta uma *fully-connected layer*, permitindo assim a classificação:
X .92
O .51
input layer
hidden layer 1
output layer
16:48 / 18:25

82

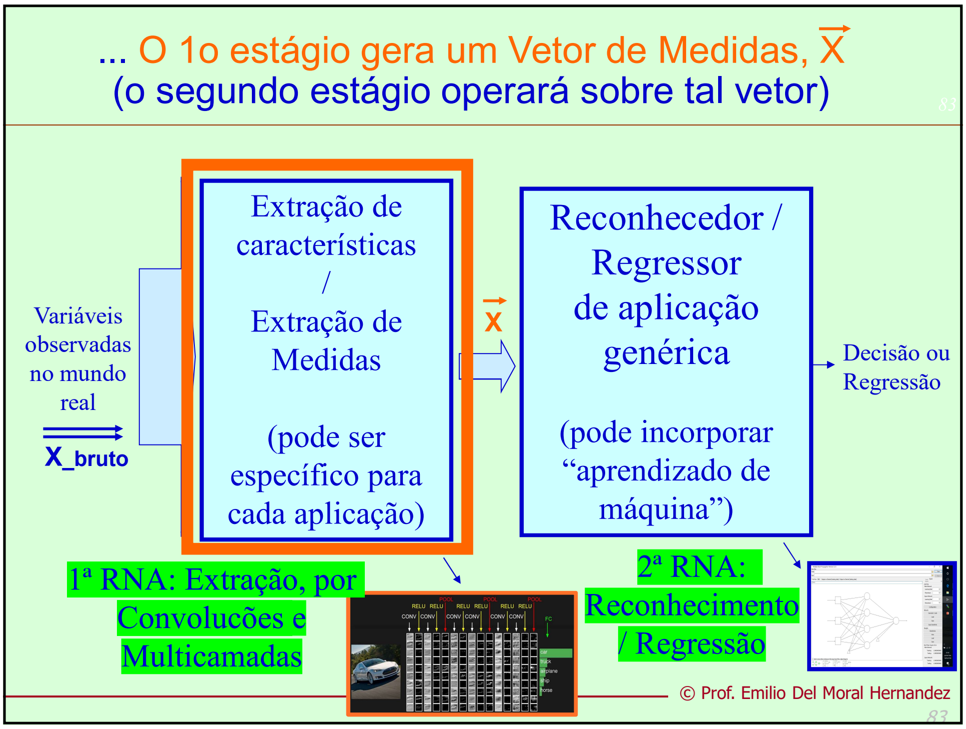

... O 1o estágio gera um Vetor de Medidas, $\vec{X}$
(o segundo estágio operará sobre tal vetor)
Variáveis observadas no mundo real
X_bruto
Extração de características / Extração de Medidas
(pode ser específico para cada aplicação)
$\vec{X}$
Reconhecedor / Regressor de aplicação genérica
(pode incorporar "aprendizado de máquina")
Decisão ou Regressão
1ª RNA: Extração, por Convoluções e Multicamadas
2ª RNA: Reconhecimento / Regressão
© Prof. Emilio Del Moral Hernandez
83

83