



THE DEVELOPER'S CONFERENCE

Trilha – Machine Learning

Uso de PyTorch para Aplicações de Visão Computacional

Fulvio Mascara

Cientista-chefe @ Foursys

Community Manager @ AI Brasil



THE
DEVELOPER'S
CONFERENCE



CARA...

- Corredor de media e longa distância
- Diabético
- Programo desde os 11 anos
- "Tocador" de violão e guitarra
- Gosto de cozinhar e viajar



... E CRACHÁ!

- 30 anos de carreira
- Cientista-chefe (P&D&I) da Foursys
- Community Manager – AI Brasil
- Tecnólogo em Proc. Dados (Mackenzie)
- Pós-Graduado em Solution Architect (FIAP)
- Pós-Graduado em Estatística Aplicada (FMU)

Agenda



- Frameworks Deep Learning
- PyTorch
- Visão Computacional no PyTorch
- Demonstração
 - Notebook Jupyter
- Expectativas
- Links úteis

Frameworks Deep Learning

Panorama atual



Caffe



PYTORCH



theano

Frameworks Deep Learning

Principais Características – Visão Mercado



THE
DEVELOPER'S
CONFERENCE

- Otimizado para performance
- Fácil de entender e codificar
- Bom suporte da comunidade
- Paralelizar processos para reduzir os cálculos
- Automaticamente calcule os gradientes
- Design de Código conveniente
- Exemplos / referências de código de alta qualidade
- Velocidade do treinamento e da inferência
- Quantidade de funções / métodos oferecidos “out of the box”
- Compatibilidade nas atualizações de versão
- Suporte a múltiplas linguagens de programação

Fonte:
<https://www.analyticsvidhya.com/blog/2019/03/deep-learning-frameworks-comparison/>

Fonte: <https://medium.com/apache-mxnet/a-way-to-benchmark-your-deep-learning-framework-on-premise-4f7a0f475726>

Frameworks Deep Learning

Principais Características – Visão pessoal



THE
DEVELOPER'S
CONFERENCE

- Constante evolução
- Comunidade vibrante, usando o framework tanto pra pesquisa quanto produção
- Rápida curva de aprendizado
- Ter recursos que permitam depurar o processo de treinamento das redes
- Modelos prontos para facilitar o processo de Transfer Learning
- Exportar o resultado para formatos que acelerem a inferência para Mobile e Edge Computing
- Velocidade no treinamento e na inferência


Frameworks Deep Learning

Adoção / Uso – Visão Setembro/2018



THE
DEVELOPER'S
CONFERENCE

Deep Learning Framework Power Scores 2018



Critérios:

- Online Job Listings
- **KDnuggets Usage Survey**
- Google Search Volume
- Medium Articles
- **Amazon Books**
- ArXiv Articles
- GitHub Activity

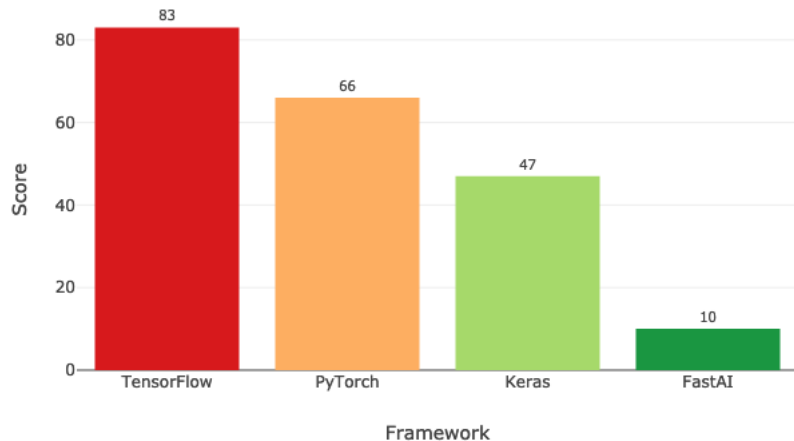
Frameworks Deep Learning

Adoção / Uso – Visão Abril/2019



THE
DEVELOPER'S
CONFERENCE

Deep Learning Framework Six-Month Growth Scores 2019



Critérios:

- Online Job Listings
- Google Search Interest
- Medium Articles
- Quora Followers
- ArXiv Articles
- GitHub Activity

PyTorch

Histórico



THE
DEVELOPER'S
CONFERENCE

- Criado em Jan/16 pelo grupo de pesquisa de AI do Facebook
 - Adam Paszke, Sam Gross, Soumith Chintala, Gregory Chanan
- Baseado no Torch
- Escrito em Python, C++ e CUDA
- PyTorch 1.0 lançado em Dez/18, com foco de se consolidar como um framework único “the path from research to production”

PYTORCH



ONNX



Caffe2

- Atualmente está na versão 1.1, lançada em Abril/19

PyTorch

Características



- Fácil e muito flexível para prototipação
- Apesar das diversas features da v1.0, ainda é um framework muito mais voltado pra pesquisa
- Computação por Tensores, que acabam sendo uma abstração de arrays do numpy, mas com os ganhos computacionais do uso de GPU
- O fato de herdar as características do numpy, facilita a curva de aprendizado
- Estrutura de programação imperativa e não declarativa
- Dynamic Computational Graphs, ou seja, você pode alterar a arquitetura de uma rede durante sua execução, pois o “graph” é gerado “on the fly”
- Os DCGs são o que viabilizam um outro recurso do PyTorch: autograd. O autograd (módulo) usa um método de AD (Automatic Differentiation) pra “gravar” as operações de forward-pass e realizar um replay das mesmas pra calcular os gradientes no backprop
- Funcionalidades pra escalar o processo de treinamento das redes, provendo ganho de performance
- Possui compilador jit (just in time), que com o uso de Torch Script, torna possível rodar um código salvo no PyTorch, de forma compilada e sem necessidade do Python.
- Suporte nativo ao ONNX (Open Neural Network Exchange), o que facilita na integração com outras ferramentas compatíveis com este padrão
- Front-end híbrido, que permite transitar entre “eager mode” e “graph mode”
- Possui API e Front-end em C++
- Conta com datasets e modelos prontos pra uso, acelerando o processo de prototipação e desenvolvimento
- Pronto para os principais vendedores e plataformas de cloud AI/ML do mercado (AWS Sagemaker, Azure, GCP Kubeflow e Tensorboard)

PyTorch

Principais Estruturas

- Matrizes ou Tensores
- Operações com Tensores
- Variáveis e Gradientes (Autograd)



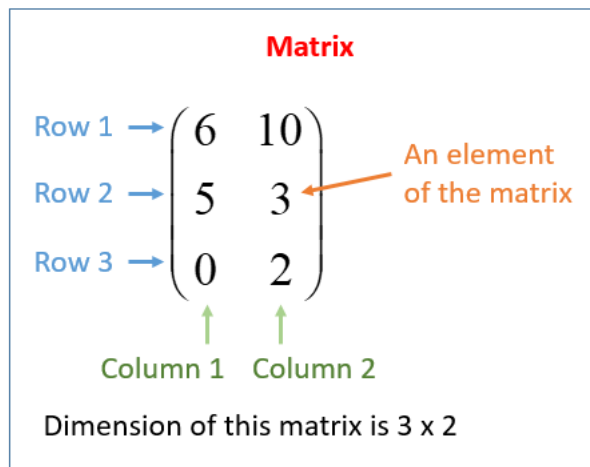
THE
DEVELOPER'S
CONFERENCE

PyTorch

Principais Estruturas



➤ Matrices ou Tensores



```
import numpy as np
import torch

# 1) Create a PyTorch Tensor an array

arr = [[3, 4], [8, 5]] # python array
pyt_tensor = torch.Tensor(arr) # PyTorch tensor

# 2) Create a tensor

ones_tensor = torch.ones((2, 2)) # tensor containing all ones
torch.manual_seed(0) # to have same values for random
generation
rand_tensor = torch.rand((2, 2)) # tensor containing random values

# if running on GPU, set random seed value as follows
if torch.cuda.is_available():
    torch.cuda.manual_seed_all(0)

# 3) Create a tensor from numpy array (dtype must be either double,
float, int64, int32, or uint8)

np_arr = np.ones((2, 2))
pyt_tensor = torch.from_numpy(np_arr)
np_arr_from_tensor = pyt_tensor.numpy() # convert tensor to numpy
array
```

PyTorch

Principais Estruturas



THE
DEVELOPER'S
CONFERENCE

➤ Operações com Tensores

```
import numpy as np
import torch

# 1) Resizing a tensor

pyt_tensor = torch.ones((2, 2))
print(pyt_tensor.size()) # shows the size of this tensor
pyt_tensor = pyt_tensor.view(4) # resizing 2x2 tensor to 4x1

# 2) Mathematical Operations

pyt_tensor_a = torch.ones((2, 2))
pyt_tensor_b = torch.ones((2, 2))
res_tensor = pyt_tensor_a + pyt_tensor_b # simple
# element wise addition
res_tensor = torch.add(pyt_tensor_a, pyt_tensor_b) # another way
# of addition
pyt_tensor_a.add_(pyt_tensor_b) # In-place
# addition

# Operation  operator  function_name
# => Addition    +      add
# => Subtraction -      sub
# => Multiplication *    mul
# => Divide      /      div
```

```
# 3) Mean and Standart deviation

pyt_tensor = torch.Tensor([1, 2, 3, 4, 5])
mean = pyt_tensor.mean(dim=0) # if multiple
# rows then dim = 1
std_dev = pyt_tensor.std(dim=0) # if multiple
# rows then dim = 1
```

PyTorch

Principais Estruturas



➤ Variáveis e Gradientes (Autograd)

```
import numpy as np
import torch
from torch.autograd import Variable

pyt_var = Variable(torch.ones((2, 2)), requires_grad = True)

# behaves exactly the same as tensors, so we can apply all
operations in the same way
```

```
import numpy as np
import torch
from torch.autograd import Variable

# let's consider the following equation
# y = 5(x + 1)^2

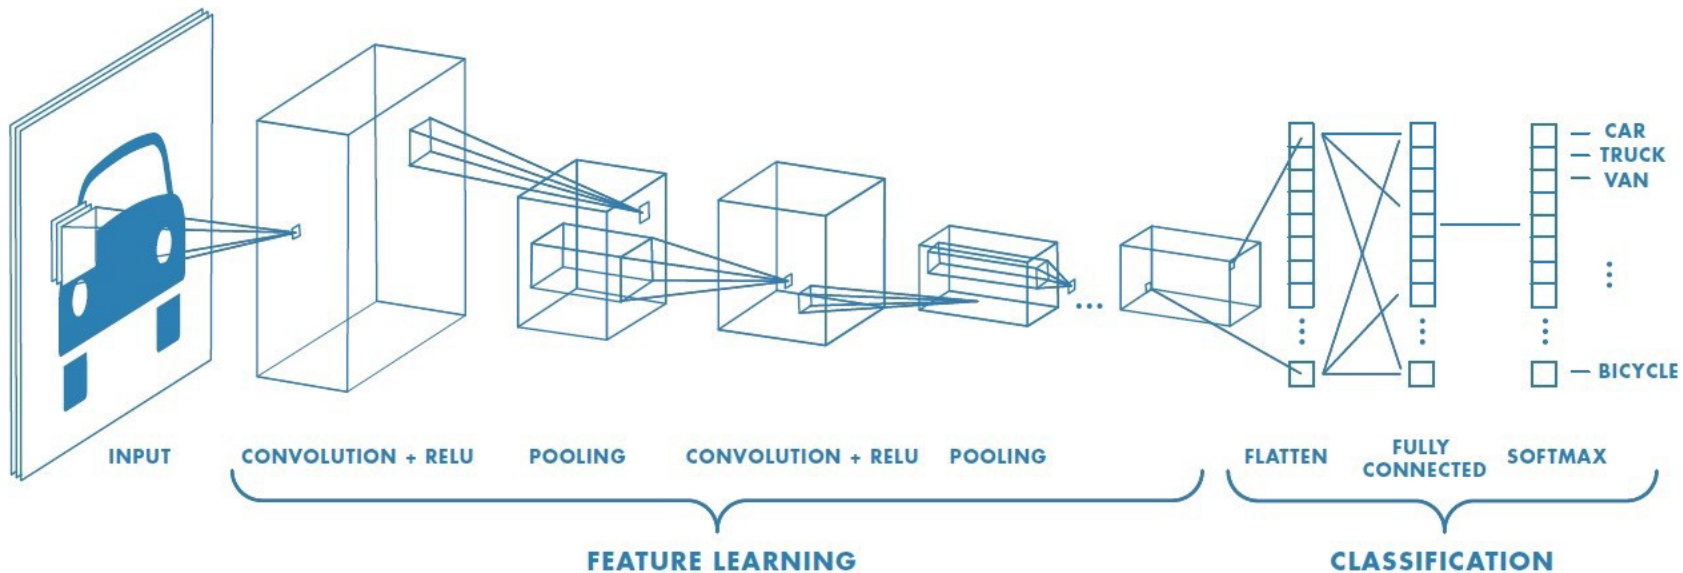
x = Variable(torch.ones(1), requires_grad = True)
y = 5 * (x + 1) ** 2      # implementing the equation.
y.backward()             # calculate gradient
print(x.grad)            # get the gradient of variable x
# differentiating the above mentioned equation
# => 5(x + 1)^2 = 10(x + 1) = 10(2) = 20
```

PyTorch

CNN – Convolutional Neural Networks



THE
DEVELOPER'S
CONFERENCE



https://miro.medium.com/max/2625/1*vkQ0hXDaQv57sALXAJquxA.jpeg

PyTorch

Visão Computacional e CNNs



THE
DEVELOPER'S
CONFERENCE

torch.nn

Convolution Layers

- Conv1d
- Conv2d
- Conv3d
- ConvTranspose1d
- ConvTranspose2d
- ConvTranspose3d
- Unfold
- Fold

Pooling Layers

MaxPool1d	FractionalMaxPool2d
MaxPool2d	LPPool1d
MaxPool3d	LPPool2d
MaxUnpool1d	AdaptiveMaxPool1d
MaxUnpool2d	AdaptiveMaxPool2d
MaxUnpool3d	AdaptiveMaxPool3d
AvgPool1d	AdaptiveAvgPool1d
AvgPool2d	AdaptiveAvgPool2d
AvgPool3d	AdaptiveAvgPool3d

Padding Layers

- ReflectionPad1d
- ReflectionPad2d
- ReplicationPad1d
- ReplicationPad2d
- ReplicationPad3d
- ZeroPad2d
- ConstantPad1d
- ConstantPad2d
- ConstantPad3d

Dropout Layers

- Dropout
- Dropout2d
- Dropout3d
- AlphaDropout

Vision Layers

- PixelShuffle
- Upsample
- UpsamplingNearest2d
- UpsamplingBilinear2d

PyTorch

Visão Computacional e CNNs



THE
DEVELOPER'S
CONFERENCE

torch.nn.functional

Convolution Functions

conv1d
conv2d
conv3d
conv_transpose1d
conv_transpose2d
conv_transpose3d
unfold
fold

Pooling Functions

avg_pool1d	lp_pool1d
avg_pool2d	lp_pool2d
avg_pool3d	adaptive_max_pool1d
max_pool1d	adaptive_max_pool2d
max_pool2d	adaptive_max_pool3d
max_pool3d	adaptive_avg_pool1d
max_unpool1d	adaptive_avg_pool2d
max_unpool2d	adaptive_avg_pool3d
max_unpool3d	

Dropout Functions

dropout
alpha_dropout
dropout2d
dropout3d

Vision Functions

pixel_shuffle
pad
interpolate
upsample
upsample_nearest
upsample_bilinear
grid_sample
affine_grid

PyTorch

Visão Computacional e CNNs



THE
DEVELOPER'S
CONFERENCE

torchvision

datasets

MNIST	ImageNet
Fashion-MNIST	CIFAR
KMNIST	STL10
EMNIST	SVHN
FakeData	PhotoTour
- COCO	SBU
Captions	Flickr
Detection	VOC
LSUN	Cityscapes
ImageFolder	SBD
DatasetFolder	

models

- Classification	- Semantic Segmentation
Alexnet	Fully Convolutional Networks
VGG	DeepLabV3
ResNet	
SqueezeNet	- Object Detection, Instance Segmentation and Keypoint Detection
DenseNet	Runtime characteristics
Inception v3	Faster R-CNN
GoogLeNet	Mask R-CNN
ShuffleNet v2	Keypoint R-CNN
MobileNet v2	
ResNext	

transforms

Crop
Resize
Scale
Flip
Rotate
Color
Brightness / Contrast / Hue
Affine
Compose (Pipeline)
PIL Image
Tensor



ENOUGH TALK

SHOW ME A DEMO!

Expectativas



- Aumentar a adoção em ambientes produtivos
- PyTorch Lite
- Ter uma versão não imperativa

Conclusões

Links úteis



THE
DEVELOPER'S
CONFERENCE

Awesome List – PyTorch

<https://github.com/bharathgs/Awesome-pytorch-list>

The Incredible PyTorch

<https://www.ritchieng.com/the-incredible-pytorch/>

Fast.ai

<https://docs.fast.ai/index.html>

Chainer

<https://chainer.org>

Contatos



[in/fulviomascara](#)



[@fulviomascara](#)



fulvio.mascara



[fulviomascara](#)



Linked in



meetup



facebook

Muito obrigado !



**THE DEVELOPER'S
CONFERENCE**