



Aprendizagem Profunda

TIN0255 - Aprendizagem Profunda
2026.2 - Prof. Pedro Moura

Ciência de Dados

\$600 to buy a disk drive that can store all of the world's music

5 billion mobile phones in use in 2010

30 billion pieces of content shared on Facebook every month

\$5 million vs. \$400

Price of the fastest supercomputer in 1975¹ and an iPhone 4 with equal performance

400% projected growth in global data generated per year vs. **5%** growth in global IT spending

235 terabytes data collected by the US Library of Congress by April 2011

15 out of 17 sectors in the United States have more data stored per company than the US Library of Congress

Ciência de Dados



Deep Learning



04 out

Deep Learning é tecnologia de aprendizado de máquina que mais cresce em todo o mundo

Deep Learning



Deep Learning



Pergunta

- Por que se fala tanto em Ciência de Dados atualmente?
- E o que é Aprendizagem Profunda (*Deep Learning*)?
- O que você entende por “grandes quantidades de dados”?
 - Qual a relação disso com Aprendizagem Profunda?
- Onde isso está presente?
- Você acha que é muito difícil?

Aprendizagem Profunda

- Utiliza os conceitos das seguintes disciplinas da Computação:
 - Cálculo Diferencial e Integral I e II;
 - Álgebra Linear;
 - Estruturas de Dados; e
 - Análise de Algoritmos.

Motivação

- Como desenvolver um algoritmo/modelo que seja capaz de reconhecer se há uma banana aparecendo em uma imagem?



- Desenvolvê-lo será trabalhoso?

Motivação

- E se for o rosto de uma pessoa?



Motivação



- Este [link](#) contém uma leitura interessante sobre o tema!

Motivação

- O que vocês conseguiram perceber da discussão de ambos os exemplos?
- Tradicionalmente, como eram feitos os modelos de Aprendizagem de Máquina (*Machine Learning*)?
- E quais foram os benefícios trazidos pela Aprendizagem Profunda?
 - Mas por que isso não era feito antes?

Ementa

- Apresentação das principais arquiteturas de Aprendizagem Profunda (*Deep Learning*). Redes Neurais *Feedforward*. Redes Neurais Convolucionais. Máquina Restrita de *Boltzmann*. Redes Recorrentes. *Autoencoder*. Redes Generativas Adversarias. Aprendizado por Reforço. Aplicações a problemas de diversas áreas.

Objetivos

- Permitir ao aluno entender o funcionamento das principais arquiteturas de Aprendizagem Profunda e aprender a identificar situações em que pode aplicar cada uma dessas arquiteturas.

Conteúdo Programático

1. Introdução às Redes Neurais

1.1. Regressão Linear

1.2. Primeiro Modelo de rede de neurônios artificiais: Perceptron

1.3. Conceito de Função de Ativação

1.4. Treinando o Modelo

2. Redes Neurais Multicamadas (Rede *Feedforward*)

2.1. Principais Funções de Ativação

2.2. Funções de custo

2.3. *Backpropagation*

Conteúdo Programático

3. Redes Neurais Convolucionais

3.1. Camada de Convolução

3.2. Camada de *Pooling*

3.3. Reconhecimento de Números Escritos à Mão (MNIST)

4. Máquina Restrita de *Boltzmann* (RBM)

5. Redes Neurais Recorrentes (RNN)

5.1. *Long Short-Term Memory* (LSTM)

Conteúdo Programático

6. Redes Generativas Adversariais (GANs)

6.1. Desafios

7. Aprendizado por Reforço

7.1. Aprendizado por Reforço Profundo

8. Arquiteturas Compostas

9. Aplicações a problemas de diversas áreas, como classificação ou geração de imagens, classificação/geração de música e etc.

Ambiente de Programação

- O conteúdo da disciplina vai ser abordado de maneira equilibrada: tanto em termos conceituais, mostrando as definições matemáticas e algorítmicas das arquiteturas, quanto em termos de código.
- A linguagem adotada será Python.
 - Por estar se consolidando como a linguagem de Ciência de Dados;
 - Por ter facilidade para manipulação de matrizes e métodos que operam sobre essas; e
 - Por ter a API **Keras** (interface para a biblioteca Tensorflow).

Ambiente de Programação

- Ambiente de Programação:
 - Usaremos notebooks **Jupyter**, por conta da interatividade.
- O ambiente que recomendo é o *Google Colab Notebooks*.
 - Para quem quiser se familiarizar, leiam este ótimo guia:
[Google Colab – Guia do Iniciante](#)
- Outra opção é usar os notebooks Jupyter a partir do container **Docker**.
 - Códigos do livro em que me baseiam fornecem as duas opções.

Aulas

- Horário

- Terça e Quinta – 20:00 às 22:00

- Lab 2

- Material no Moodle

- moodleccet.uniriotec.br/
 - Inscrever-se no curso
 - 2026.2 – Aprendizagem Profunda

Avaliações

- Desenvolvimento de um projeto ao longo do semestre: individual.
 - Definição de um problema de um determinado domínio;
 - Deve conter uma boa massa de dados (de preferência não tabular); e
 - Escolha das arquiteturas a serem aplicadas.
- Escrita de um **relatório** descrevendo o problema, as arquiteturas e os experimentos realizados.
 - Apresentação do projeto também.
- **Estudo e apresentação** de artigo no contexto de Aprendizagem Profunda no final do semestre.

Projeto

- Onde se inspirar para definir o problema e dados massivos?
 - [Kaggle](#)
 - [UCI Machine Learning Repository](#)
 - [Towards Data Science](#)
 - E conversando com o professor. :)
-

Comentários

- Esse é uma área na qual venho trabalhando nos últimos anos.
 - O Prof. Jean-Pierre, que esteve como professor visitante na UNIRIO de 2018 a 2020, teve uma boa contribuição nisso;
 - Tenho estudado bastante o tema nos últimos anos; e
 - Estou orientando diversos alunos de graduação e mestrado (até de doutorado) utilizando essas técnicas. :)
 - Espero que seja uma experiência interessante para todos nós!
-

Material Didático

- A disciplina é fortemente baseada em três livros:
 - **Deep Learning Illustrated: A Visual, Interactive Guide to Artificial Intelligence;**
 - **Mining of Massive Datasets;**
 - **Neural Networks and Deep Learning: A Textbook.**
- O livro **Deep Learning** de Ian Goodfellow, Yoshua Bengio e Aaron Courville também vai ser utilizado em alguns momentos.
- Existe vastos material didático na internet.
 - O portal [Towards Data Science](#) tem artigos (não científicos) bem interessantes.

Material Didático

BIBLIOGRAFIA BÁSICA

1. Krohn, Jon; Beyleveld, Grant; Bassens, Aglaé. *Deep Learning Illustrated: A Visual, Interactive Guide to Artificial Intelligence*. Addison-Wesley Professional, 2020.
2. Goodfellow, Ian. *Deep Learning*. The Mit Press, 2016.
3. Aggarwal, Charu C.. *Neural Networks and Deep Learning: A Textbook*. Springer, 2018.
4. Briot, Jean-Pierre; Hadjeres, Gaëtan; Pachet, François-David. *Deep Learning for Music Generation*. Springer, 2020.
5. Chollet, François. *Deep Learning with Python*. Manning Publications, 2017.
6. Foster, David. *Generative Deep Learning*. O'Reilly, 2019.

Material Didático

7. Graesser, Laura; Loon Keng, Wah. *Foundations of Deep Reinforcement Learning: Theory and Practice in Python*. Addison-Wesley Professional, 2019.

Material Didático

BIBLIOGRAFIA COMPLEMENTAR

1. LeCun, Yann; Bengio, Yoshua; Hinton, Geoffrey. *Deep Learning*. In: Nature. vol. 521. p. 436–444. 2015.
2. Goodfellow, Ian J.; Pouget-Abadie, Jean; Mirza, Mehdi; Xu, Bing; Warde-Farley, David; Ozair, Sherjil; Courville, Aaron; Bengio, Yoshua. *Generative Adversarial Networks*. 2014. arXiv: 1406.2661.
3. Kelleher, John D. *Deep Learning* (The MIT Press Essential Knowledge series). The MIT Press. 2019.
4. Leskovec, Jure; Rajaraman, Anand. Ullman, Jeffrey. *Mining of Massive Datasets*. 3^a ed. Cambridge University Press, 2020.
5. Skansi, Sandro. *Introduction to Deep Learning: From Logical Calculus to Artificial Intelligence* (Undergraduate Topics in Computer Science). Springer, 2018.

Material Didático

6. Machine Learning Mistery – Making Developers Awesome at Machine Learning. Disponível em: <<https://machinelearningmastery.com/>>. Acesso em: 03 jul. 2020.
7. A Neural Network Playground. Disponível em: <<https://playground.tensorflow.org/>>. Acesso em: 09 jul. 2020.