
CURSO: DOUTORADO EM MODELAGEM MATEMÁTICA – 2º semestre de 2023

DISCIPLINA: Redes Neurais e Deep Learning

PROFESSOR(ES): Dario Augusto Borges Oliveira

CARGA HORÁRIA: 60h

PRÉ-REQUISITO: Teoria da Probabilidade; Estrutura de Dados e Algoritmos;

HORÁRIO E SALA DE ATENDIMENTO: 5as 11hs às 13hs (Sala do Professor).

SALA: Laboratório 1332

PLANO DE ENSINO

1. Ementa

Fundamentos Matemáticos para Redes Neurais. Perceptrons e Multi-Layer Perceptrons. Deep Learn. Redes Feedforward. Backpropagation. Regularização. Performance. Avaliação do Aprendizado. Tarefas e Arquiteturas de Redes Neurais: Convolutional Neural Networks (CNNs). Modelos Sequenciais: Recurrent Neural Networks (RNNs). Generative Adversarial Networks (GANs). Transfer Learning. Deep Auto-encoders. Detecção e Localização. Segmentação Semântica. Aprendizado Auto-Supervisionado. Modelos Open Source. Algoritmos. Plataformas de Hardware e Software. Exemplos.

2. Objetivos da disciplina

O objetivo central da disciplina é apresentar aos alunos o campo de aprendizado profundo e capacitá-los a desenvolver soluções utilizando as diferentes técnicas abordadas no curso. Os objetivos secundários são: (1) Apresentar os fundamentos matemáticos de otimização e treinamento dos modelos de aprendizado profundo; (2) Apresentar as questões fundamentais do campo, como otimização, generalização, transferência de aprendizado, e outros; (3) Apresentar arquiteturas fundamentais de modelos consagrados para as tarefas supra mencionadas; (4) Desenvolver habilidade de programação nos alunos para criação de soluções usando os métodos e tarefas apresentados no curso; (5) Criar senso crítico para que os alunos consigam pesquisar e utilizar novos modelos de aprendizado profundo no futuro.

3. Procedimentos de ensino (metodologia)

O curso será estruturado em aulas teóricas participativas intercaladas com aulas práticas interativas, de forma que o aluno irá imediatamente aplicar e experimentar os conceitos teóricos discutidos em sala de aula. Os alunos também irão exercitar a leitura e

entendimento de artigo científico para desenvolver habilidades e independência para aprender novos modelos no futuro, que serão avaliados em seminário coletivo para os colegas. No decorrer do curso serão propostas atividades de programação que envolvem o desenvolvimento de solução para tarefas propostas.

4. Conteúdo programático detalhado

Data	Topico	Atividade
Agosto, 15	Introdução a Deep Learning Convolutional Neural Networks Treinamento de CNNs	Aula teórica participativa
Agosto, 17	Introdução ao COLAB	Aula prática de laboratório
Agosto, 22	Generalização Otimização	Aula teórica participativa
Agosto, 24	Backpropagation	Aula prática de laboratório
Agosto, 29	Arquiteturas CNN	Aula teórica participativa
Agosto, 31	Otimização	Aula prática de laboratório
Setembro, 5	Segmentação Semântica (1/2)	Aula teórica participativa
Setembro, 12	Transfer Learning <i>1a Atividade (Transfer Learning)</i>	Aula prática de laboratório
Setembro, 14	Segmentação Semântica (2/2)	Aula teórica participativa
Setembro, 19	Segmentação Semântica <i>1a Atividade deadline</i> <i>2a Atividade (FCN)</i>	Aula prática de laboratório
Setembro, 21	Recurrent Neural Networks <i>2a Atividade deadline</i>	Aula teórica participativa
Setembro, 26	Recurrent Neural Networks <i>3a Atividade (RNN)</i>	Aula prática de laboratório
Outubro, 3	Detecção e Localização	Aula teórica participativa

Outubro, 10	Detecção e Localização <i>3a Atividade deadline</i> <i>Definição Seminários</i>	Aula prática de laboratório
Outubro, 17	Prova A1	
Outubro, 19	Instance Segmentation	Aula teórica participativa
Outubro, 24	Instance Segmentation	Aula prática de laboratório
Outubro, 26	GANs	Aula teórica participativa
Outubro, 31	GANs	Aula prática de laboratório
Novembro, 7	Similarity Learning	Aula teórica participativa
Novembro, 9	Similarity Learning	Aula prática de laboratório
Novembro, 14	Autoencoders/Variational AEs	Aula teórica participativa
Novembro, 16	Autoencoders	Aula prática de laboratório
Novembro, 21	Self-supervised Learning (1/2)	Aula teórica participativa
Novembro, 23	Aprendizado de Representação	Aula prática de laboratório
Novembro, 28	Self-supervised Learning (2/2)	Aula teórica participativa
Dezembro, 30	Clusterização	Aula prática de laboratório
Dezembro, 05	Apresentação de Projeto	
Dezembro, 07	Prova A2	
Dezembro, 12	Prova AS	

5. Procedimentos de avaliação

A avaliação dos alunos será uma média ponderada de provas escritas (A1 e A2), atividades de programação individuais ou em grupo, e um seminário sobre um artigo científico (individual ou em grupo).

6. Bibliografia Obrigatória

- GOODFELLOW, Ian et al. Deep learning. Cambridge: MIT press, 2016. Disponível em: <http://www.deeplearningbook.org/>
- TALWALKAR, Ameet. Neural Networks and Deep Learning. Neural Networks, n. 1/16, 2015. Disponível em: <http://neuralnetworksanddeeplearning.com/>
- ANDREW NG. Machine Learning Yearning. Disponível em: <http://www.mlyearning.org/>

7. Bibliografia Complementar

- MCCLURE, Nick. TensorFlow machine learning cookbook. 2017.
- PATTERSON, Josh; GIBSON, Adam. Deep Learning: A Practitioner's Approach. O'Reilly Media, Inc., 2017.
- MICHALSKI, Ryszard S.; CARBONELL, Jaime G.; MITCHELL, Tom M. (Ed.). Machine learning: An artificial intelligence approach. Springer Science & Business Media, 2013.
- Abu-Moustafa, Y.S., Magdon-Ismail, M., e Lin H-S. (2012) Learning from data. AMLBook.com.
- Hastie, T., Tibshirani, R., Friedman, J. (2013) The elements of statistical learning. Springer.
- Luiz André Barroso and Jimmy Clidaras and Urs Hölzle. The Datacenter as a Computer: An Introduction to the Design of Warehouse-Scale Machines. Morgan & Claypool Publishers (2013).

8. Minicurrículo do(s) Professor(s)

Doutor e Mestre em Engenharia Elétrica pela Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio) em 2013 e 2009 respectivamente, tendo realizado parte de sua pesquisa de doutorado na Universidade Leibniz de Hannover, Alemanha e no Instituto Superior Técnico, Portugal. Graduou-se em Engenharia Elétrica na Universidade do Estado do Rio de Janeiro (UERJ), em 2007. Trabalha na área de visão computacional e reconhecimento de padrões, com principais aplicações em sensoriamento remoto, clima, agricultura, florestas, sustentabilidade e imagens médicas. Trabalhou em pesquisa na indústria na General Electric Global Research e na IBM Research de 2015 a 2021. De 2021 a 2022 foi professor visitante na Technische Universität München, na Alemanha. Desde 2022 é professor adjunto na Escola de Matemática Aplicada da Fundação Getúlio Vargas.

9. Link para o Currículo Lattes

<http://lattes.cnpq.br/9356377831965143>