



PLANO DE ENSINO DE DISCIPLINA

UNIDADE: PÓS-GRADUAÇÃO STRICTO SENSU EM ENGENHARIA ELÉTRICA

ÁREA: INTELIGÊNCIA ARTIFICIAL APLICADA À AUTOMAÇÃO E ROBÓTICA

TIPO: OPTATIVA

CARGA HORÁRIA: 48 HORAS

CRÉDITOS: 4

PROFESSOR: Reinaldo A. C. Bianchi (responsável)

DISCIPLINA: TÓPICOS ESPECIAIS EM APRENDIZAGEM (PEL 208)

EMENTA

Introdução a Aprendizagem de Máquina e ao Aprendizado Estatístico; Aprendizado Supervisionado e não Supervisionado; Métodos de Regressão e Classificação Linear; Métodos de validação e seleção; Aprendizado Probabilístico; Redes Neurais Artificiais; Redes de Crenças Profundas; Aprendizado de Máquina aplicados em Processamento de Imagem, Visão Computacional e Processamento de Linguagem Natural; Redes Transformers.

OBJETIVOS

Permitir que os alunos de Pós-Graduação possam aprender conceitos associados a aprendizado de máquina, com ênfase nas técnicas de Inteligência Artificial e Computacional, Aprendizado Estatístico e Probabilístico e Aprendizado Profundo.

METODOLOGIA ADOTADA

Abordagem expositiva em sala de aula, uso de laboratório e trabalhos de programação.



RECURSOS NECESSÁRIOS

Sala de aula, laboratório com o software Python, Anaconda, SciKit Learn, Torch e Tensorflow.

PROGRAMA

Introdução a Aprendizagem de Máquina; Introdução a Aprendizagem Estatística; Métodos de Regressão Linear; Métodos de Regressão Linear – Método dos Mínimos Quadrados e o KNN.

Aprendizado Baseado em Grafos: Árvores de Decisão, Ensembles e Random Forest, XGBoost.

Aprendizado Probabilístico: Naïve Bayes e Regressão Logística

Aprendizado Não-Supervisionado: Agrupamento: K-Means, Expectation Maximization, Gaussian Mixture Models, Hierarchical Clustering, DBSCAN, BIRCH.

Introdução ao Processamento de Imagem e Visão Computacional (Imagem, Filtros)

Inteligência Computacional: Redes Neurais Artificiais, Backpropagation.

Introdução ao Aprendizado Profundo: Redes Convolucionais CNN; Classificação de Imagens.

Deteção e Segmentação: YOLO, EfficientNet, DetectNet; IoU, Dice, mAP.

Criação de Datasets, Data Augmentation, GANs.

Pré-processamento de Texto: tokenização, n-grams, BoW, TF-IDF, embeddings (word2vec, glove, fasttext)

Modelos probabilísticos e lineares para texto: HMM.

Modelos Sequenciais Recorrentes: RNN, LSTM.

Atenção e Transformers: self-attention; positional encoding; encoder/decoder; BERT, GPT, LLAMA

MÉTODO DE AVALIAÇÃO

Exercícios práticos.

BIBLIOGRAFIA

Hastie, T.; Tibshirani, R.; Friedman, J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Second Edition, Berlin: Springer, 2009.

Mitchell, Tom M. Machine Learning. Boston : WCB/McGraw-Hill, c1997.



Fundação
Educacional Inaciana
"Pe. Sabóia de Medeiros"

Campus São Bernardo do Campo

Av. Humberto de A.

Castelo Branco, 3972

S.B. do Campo | SP

09850-901

+55 11 4353 2900

fei@fei.org.br

Géron, Aurélien. Hands On Machine Learning with Scikit-Learn, Keras and Tensorflow. O'Reilly, 2022.

Deep Learning, Yoshua Bengio, Ian Goodfellow, Aaron Courville, MIT Press, 2016.

Raschka, Sebastian. Build a Language Model from Scratch. Manning Publicationd, NY, 2025.

Szeliski. Computer Vision: Algorithms and Applications, 2022.

Daniel Jurafsky e James H. Martin,. Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition with Language Model. Stanford, 2026.