



Programa de disciplina

I. Identificação da disciplina

<i>Código</i>	<i>Nome da disciplina</i>	<i>Horas-aula semanais</i>	<i>Horas-aula semestrais</i>
MTM3587	Aprendizado de Máquina	Teóricas: 2 Práticas: 2	72

II. Pré-requisito(s)

MTM3401 - Cálculo I, MTM3422 - Álgebra Linear II, MTM3520 - Laboratório de Matemática Computacional (Bacharelado) ou MTM3571 - Tecnologias Computacionais na Educação Matemática (Licenciatura).

III. Curso(s) para o(s) qual(is) a disciplina é oferecida

Matemática (bacharelado e licenciatura).

IV. Ementa

Conceitos fundamentais e resultados clássicos em aprendizado de máquina. Técnicas de regressão, classificação, redução de dimensionalidade e de clusterização e suas aplicações. Implantação de modelos de aprendizado de máquina na nuvem. Projeto de aprendizado de máquina de ponta a ponta.

V. Objetivos

Concluindo o programa do curso, o aluno deverá ser capaz de:

- Compreender os fundamentos em aprendizado de máquina.
- Reconhecer conceitos matemáticos envolvidos na construção de algoritmos em machine learning, incluindo as hipóteses assumidas e suas limitações.
- Utilizar pacotes computacionais de última geração para criação de modelos em machine learning.
- Aplicar técnicas de machine learning para solução de problemas.

VI. Conteúdo programático

Unidade 1. Introdução ao aprendizado de máquina.

1.1 Conceito de aprendizado de máquina.

1.2 Instrumentalismo v.s. Realismo e a perspectiva do aprendizado de máquina.

1.3 Tipos de aprendizado.

1.4 Noções básicas em sobreajuste de dados e subajuste de dados.

1.5 Ferramentas computacionais para análise, manipulação e visualização de dados.

1.6 Naive Bayes e aplicação na construção de um filtro de spam.

1.7 Projeto offline de aprendizado de máquina de ponta a ponta.

Unidade 2. Modelos de aprendizado de máquina e técnicas de preparação de dados

2.1. Introdução a regressão.

2.2 Gradiente descendente (Método do gradiente).

2.3 Modelos lineares regularizados.

2.4 Compensação viés/variância.

2.5 Métodos para validação de modelos.

2.6 Técnicas para ajuste e seleção de modelos.

2.7 K-vizinhos mais próximos (K-NN).

2.8 Perceptron.

2.9 Máquina de Vetores de Suporte (SVM).

2.10 Regressão logística.

2.11 Medidas de desempenho para classificação.

2.12 Classificação multiclasse.

2.13 Técnicas avançadas de imputação de dados.

2.13.1 Imputação múltipla por equações encadeadas (MICE).

2.13.2 Imputação através de modelos de machine learning.

- 2.14 Técnicas de reamostragem para dados desbalanceados.
- 2.15 Árvores de decisão.
- 2.16 Métodos de Ensemble.
- 2.16.1 Classificação por votos.
- 2.16.2 Agregação com reposição amostral (Bagging).
- 2.16.3 Agregação sem reposição amostral (Pasting).
- 2.16.4 Árvores aleatórias.
- 2.16.5 Métodos de boosting.

Unidade 3. Redução de dimensionalidade e Clusterização.

- 3.1 Análise de Componentes Principais (PCA) e conexão com decomposição em valores singulares (SVD).
- 3.2 Projeções Aleatórias e Lema de Johnson-Lindenstrauss.
- 3.3 Técnicas de redução de dimensionalidade não-linear (manifold learning).
- 3.4 Aplicações de redução de dimensionalidade.
- 3.5 K-means.
- 3.6 Clusterização Hierárquica.
- 3.7 Clusterização Espacial Baseada em Densidade de Aplicações com Ruído (DBSCAN).
- 3.8 Aplicações de clusterização.

VII. Bibliografia básica

1. Géron, A. Mão à obra: aprendizado de máquina com Scikit-Learn & TensorFlow: Conceitos, ferramentas e técnicas para a construção de ferramentas inteligentes. São Paulo: Altabooks, 28 de junho de 2019.
2. Shwartz, S. Shalev; David, S. Ben. Understanding Machine Learning: From Theory to Algorithms. Cambridge: Cambridge University Press, 2014. Disponível em: <https://www.cs.huji.ac.il/~shais/UnderstandingMachineLearning/copy.html>
3. Deisenroth , M. Peter; Faisal, A. Aldo; Ong, C. Soon. Mathematics for Machine Learning. Cambridge: Cambridge University Press, 2020. Disponível em: <https://mml-book.github.io/book/mml-book.pdf>

VIII. Bibliografia complementar

1. Abu-Mostafa, Y.; Magdon-Ismail M.; Lin H.T. Learning From Data. New York: AMLBook, 2017.
2. Cunningham, J.P; Ghahramani, Z. Linear Dimensionality Reduction: Survey, Insights, and Generalizations. Journal of Machine Learning Research 16, 2859 – 2900, 2015.
3. Dasgupta, S; Gupta, A. An Elementary Proof of a Theorem of Johnson and Lindenstrauss, Random structures and algorithms 22(1), 60 – 65, 2003.
4. Géron, A. Hands-On Machine Learning with Scikit-Learn and TensorFlow 2e: Concepts, Tools, and Techniques to Build Intelligent Systems. Sebastopol: O'Reilly Media, Inc, 2019.
5. Hastie, T.; Tibshirani, R.; Friedman, J. The Elements of Statistical Learning: Data Mining, Inference and Prediction. Basileia: Springer, 2009.
6. Murphy, K.P. Machine Learning: A Probabilistic Perspective. Cambridge: MIT press. 2012.
7. Raschka, S.; Mirjalili, V. Python Machine Learning: Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow. Birmingham: Packt Publishing, 2017.
8. Vapnik, V. Empirical inference science afterword of 2006. London: Springer, 2006.

Este programa foi criado pelo professor Edson Cilos Vargas Júnior em 08 de julho de 2021.