

Tópicos em Inteligência Artificial: Fundamentos do Aprendizado de Máquinas (Versão Preliminar)

11 agosto, 2022

Sobre o Professor

- **Professor:** Saul Leite
- **E-mail:** saul.leite@ufabc.edu.br
- **Site:** <http://professor.ufabc.edu.br/~saul.leite/>

Objetivos

A disciplina visa introduzir Aprendizado de Máquinas, com aspectos teóricos, para alunos de pós-graduação em Ciência da Computação e demais discentes interessados neste tema. Os tópicos apresentados ao longo do curso darão mais enfoque ao aprendizado supervisionado e o objetivo será tratar este problema de forma unificante, salientando as similaridades entre as diversas abordagens. Não será exigido conhecimento prévio sobre aprendizado de máquinas para cursar esta disciplina.

Metodologia

Aulas serão exposição dos conteúdos abordados pelo professor através do quadro ou projetor. A avaliação da disciplina será dividida em duas partes:

1. **Participação:** avalia a assiduidade do aluno em sala de aula e sua participação nas discussões durante as aulas;
2. **Seminários:** os alunos serão responsáveis pela apresentação de alguns tópicos especiais contidos em livros ou artigos. Todos os tópicos serão indicados pelo professor, exceto pelo último que será de livre escolha do aluno. Esta etapa de avaliação diz respeito a qualidade da apresentação destes seminários.

Planejamento Semanal

Segue abaixo o planejamento preliminar para a disciplina. Os tópicos marcados em *itálico* serão apresentados pelos alunos da disciplina.

Semana 01

1. Introdução à disciplina.
2. O problema do aprendizado supervisionado: definição, funções de perda, soluções ótimas (função de regressão e classificador de Bayes). Algoritmo KNN como uma aproximação das soluções ótimas. Problema da maldição da dimensionalidade.

Semana 02

3. Subajuste, sobreajuste, o compromisso entre viés-variância, e validação de modelos.
4. Elementos de Otimização Convexa.

Semana 03

5. Regressão Linear regularizada: Lasso, Ridge, e Elastic-Net. Interpretação dos métodos como os de minimização do risco empírico regularizado.
6. *Apresentações de Tópicos I*: Métodos de otimização em algoritmos de aprendizado de máquinas.

Semana 04

7. Regressão não-linear com funções bases. Regressão Ridge com kernel.
8. Kernels: definição, espaços de Hilbert, espaço de Hilbert do kernel de reprodução, propriedades.

Semana 05

9. Análise discriminante no problema de classificação: algoritmos LDA, QDA, e Naive Bayes.
10. *Apresentação de Tópicos II*: Kernels para dados não numéricos e outros métodos baseados em Kernel.

Semana 06

11. Classificadores lineares: classificador de Fisher, perceptron, e regressão logística.
12. Máquinas de Vetor Suporte (SVMs) para regressão e classificação. SVMs como um algoritmo de minimização do risco Empírico.

Semana 07

13. Dualidade, espaço de versões, *Representer Theorem*, e o Perceptron dual.
14. Aprendizado on-line e limitantes de arrependimento.

Semana 08

15. Árvores para classificação e regressão. Introdução à métodos ensemble, *bagging* e *boosting*.
16. *Apresentação de Tópicos III*: formulações do SVM alternativas, métodos on-line e limitantes de arrependimento.

Semana 09

17. Seleção de Características, métodos *best subset selection (BSS)*, *forward subset selection (FSS)*, *recursive feature elimination (RFE)* e variantes.
18. Redução da dimensionalidade com a análise das componentes principais (PCA), e o método Kernel-PCA.

Semana 10

19. O *Framework* do Aprendizado PAC
20. *Apresentação de Tópicos IV*: outros métodos baseados em boosting.

Semana 11

21. Complexidade de Rademacher e Dimensão VC (Parte 1)
22. Complexidade de Rademacher e Dimensão VC (Parte 2)

Semana 12

23. Model Selection
24. *Apresentação de Tópicos V*: livre.

Referências Bibliográficas

- [1] Mohri, Mehryar, Afshin Rostamizadeh, and Ameet Talwalkar. Foundations of Machine Learning, Second Edition. Second edition. Cambridge, Massachusetts: The MIT Press, 2018.
- [2] Hastie, Trevor, Robert Tibshirani, and Jerome Friedman. The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition. 2nd edition. New York, NY: Springer, 2016.
- [3] Shawe-Taylor, John, and Nello Cristianini. Kernel Methods for Pattern Analysis. Cambridge: Cambridge University Press, 2004.
- [4] James, Gareth, Daniela Witten, Trevor Hastie, and Robert Tibshirani. An Introduction to Statistical Learning: With Applications in R. 2nd ed. 2021 edition. New York NY: Springer, 2021.

[5] Cucker, Felipe, and Ding Xuan Zhou. Learning Theory: An Approximation Theory Viewpoint. Illustrated edition. Cambridge, UK ; New York: Cambridge University Press, 2007.