

Aprendizado de Máquina

Plano de Ensino¹ – 2020.2

1 Informações gerais

- Professor: Danilo Silva (danilo.silva@ufsc.br)
- Carga horária semestral: 72 horas-aula = 60 horas (1 hora-aula = 50 minutos)
- Carga horária semanal: 4 horas-aula (Teóricas: 4; Práticas: 0)
- Oferecimento:
 - EEL7514 – Tópico Avançado em Processamento de Sinais (Engenharia Eletrônica)
 - EEL7513 – Tópicos Avançados em Controle e Proc. de Sinais IV (Engenharia Elétrica)²
 - EEL410250 – Aprendizado de Máquina (Pós-Graduação em Engenharia Elétrica)
- Pré-requisitos:
 - INE5202 – Cálculo Numérico em Computadores
 - INE5118 – Probabilidade Estatística e Processos Estocásticos
 - EEL7522 – Processamento Digital de Sinais

Obs: Caso não consiga matrícula devido à limitação de vagas, recomenda-se aguardar em lista de espera até o fim da semana de ajustes de matrícula, quando é possível haver desistências.

2 Ementa

Conceitos básicos sobre aprendizado de máquina. Aprendizado supervisionado: regressão e classificação; regressão linear; regressão logística; máquinas de vetores de suporte; redes neurais; redes profundas, redes convolucionais e redes recursivas. Aprendizado não-supervisionado: *clustering*; redução de dimensionalidade; detecção de anomalias. Aplicações em processamento de sinais.

3 Objetivos

Estudo de técnicas de aprendizado de máquina e sua utilização por meio de bibliotecas de software da atualidade, com enfoque em modelos preditivos relevantes para aplicações em processamento de sinais.

4 Conteúdo programático

- **Introdução:** Motivação; Tipos de aprendizado; Exemplos de aplicações.
- **Revisão teórica:** Probabilidade e variáveis aleatórias; Métodos numéricos de otimização.
- **Aprendizado supervisionado:** Conceitos básicos sobre regressão e classificação; Regressão linear; Regressão logística; Máquinas de vetores de suporte; Redes neurais; Redes profundas; Redes convolucionais; Redes recursivas; Técnicas de regularização.
- **Aprendizado não-supervisionado:** *Clustering*; Redução de dimensionalidade; Detecção de anomalias.

¹Plano de ensino adaptado, em caráter excepcional e transitório, para substituição de aulas presenciais por aulas em meios digitais, enquanto durar a pandemia do novo coronavírus – COVID-19, em atenção à Resolução Normativa 140/2020/CUn.

²Também pode ser validada como Projeto Nível I/II em Processamento de Sinais

- **Aplicações em processamento de sinais:** Aplicações selecionadas; Desenvolvimento do projeto final.

5 Metodologia

A disciplina será organizada em atividades síncronas e assíncronas. As atividades assíncronas incluem: videoaulas gravadas para exposição do conteúdo teórico; exercícios de teoria e programação fornecidos semanalmente; e o desenvolvimento de um projeto final. As atividades síncronas consistem de reuniões semanais através de webconferência para correção e discussão dos exercícios, para o esclarecimento de dúvidas, e para orientação, acompanhamento e apresentação do projeto final. As atividades síncronas que envolverem toda a turma serão gravadas e estarão disponíveis para os alunos que não puderem estar presentes.

Os exercícios de programação serão baseados em linguagem Python e respectivas bibliotecas de código aberto. Artigos envolvendo aplicações ou extensões da teoria serão sugeridos periodicamente para serem discutidos. O projeto final tem como objetivo aplicar a teoria em algum problema prático de interesse do aluno. O projeto deve ser realizado preferencialmente em dupla, com tema distinto para cada equipe, e consiste na entrega de relatório em formato de artigo, apresentação de slides e implementação comentada.

A comunicação entre professor e alunos ocorrerá por meio do ambiente virtual de aprendizagem (Moodle) com o envio de mensagens, postagens em fóruns, entre outros, bem como por e-mail. Também será oferecida a possibilidade de agendamento de horário para atendimento por vídeo.

6 Atividades práticas

A disciplina não exige atividades práticas presenciais. Os exercícios semanais e o projeto final podem ser realizados de forma não-presencial e assíncrona, utilizando plataformas de software gratuitas.

7 Avaliação e controle de frequência

O aproveitamento na disciplina será mensurado pela realização dos exercícios semanais e pela avaliação do projeto final, de acordo com a seguinte ponderação (onde N representa o número de exercícios):

- 25%/ N : entrega de cada exercício semanal dentro do prazo estabelecido (até às 08:00 do dia em que será feita a correção), mesmo que incompleto ou contendo erros. Todos os exercícios serão disponibilizados com pelo menos 1 semana de antecedência;
- 25%: entrega do conjunto de todos os exercícios completos e corrigidos até o encerramento da disciplina;
- 50%: avaliação do projeto final.

A frequência será computada pela participação nas atividades síncronas ou, em caso de ausência, pela entrega do exercício correspondente.

8 Cronograma

As atividades síncronas (webconferência) serão realizadas semanalmente nas terças das 08:30 às 10:30, sendo o restante da carga horária semanal complementado com videoaulas gravadas, leituras e atividades práticas. Em virtude de feriados, duas aulas de reposição serão agendadas em horários a serem combinados com a turma, preferencialmente na quartas-feiras. O cronograma semanal está descrito a seguir.

Semana	Data	CH	Tópico
1	02/02	4h	Introdução / Python / Regressão linear
2	09/02	4h	Regressão linear / Regularização
3	16/02*	4h	Regressão linear / Otimização
4	23/02	4h	Regressão logística
5	02/03	4h	SVM
6	09/03	4h	Redes neurais
7	16/03	5h	Redes profundas
8	23/03*	6h	Redes convolucionais / Redes recorrentes
9	30/03	6h	Clustering / Detecção de anomalias
10	06/04	6h	Redução de dimensionalidade / Sistemas de recomendação
11	13/04	5h	Propostas de projeto
12	20/04	5h	Desenvolvimento e acompanhamento dos projetos
13	27/04	5h	Desenvolvimento e acompanhamento dos projetos
14	04/05	5h	Pré-apresentação
15	11/05	5h	Apresentação do projeto final / Entrega dos exercícios corrigidos

* Feriado; encontro síncrono será reagendado em data posterior a ser combinada com a turma.

9 Referências

Todos os materiais da disciplina, incluindo slides, links para textos e vídeos, etc, serão disponibilizados aos alunos via Moodle. Todos os livros indicados abaixo como disponíveis online podem ser acessados gratuitamente.

Bibliografia principal

- [1] C. M. Bishop, *Pattern Recognition and Machine Learning*. Springer, 2006. [Online]. Available: <https://www.microsoft.com/en-us/research/publication/pattern-recognition-machine-learning>
- [2] G. James, D. Witten, T. Hastie, and R. Tibshirani, *An Introduction to Statistical Learning*. Springer, 2013. [Online]. Available: <http://www.statlearning.com>
- [3] M. A. Nielsen, *Neural Networks and Deep Learning*. Determination Press, 2015. [Online]. Available: <http://neuralnetworksanddeeplearning.com>
- [4] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2017. [Online]. Available: <https://www.deeplearningbook.org>

Bibliografia complementar

- [5] J. Watt, R. Borhani, and A. K. Katsaggelos, *Machine Learning Refined: Foundations, Algorithms, and Applications*. New York: Cambridge University Press, 2016.
- [6] Y. S. Abu-Mostafa, M. Magdon-Ismael, and H.-T. Lin, *Learning from Data: A Short Course*. AMLbook.com, 2012.
- [7] T. Hastie, R. Tibshirani, and J. H. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, 2nd ed. Springer, 2009. [Online]. Available: <https://web.stanford.edu/~hastie/ElemStatLearn>
- [8] K. P. Murphy, *Machine Learning: A Probabilistic Perspective*. MIT Press, 2012.
- [9] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*, 2nd ed. Wiley, 2001.