

**PLANO DE ENSINO**

<b>ENGENHARIA DE PRODUÇÃO</b>				
<b>Turno:</b> Noturno			<b>Currículo:</b> 2023	
<b>INFORMAÇÕES BÁSICAS</b>				
<b>Unidade curricular</b> Aprendizado Supervisionado				<b>Departamento</b> DEMEP
<b>Período</b> 2024/01	<b>Carga Horária</b>			<b>Código CONTAC</b> -
	<b>Teórica</b> 30	<b>Prática</b> 30	<b>Total</b> 60	
<b>Natureza</b> Optativa	<b>Grau acadêmico / Habilitação</b> Bacharelado		<b>Pré-requisito</b> Cálculo I/Álgebra linear	<b>Co-requisito</b> -
<b>EMENTA</b>				
Introdução a aprendizagem estatística. Acuracidade e interpretação. Aprendizado supervisionado e não supervisionado. Regressão e classificação. Vício e variância. Métricas para avaliar a acuracidade dos modelos. Treinamento e validação. Regressão linear simples. Coeficientes de mínimos quadrados. Intervalo de confiança e teste de hipóteses para os coeficientes. Regressão linear múltipla. Métricas de acuracidade dos modelos. Preditores qualitativos. Termos de interação. Modelos de regressão não linear. Métodos de seleção e comparação de modelos. Pressuposições. Métodos para encolhimento: regressão rígida e LASSO. Regressão via <i>splines</i> e modelos generalizados aditivos. Regressão por árvores de decisão e floresta aleatória. Algoritmos para árvore de decisão e floresta aleatória. <i>Bagging</i> e <i>boosting</i> para árvores de decisão. Regressão logística e introdução aos problemas de classificação. Regressão logística simples. Regressão logística múltipla. Regressão logística para mais de duas classes para resposta. Encolhimento em regressão logística. Modelos generalizados para regressão logística. Análise linear discriminante. Teorema de Bayes para classificação. Classificação por k-vizinhos mais próximos. Classificação via máquinas de vetores de suporte. Classificação via modelos de árvore de decisão e floresta aleatória. Redes neurais para classificação e regressão. Aprendizagem não supervisionada. Análise de componentes principais e métodos de agrupamento.				
<b>OBJETIVOS</b>				
Apresentar aos alunos de graduação em Engenharia conceitos introdutórios e métodos de aprendizagem estatística com aplicações e implementação computacional.				
<b>CONTEÚDO PROGRAMÁTICO</b>				
<b>05/03/2024:</b> Apresentação da disciplina. Informações sobre linguagem R, Python e software. Método de ensino e avaliação. Aprendizado supervisionado e não supervisionado. Regressão e classificação.				
<b>07/03/2024:</b> Aula de laboratório 1.				
<b>12/03/2024:</b> Acuracidade e interpretação. Sobreajuste vs subajuste.				
<b>14/03/2024:</b> Aula de laboratório 2.				
<b>19/03/2024:</b> Regressão linear simples, polinomial e múltipla				
<b>21/03/2024:</b> Aula de laboratório 3.				
<b>26/03/2024:</b> Regressão por árvore de decisão e floresta aleatória				
<b>02/04/2024:</b> Aula de laboratório 4.				
<b>04/04/2024:</b> Métodos de validação cruzada. <i>K-fold</i> , <i>leave-one-out</i> .				
<b>09/04/2022:</b> Aula de laboratório 5.				

**11/04/2024:** Regressão rígida e lasso.

**16/04/2024:** Aula de laboratório 6.

**11/04/2024:** Regressão por componentes principais e por mínimos quadrados parciais

**18/04/2024:** Aula de laboratório 7. Entrega parcial trabalho 1.

**23/04/2024:** Regressão via splines e modelos generalizados aditivos.

**25/04/2024:** Aula de laboratório 8.

**30/04/2024:** Redes neurais e aprendizado profundo

**02/05/2024:** Aula de laboratório 9.

**07/05/2024:** Prova 1.

**09/05/2024:** Estimador de máxima verossimilhança.

**14/05/2024:** Classificação via regressão logística binária.

**16/05/2024:** Aula de laboratório 11. Entrega final trabalho 1.

**21/05/2024:** Análise linear discriminante e quadrática.

**23/05/2024:** Aula de laboratório 12.

**28/05/2024:** Classificação por k vizinhos mais próximos.

**04/06/2024:** Aula de laboratório 13.

**06/06/2024:** Classificação via máquinas de vetores de suporte. Entrega parcial trabalho 2.

**11/06/2024:** Aula de laboratório 14.

**18/06/2024:** Introdução ao Aprendizado não supervisionado.

**20/06/2024:** Aula de laboratório 15.

**24/06/2024:** Prova 2. Entrega final trabalho 2.

**02/07/2024:** Substitutiva

#### **METODOLOGIA**

Aulas teóricas utilizando quadro e slides. Aulas práticas em laboratório de informática com implementação dos métodos via linguagem R e Python. Playlist de apoio: [https://www.youtube.com/watch?v=B\\_jeYKRqQ2U&list=PLF26sItZ5UuMgWB\\_suyd0pIPfs\\_egfTK9](https://www.youtube.com/watch?v=B_jeYKRqQ2U&list=PLF26sItZ5UuMgWB_suyd0pIPfs_egfTK9)

#### **CRITÉRIOS DE AVALIAÇÃO**

Trabalho 1, parcial (T1p): Coleta de dados para regressão, data final de entrega: 18/04/2024

Trabalho 1, final (T1f): Regressão, data final de entrega: 16/05/2024

Trabalho 2, parcial (T2p): Coleta de dados para classificação, data final de entrega: 06/06/2024

Trabalho 2, final (T2f): Classificação, data final de entrega: 21/06/2024

Prova 1 (P1): regressão, data: 07/05/2024

Prova 2 (P2): classificação, data: 24/06/2024

Valores das avaliações: T1p: 1,00; T1f: 1,50; T2p: 1,00; T2f: 1,50; P1: 2,50; P2: 2,50

Os trabalhos deverão ser entregues no SIGAA por apenas um membro de cada grupo.

1 Prova substitutiva dia 02/07/2024 substituindo a menor nota\* em data a ser acordada com os discentes.

\*Menor nota entre: T1p+T1f; T2p+T2f; P1; ou P2.

#### BIBLIOGRAFIA BÁSICA

James, G., Witten, D., Hastie, T., & Tibshirani, R. An introduction to statistical learning. New York: springer, 2013. Disponível em: <https://www.statlearning.com/>

IZBICKI, Rafael; DOS SANTOS, Tiago Mendonça. **Aprendizado de máquina: uma abordagem estatística**. Rafael Izbicki, 2020. Disponível em: <http://www.rizbicki.ufscar.br/AME.pdf>

#### BIBLIOGRAFIA COMPLEMENTAR

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. The elements of statistical learning: data mining, inference, and prediction. Springer Science & Business Media, 2009. Disponível em: <https://web.stanford.edu/~hastie/ElemStatLearn/>

EFRON, Bradley; HASTIE, Trevor. Computer age statistical inference. Cambridge University Press, 2021 (corrected version). Disponível em: <https://web.stanford.edu/~hastie/CASI/index.html>

Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). Deep learning. Cambridge: MIT press.

PATHAK, Manas A. Beginning data science with R. Springer, 2014.

RAMASUBRAMANIAN, Karthik; SINGH, Abhishek. Machine Learning Using R: With Time Series and Industry-Based Use Cases in R. Apress, 2018.

Aprovado pelo Colegiado em \_\_\_\_ / \_\_\_\_ / \_\_\_\_



Robson Bruno Dutra Pereira

Allexandre Fortes da Silva Reis