

Plano de Ensino

01. Dados de Identificação da Disciplina:

Semestre:	2026.2	Curso:	Matemática Aplicada E Computacional
Turma:	A	Código Componente:	IME0546
Componente:	TÓPICOS EM MATEMÁTICA APLICADA	UA Responsável:	IME
Carga Horária:	64	UA Solicitante:	IME
Teórica/Prática:	64/-	EAD/PCC:	-/-
Horários:	24T56	Docente:	Prof(a) David Henriques Da Matta

02. Ementa:

Fundamentos de aprendizado estatístico: diferença entre aprendizagem supervisionada e não supervisionada; relação entre precisão e interpretabilidade de modelos. Regressão linear: simples, múltipla e extensões. Técnicas de classificação: regressão logística, análise discriminante e comparação entre métodos. Métodos de reamostragem: validação cruzada e trade-off entre viés e variância. Estratégias de seleção e regularização de modelos: subset selection, ridge e lasso. Modelos baseados em árvores: árvores de decisão, bagging, random forests e boosting. Support Vector Machine (SVM).

03. Programa:

- 1) Fundamentos do aprendizado estatístico: conceitos básicos de aprendizado estatístico; diferença entre aprendizado supervisionado e não supervisionado; relação entre precisão e interpretabilidade de modelos; introdução aos tipos de variáveis e estrutura dos dados; métricas de avaliação de modelos.
- 2) Regressão linear: regressão linear simples; regressão linear múltipla: seleção de variáveis e diagnóstico de modelo. Extensões: regressão por splines.
- 3) Técnicas de classificação: regressão logística; análise discriminante linear (LDA) e quadrática (QDA); comparação entre métodos de classificação (curvas ROC); implementação prática e interpretação dos resultados.
- 4) Métodos de reamostragem: validação cruzada k-fold; bootstrap; trade-off entre viés e variância; aplicação prática de métodos de reamostragem em seleção de modelos.
- 5) Seleção e regularização de modelos: técnicas de subset selection: forward, backward, stepwise; regularização: ridge regression, lasso regression; comparação entre métodos de seleção e regularização; implementação e interpretação dos resultados.
- 6) Modelos baseados em árvores: árvores de decisão: construção, poda, interpretação; bagging e random forests: conceitos e implementação; boosting: Gradient Boosted Trees; comparação entre modelos baseados em árvores e outros métodos.
- 7) Support Vector Machines (SVM): conceito de margem ótima e vetores de suporte; kernel trick: kernels lineares e não lineares; parâmetros de ajuste e interpretação; aplicações práticas em dados reais; comparação entre SVM e outros classificadores.

04. Cronograma:

1. Fundamentos do aprendizado estatístico (4 aulas).
2. Regressão linear (6 aulas).
3. Técnicas de classificação (8 aulas).
4. Métodos de reamostragem (8 aulas).
5. Seleção e regularização de modelos (6 aulas).
6. Modelos baseados em árvores (14 aulas).
7. Support Vector Machines (10 aulas).
8. Avaliações (8 aulas).

05. Objetivos Gerais:

Desenvolver uma compreensão teórico-prática das técnicas estatísticas aplicadas ao aprendizado de máquina (Machine Learning) e promover o domínio das ferramentas computacionais, capacitando os alunos a resolver problemas reais em diferentes contextos profissionais e de pesquisa.

06. Objetivos Específicos:

Ao final do curso, espera-se que os alunos sejam capazes de:

- Utilizar o software R para importar, organizar, limpar e processar dados;
- Aplicar métodos estatísticos de aprendizado de máquina para análise de dados, realizando inferências, previsões e classificações;
- Compreender as vantagens e limitações dos diferentes métodos abordados;
- Interpretar e comunicar os resultados de forma crítica e contextualizada;
- Desenvolver autonomia na busca e aplicação de novas técnicas e abordagens estatísticas.

07. Metodologia:

O curso será conduzido de modo que o aluno assuma papel ativo em seu processo de aprendizado, sendo responsável por construir e aprofundar o conhecimento sob a tutoria do docente. Além de introduzir conceitos e métodos fundamentais, o professor proporrá desafios que incentivem o desenvolvimento de competências essenciais para o enfrentamento de situações práticas e problemas que os alunos encontrarão após a graduação. As atividades incluirão aulas expositivas e dialogadas, uso de ferramentas computacionais (principalmente R), resolução de exercícios práticos, estudo de casos e discussão de artigos científicos relevantes. Será estimulada a autonomia dos alunos na exploração de conteúdos e no desenvolvimento contínuo de habilidades, promovendo uma integração entre teoria e prática.

08. Avaliações:

A avaliação do curso será contínua, baseada em apresentações desenvolvidas pelos próprios alunos ao longo do semestre. Cada apresentação terá nota atribuída de zero a dez e deverá contemplar tanto os aspectos conceituais quanto a aplicação prática das técnicas estudadas.

Os alunos serão organizados em grupos de, no máximo, três integrantes, sendo que a atribuição de notas será individual, levando em consideração a participação, o domínio do conteúdo e a qualidade da apresentação.

As datas das avaliações serão definidas em consenso com os alunos, de modo a respeitar o ritmo e o progresso das turmas. A nota final do curso corresponderá à média aritmética das notas obtidas nas apresentações realizadas ao longo do semestre.

Observações:

1. Essas datas poderão sofrer alterações.
2. Haverá prova substitutiva para o aluno que perder qualquer das atividades avaliativas, com ausência justificada e tenha solicitado uma segunda chamada em até 7 (sete) dias após a data de realização da avaliação.
3. O estudante poderá solicitar segunda chamada de avaliação de componentes curriculares à unidade acadêmica ou à unidade acadêmica especial responsável pelo componente curricular, de forma remota, até 7 (sete) dias após a data da realização da avaliação.
4. O aluno será aprovado se a média final (MF) for igual ou superior a 6 (seis) pontos e se tiver frequência igual ou superior a 0.75 da carga horária total da disciplina. Caso contrário será reprovado.
5. Os resultados serão disponibilizados via sistema SIGAA UFG.

09. Bibliografia:

[1]: FARAWAY, J. J. Linear models with R. Boca Raton: Chapman & Hall/CRC, 2004.

[2]: HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. The elements of statistical learning: data mining, inference, and prediction. 2. ed. New York: Springer, 2009.

10. Bibliografia Complementar:

[1]: LITTELL, R. C.; STROUP, W. W.; FREUND, R. J. SAS for linear models. Cary: SAS Institute, 2002.

[2]: BERK, R. A. Statistical learning from a regression perspective. New York: Springer, 2008.

[3]: WICKHAM, H.; GROLEMUND, G. R for data science. Sebastopol: O'Reilly, 2016.

[4]: SEARLE, S. R. Linear models. New York: Wiley, 1997.

[5]: DALGAARD, P. Introductory statistics with R. 2. ed. New York: Springer, 2008.

11. Livros Texto:

[1]: BERK, R. A. Statistical learning from a regression perspective. New York: Springer, 2008. (C2)

[2]: FARAWAY, J. J. Linear models with R. Boca Raton: Chapman & Hall/CRC, 2004. (B1)

[3]: HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. The elements of statistical learning: data mining, inference, and prediction. 2. ed. New York: Springer, 2009. (B2)

12. Horários:

Dia	Horário	Sala Distribuída
2 ^a	T5	208, CAA (50)
2 ^a	T6	208, CAA (50)
4 ^a	T5	104, CAA (24)
4 ^a	T6	104, CAA (24)

13. Horário de Atendimento do(a)s Professor(a):

1. Segunda-feira das 18:30h às 19:00h
2. Quarta-feira das 18:30h às 19:00h

14. Professor(a):

David Henriques Da Matta. Email: dhmatta@ufg.br, IME

Prof(a). David Henriques Da Matta