



EMENTA DA DISCIPLINA: ANÁLISE MULTIVARIADA APLICADA AS CIÊNCIAS FLORESTAIS

1. Fundamentos de Álgebra Linear e Probabilidade Multivariada: 1.1. Matrizes, vetores, autovalores e autovetores, 1.2. Matrizes de covariância e correlação, 1.3. Testes de esfericidade e tratamento de dados faltantes, 1.4. Outliers multivariados (Distância de Mahalanobis), 1.5. Aplicações em R (base, psych) e Python (numpy, scipy). 2. Variáveis Aleatórias Multivariadas: 2.1. Distribuições marginais e condicionais, 2.2. Distribuição normal multivariada, 2.3. Verificação de normalidade (Mardia, Royston), 2.4. Simulações e exemplos com R e Python. 3. Representação e Visualização de Dados Multivariados: 3.1. Perfis uni, bi e multivariados, 3.2. Biplots, gráficos canônicos e t-SNE, 3.3. Visualização com UMAP e ferramentas interativas, 3.4. Uso de ggplot2, seaborn, matplotlib, plotly. 4. Análise de Variância Multivariada (MANOVA): 4.1. Modelos multivariados, soma de quadrados, 4.2. Critérios de Wilks, Pillai, Roy, Hotelling, 4.3. Validação com bootstrap e PERMANOVA, 4.4. Exemplos com `vegan::adonis` e `statsmodels`. 5. Regressão Múltipla e Logística: 5.1. Diagnóstico de modelos, multicolinearidade, 5.2. Regularização: Ridge e Lasso, 5.3. Modelos logísticos binários e multinomiais, 5.4. Aplicação com `caret`, `glmnet`, `scikit-learn`. 6. Aprendizado Supervisionado: 6.1. Árvores de decisão, Random Forests, Boosting, 6.2. Comparações com métodos clássicos (LDA, Logística), 6.3. Cross-validation, tuning e métricas de performance, 6.4. Ferramentas: `rpart`, `randomForest`, `xgboost`, `sklearn`. 7. Análise de Componentes Principais (PCA): 7.1. Redução de dimensionalidade e interpretação, 7.2. Critérios de retenção: Kaiser, scree plot, análise paralela, 7.3. Visualização em 2D/3D, 7.4. Implementação: `prcomp`, `FactoMineR`, `sklearn.decomposition`. 8. Análise Fatorial Exploratória: 8.1. Modelos fatoriais, cargas e comunalidades, 8.2. Extração: máxima verossimilhança e mínimos quadrados, 8.3. Rotações ortogonais e oblíquas, 8.4. Avaliação com KMO e testes de esfericidade. 9. Análise de Agrupamento: 9.1. Distâncias: Euclidiana, Mahalanobis, Gower, 9.2. Métodos hierárquicos e não hierárquicos, 9.3. Validação com índice de Silhouette, Gap, 9.4. Aplicações com cluster, `fpc`, `sklearn.cluster`. 10. Técnicas de Ordenação Ecológica: 10.1. Análise de correspondência (CA, CCA), 10.2. Escalonamento Multidimensional (MDS e NMDS), 10.3. Avaliação de stress e Shepard plot, 10.4. Uso de `vegan`, `scikit-bio`. 11. Análise Discriminante: 11.1. LDA, QDA, funções discriminantes, 11.2. Validação cruzada (`jackknife`, `LOOCV`), 11.3. Classificação e comparação com ML, 11.4. Ferramentas: `MASS::lda`, `sklearn.discriminant_analysis`. 12. Correlação Canônica e PLS, 12.1. Coeficientes canônicos, variáveis latentes, 12.2. Inferência e interpretação, 12.3. Introdução ao Partial Least Squares (PLS), 12.4. Uso com CCA, `pls`, `sklearn.cross_decomposition`

Bibliografia:

- Boone, E. L., et al. Applied Statistics with R and Python. Springer, 2020.
Geron, A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. O'Reilly, 2019.
Hair, J. F., et al. Multivariate Data Analysis. Cengage, 2019.
James, G., et al. An Introduction to Statistical Learning with Applications in R. Springer, 2021.
Kassambara, A. Practical Guide to Cluster Analysis in R; Multivariate Analysis in R. STHDA, 2017–2020.
Lantz, B. Machine Learning with R: Expert techniques for predictive modeling. Packt, 2021.
Manly, B. F. J. Métodos estatísticos multivariados: uma introdução. Bookmam, 2019.
Queiroz, W. T. Análise Multivariada em inventário Florestal. Poisson, 2021.
Reis, P. C. R. Agrupamento de espécies madeireiras da Amazônia com base em propriedades físicas e mecânicas. Ciência florestal, 2019.
Silva, R. A. Métodos de análise multivariada em R. FEALQ, 2016.