

# Topicos em Inteligência Artificial: Aprendizado de Máquina para Ciências com Regressão Simbólica

November 2023

## 1 Sobre o professor

- **Professor:** Fabrício Olivetti de França
- **E-mail:** folivetti@ufabc.edu.br
- **Site:** <https://folivetti.github.io/>

## 2 Objetivos

Aprendizado de Máquina para Ciências (ou em inglês, *Scientific Machine Learning* - SciML) é uma área emergente que tem por objetivo principal a busca por um modelo preditivo que seja aderente a certas características de interesse e forneça informações relevantes para o fenômeno estudado. Essa área reduz o foco do modelo criado apenas para predição e estimula o uso do modelo como parte de uma investigação científica para a extração de conhecimento. A Regressão Simbólica é conhecida como um modelo de regressão não-linear cujas características permitem a criação de modelos interpretáveis, incorporando conhecimento de domínio, e que permitem a análise de incertezas por padrão. Esse curso tem o objetivo principal de ensinar sobre os conceitos principais de Regressão Simbólica contextualizados em SciML e como utilizar tal ferramenta para extração de conhecimento de dados diversos.

## 3 Metodologia

Aulas expositivas dos conteúdos abordados pelo professor com demonstrações do uso das ferramentas de regressão. A avaliação da disciplina será feita através da escrita de um artigo científico aplicando os conceitos da disciplina em uma base de dados de interesse.

## **4 Planejamento Semanal**

### **4.1 Semana 01**

1. Introdução à disciplina
2. Conceitos básicos de aprendizado de máquina

### **4.2 Semana 02**

1. Fériado de carnaval

### **4.3 Semana 03**

1. Análise de Regressão e Modelos Paramétricos
2. Regressão Simbólica

### **4.4 Semana 04**

1. Regressão simbólica: Programação Genética
2. Regressão Simbólica: outras abordagens

### **4.5 Semana 05**

1. Ferramentas de regressão simbólica: SRBench, srtree-opt
2. Gráficos de avaliação de modelo

### **4.6 Semana 06**

1. Função distribuição e verossimilhança
2. Exemplos de dados de diferentes distribuições

### **4.7 Semana 07**

1. Otimização não-linear dos coeficientes
2. Implementando um algoritmo de otimização

### **4.8 Semana 08**

1. Validação de Modelo
2. Seleção de Modelo

## **4.9 Semana 09**

1. Simplificação de Modelo
2. Integrando conhecido pré-existente

## **4.10 Semana 10**

1. Feriado (08 de abril)
2. Extrairando informações do modelo

## **4.11 Semana 11**

1. Incertezas: intervalos de confiança e predição
2. Incertezas: profile likelihood

## **4.12 Semana 12**

1. Apresentação dos resultados dos artigos
2. Apresentação dos resultados dos artigos

## **4.13 Semana 13 (restituição)**

1. Considerações finais (30 de abril - terça-feira)
2. Revisão final dos artigos (03 de maio - sexta-feira)

# **5 Referências Bibliográficas**

## **References**

- [1] Guilherme Seidyo Imai Aldeia and Fabrício Olivetti de França. “Measuring feature importance of symbolic regression models using partial effects”. In: *Proceedings of the Genetic and Evolutionary Computation Conference*. 2021, pp. 750–758.
- [2] Douglas Bates. “Nonlinear regression analysis and its applications”. In: *Wiley Series in Probability and Statistics* (1988).
- [3] Brian C Falkenhainer and Ryszard S Michalski. “Integrating quantitative and qualitative discovery: the ABACUS system”. In: *Machine Learning* 1 (1986), pp. 367–401.
- [4] Fabricio Olivetti de Franca and Gabriel Kronberger. “Prediction Intervals and Confidence Regions for Symbolic Regression Models based on Likelihood Profiles”. In: *arXiv preprint arXiv:2209.06454* (2022).

- [5] Fabricio Olivetti de Franca and Gabriel Kronberger. “Reducing Overparameterization of Symbolic Regression Models with Equality Saturation”. In: *Proceedings of the Genetic and Evolutionary Computation Conference*. 2023, pp. 1064–1072.
- [6] Andrew Gelman and Jennifer Hill. *Data analysis using regression and multilevel/hierarchical models*. Cambridge university press, 2006.
- [7] Andrew Gelman, Jennifer Hill, and Aki Vehtari. *Regression and other stories*. Cambridge University Press, 2020.
- [8] Donald Gerwin. “Information processing, data inferences, and scientific generalization”. In: *Behavioral Science* 19.5 (1974), pp. 314–325.
- [9] Gareth James et al. *An introduction to statistical learning*. Vol. 112. Springer, 2013.
- [10] John R Koza. *Genetic programming: A paradigm for genetically breeding populations of computer programs to solve problems*. Vol. 34. Stanford University, Department of Computer Science Stanford, CA, 1990.
- [11] Gabriel Kronberger et al. “Shape-constrained symbolic regression—improving extrapolation with prior knowledge”. In: *Evolutionary computation* 30.1 (2022), pp. 75–98.
- [12] William La Cava et al. “Contemporary symbolic regression methods and their relative performance”. In: *arXiv preprint arXiv:2107.14351* (2021).
- [13] Pat Langley. “Data-driven discovery of physical laws”. In: *Cognitive Science* 5.1 (1981), pp. 31–54.
- [14] Christoph Molnar. *Interpretable machine learning*. Lulu. com, 2020.
- [15] Jorge Nocedal and Stephen J Wright. *Numerical optimization*. Springer, 1999.
- [16] Patryk Orzechowski, William La Cava, and Jason H Moore. “Where are we now? A large benchmark study of recent symbolic regression methods”. In: *Proceedings of the Genetic and Evolutionary Computation Conference*. 2018, pp. 1183–1190.
- [17] Paul Roback and Julie Legler. *Beyond multiple linear regression: applied generalized linear models and multilevel models in R*. CRC Press, 2021.
- [18] Max Willsey et al. “Egg: Fast and extensible equality saturation”. In: *Proceedings of the ACM on Programming Languages* 5.POPL (2021), pp. 1–29.