

MM845 - Tópicos de Geometria III

Total de créditos: 2

Total de horas/aulas semanais: 4h (duração do curso: 8 semanas)

Horários: Terça 16:00 — 18:00; Quinta 16:00 — 18:00

Ementa:

Concepção e aplicação de métodos de aprendizado de máquina para a investigação de problemas em geometria e matemática. Fundamentos computacionais: programação científica em Python, controle de versão e reprodutibilidade aplicados a experimentos geométricos. Fundamentos matemáticos do aprendizado de máquina sob interpretação geométrica: formulações variacionais, otimização em dimensão alta, aproximação de funções e análise espectral. Modelos lineares, regressão logística e regularização para a modelagem de propriedades geométricas. Redes neurais como espaços de funções para a aproximação de quantidades geométricas; retropropagação e geometria do espaço de parâmetros. Redes convolucionais como operadores compatíveis com simetrias. Mecanismos de atenção e transformers sobre dados geométricos estruturados. Aprendizado não supervisionado para a descoberta de estrutura: agrupamento, métodos espectrais e redução de dimensionalidade (PCA, kernel PCA, t-SNE, UMAP) sobre variedades, grafos e complexos simpliciais. Aprendizado por reforço em contextos combinatórios e geométricos. Aprendizado de máquina geométrico: equivariância, ações de grupos de Lie, redes neurais em grafos e fundamentos geométricos dos modelos de difusão. Redes neurais informadas pela física (PINNs) para EDPs geométricas elípticas, não lineares e dependentes do tempo (Laplace-Beltrami, fluxos de curvatura), integrando análise numérica clássica e aprendizado profundo.

Referências:

1. P. Rigollet, 18.657: Mathematics of Machine Learning — Lecture Notes, MIT OpenCourseWare, Massachusetts Institute of Technology, 2015.
2. A. Géron, Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow, 2019.
3. K. Gurney, An Introduction to Neural Networks, CRC Press, 2018.
4. F. Ruehle, Data science applications to string theory, Physics Reports, vol. 839, pp. 1–117, 2020.
5. S. Cuomo, V. Schiano Di Cola, F. Giampaolo, G. Rozza, M. Raissi, F. Piccialli, Scientific Machine Learning Through Physics-Informed Neural Networks: Where We Are and What's Next, Journal of Scientific Computing, vol. 92, no. 3, art. 88, 2022.
6. J. Ma, W. Wang, Q. Jin, A Survey of Deep Learning for Geometry Problem Solving, arXiv:2507.11936, 2025.
7. A. Paszke et al., PyTorch: An Imperative Style, High-Performance Deep Learning Library, arXiv:1912.01703, 2019.