

INFORMAÇÃO DE DISCIPLINAS COMPARTILHADAS

Pós => MT861 - Tópicos em Aprendizagem de Matemática Aplicada e Computacional
+ Grad => MS901 - Tópicos Especiais de Matemática Aplicada.

RESPONSÁVEIS:

Docentes: Eduardo Abreu (30 horas) e João Florindo (30 Horas)

Nível: Pós-Graduação com Espelho na Graduação - Curso 28

> TÍTULO DA DISCIPLINA.

"MT861 - Tópicos em Aprendizagem de Matemática Aplicada e Computacional"
<https://www.dac.unicamp.br/sistemas/catalogos/posgrad/catalogo2025/unidade/imecc339/disciplinas.html#MT861>

"MS901 - Tópicos Especiais de Matemática Aplicada"
<https://www.dac.unicamp.br/sistemas/catalogos/grad/catalogo2025/disciplinas/ms.html#disc-ms901>

VISÃO GERAL E ESCOPO DAS DISCIPLINAS COMPARTILHADAS (MT861 & MS901) em 1s/2026.

Nesta oportunidade, a disciplina Tópicos em Aprendizagem de Matemática Aplicada e Computacional vai abordar uma integração de Machine Learning com Matemática de análise numérica para modelos de equações diferenciais parciais lineares e não lineares, combinando os princípios da matemática com a tecnologia e as ciências computacionais para resolver problemas do mundo real. Abrange a aplicação de modelos matemáticos, métodos numéricos e algoritmos computacionais em diversas áreas, como física, engenharia, finanças e bioinformática. O objetivo é integrar e combinar técnicas de machine learning com uma base sólida em matemática e computação, ancorado em resultados de análise numérica capazes de atuar em ensino, pesquisa, desenvolvimento e resolução de desafios complexos motivados por problemas emergentes no mundo real. Por exemplo, no vasto universo da matemática aplicada e computacional, existe uma área específica que preenche a lacuna entre a teoria abstrata e o mundo tangível: a análise numérica (AN). Essa disciplina matemática concentra-se na criação de algoritmos para aproximar soluções de problemas complexos - um sólido

pilar fundamental no âmbito da computação emergente, mais especificamente, no domínio da inteligência artificial (IA) e no aprendizado de máquina (AM). IA/AM podem ajudar (e revisitar perspectivas) em problemas clássicos de análise numérica, como a aproximação de soluções de certas classes de equações diferenciais ordinárias/parciais (tipicamente com soluções suaves/regulares), particularmente em ambientes de alta dimensão, bem como em problemas envolvendo uma quantidade massiva de dados a serem tratados, incluindo a noção de incerteza/precisão das informações disponíveis. Essa disciplina "MT861 - Tópicos em Aprendizagem de Matemática Aplicada e Computacional" concentra-se na integração de certos conceitos fundamentais de disciplinas clássicas de Análise Numérica e Inteligência Artificial, visando compreender certos conceitos fundamentais de estabilidade, robustez e eficácia, mas agora dos sistemas de aprendizado de máquina. A análise numérica é útil também para: (1) identificar e compreender erros numéricos. (2) aprender algoritmos de computação numérica para resolver equações diferenciais, sistemas lineares, diferenciação e integração. Tudo isso é absolutamente crucial em aplicações, por exemplo, em estatística computacional. No curso da implementação da teoria, (1) e (2) abrem muitos problemas em ciências de modo geral e também são ferramentas importantes em pesquisa e inovação tecnológica.

> **EMENTA.** Conceitos base de Machine Learning, Motivação de modelos matemáticos baseados em equações diferenciais (ordinárias/parciais), Rudimentos de Análise Numérica, Interação entre os diversos aspectos teóricos, numéricos e aplicações de Matemática Aplicada e Computacional, Formulação das redes neurais do tipo PhysicsInformed Neural Networks (PINN), Variações de PINNs, Desafios atuais e perspectivas.

> **CONTEÚDO PROGRAMÁTICO E OBJETIVO.** O curso vai se concentrar sobre Aprendizagem de Matemática Aplicada e Computacional via integração balanceada de Machine Learning com Matemática de Análise Numérica para modelos de equações diferenciais parciais lineares e não lineares para resolução de modelos complexos motivados por desafios contemporâneos do mundo real. Como um referencial aos estudantes de Graduação, é necessário e oportuno registrar que será considerado

resultados das disciplinas básicas do núcleo do Cursão 51 (três primeiros semestres) em linha com a literatura especializada conforme a ementa e indicada na bibliografia. A disciplina de Pós-Graduação em Matemática Aplicada “MT861 - Tópicos em Aprendizagem de Matemática Aplicada e Computacional ” será acompanhada da disciplina avançada de Graduação “MS901 - Tópicos Especiais de Matemática Aplicada”, sendo oferecida em conjunto no 1S/2026.

> **METODOLOGIA DE ENSINO.** Aulas expositivas para introdução dos conceitos fundamentais além das ideias-chave material indicado na bibliografia com forte aderência com o conteúdo programático, e apresentação dos resultados na forma de seminários em sala de aula.

> **PRÉ-REQUISITOS.** Não há um pré-requisito formal. Contudo, o curso será naturalmente baseado na literatura atual, com certa ênfase na lista de referências posta na bibliografia. Espera-se que o público interessado tenha interesse e independência para estudar ativamente o material indicado, considerando uma interação mais avançada entre os aspectos teóricos, numéricos e aplicações em Machine Learning com Matemática de Análise Numérica para modelos de equações diferenciais parciais lineares e não lineares para resolução de modelos complexos motivados por desafios contemporâneos do mundo real Novamente, apenas como um referencial aos estudantes de Graduação, é necessário e oportuno registrar que será considerado resultados das disciplinas básicas do núcleo do Cursão 51 (três primeiros semestres) em linha com a literatura especializada conforme a ementa e indicada na bibliografia.

> **CRITÉRIO DE AVALIAÇÃO E CONCEITO.** Nota para a Graduação (0 até 10). Para estudantes matriculados de Graduação e de Pós-Graduação, a avaliação será por meio da apresentação de seminários e/ou relatório (tipicamente entreg/controla via o google classroom), conforme demanda de matrículas nesta disciplina, porém obrigatoriamente sobre os temas que estão norteados pela bibliografia sugerida a seguir. Nesta disciplina MT856 o conceito final será Suficiente (S) ou Insuficiente (I) para estudantes matriculados de Pós-Graduação e nota usual na escala da DAC de 0 (zero) até 10 (dez) de para estudantes matriculados de Graduação.

> BIBLIOGRAFIA.

- Juan Diego Toscano, Vivek Oommen, Alan John Varghese, Zongren Zou, Nazanin Ahmadi Daryakenari, Chenxi Wu, George Em Karniadakis (2025). From PINNs to PIKANs: recent advances in physics-informed machine learning. *Mach. Learn. Comput. Sci. Eng* 1, 15. <https://doi.org/10.1007/s44379-025-00015-1>
- E. Abreu, J. Florindo, W. Lambert (2024). A PDE-informed and Physics-informed neural network for learning weak solutions in two-dimensional conservation laws, 9th European Congress on Computational Methods in Applied Sciences and Engineering, 2024).
- J. B. Florindo and E. Abreu, (2024). A pseudo-parabolic diffusion model to enhance deep neural texture features. *Multimedia Tools and Applications*, 83(4), 11507-11528.
- S. J. Prince, (2023). *Understanding deep learning*. MIT press.
- J. Vieira, E. Abreu, and J. B. Florindo (2023). Texture image classification based on a pseudo-parabolic diffusion model. *Multimedia Tools and Applications*, 82(3), 3581-3604.
- R. A. F. Carniello, J. B. Florindo and E. Abreu (2022). A PINN computational study for a scalar 2d inviscid burgers model with riemann data. 8th European Congress on Computational Methods in Applied Sciences and Engineering.
- S. Kollmannsberger, D. D'Angella, M. Jokeit, and L. Herrmann (2021). *Deep learning in computational mechanics* (pp. 55-84). Springer International Publishing.
- J. B. Florindo and E. Abreu (2021). An application of a pseudo-parabolic modeling to texture image recognition. *International Conference on Computational Science* (pp. 386-397). Cham: Springer International Publishing.
- E. Abreu and J. B. Florindo (2021). A study on a feedforward neural network to solve partial differential equations in hyperbolic-transport problems. *International Conference on Computational Science* (pp. 398-411). Cham: Springer International Publishing.
- M. Raissi, P. Perdikaris, and G. E. Karniadakis (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational physics*, 378, 686-707.
- A. Bartel and M. Gunther, PDAEs in Refined Electrical Network Modeling *SIAM Rev.*, 60(1) (2018) 56-91. -- Mayer Humi, *Introduction to mathematical modeling*, Taylor & Francis Group, 2017. -- Ka-Kit Tung. *Topics in mathematical modeling*. Princeton University Press, 2007.