

---

CURSO: Ciência de Dados e Inteligência Artificial – 2o semestre de 2023  
DISCIPLINA: **Otimização para Ciência de Dados**  
PROFESSOR(ES): **Fernanda Maria Pereira**  
CARGA HORÁRIA: 60h: 3as e 5as de 11:10h as 12:50h  
PRÉ-REQUISITO: Álgebra Linear, Probabilidade e Cálculo em Várias Variáveis  
HORÁRIO E SALA DE ATENDIMENTO: 3as de 14:00h as 15:00h  
SALA: 502

**COMPLEMENTAÇÃO DE CARGA HORÁRIA: 2 aulas de 1h40min**

## PLANO DE ENSINO

### 1. Ementa

Conjuntos convexos; Funções convexas; Otimização não linear irrestrita, Condições de Existência e de Otimalidade; Métodos de otimização unidimensional; Método de Gradientes Conjugados; Método do gradiente; Método de Newton; Métodos quase Newton; Métodos de Buscas Diretas; Métodos de Gradientes Descendentes.

### 2. Objetivos da disciplina

Esta disciplina tem como objetivo geral abordar ferramentas matemáticas, com entendimento teórico e prático, com vista a resolver computacionalmente problemas de otimização contínua sem restrições. Especificamente, o(s) objetivo(s) será (ão): apresentar o conteúdo teórico durante as aulas, dar exemplos de aplicação de conteúdo, fazer exercícios em aula e distribuir trabalho de implementação computacional de algoritmos.

### 3. Procedimentos de ensino (metodologia)

As aulas serão ministradas com apoio de notas de aula, que cobrem todos os tópicos da disciplina. Depois de cada tópico apresentado, um exemplo específico é apresentado. Listas de exercícios serão distribuídas para testarem os conhecimentos dos alunos, e ainda será cobrado dos alunos um trabalho de implementação de algoritmos, além da aplicação de duas provas.

#### 4. Conteúdo programático detalhado

Datas	Tópico	Atividades
08/08	Introdução à modelagem matemática de problemas reais.	Exposição
10/08 a 29/08	Métodos numéricos básicos: aproximação de funções, raízes de funções, sistemas de equações lineares e não lineares, interpolação, mínimos quadrados lineares e não lineares, autovalores e autovetores. (6 aulas)	Exposição e exemplos
31/08	Otimização contínua irrestrita: notação, conceitos básicos e existência de soluções	Exposição
05/09	Funções unimodais e métodos de otimização unidimensional	Exposição e exemplos
12/09	Condições necessárias e suficientes de otimalidade	Exposição e exemplos
14/09	Aula de exercícios	Exercícios
19/09	Problema geral de otimização contínua e resolução de problemas fáceis	Exposição e exemplos
21/09	Convexidade	Exposição e exemplos
26/09	Construção de algoritmos de otimização	Exposição
28/09	Algoritmos de otimização baseados em derivadas	Exposição
02/10 a 09/10	Semana da A1	
10/10	Direção de descida e classificação de convergência	Exposição
17/10	Gradientes conjugados para funções quadráticas	Exposição e exemplos
19/10	Gradientes conjugados de Fletcher&Reeves	Exposição e exemplos
24/10	Método do gradiente	Exposição e exemplos
26/10	Método de Newton e métodos quase-Newton	Exposição e exemplos
31/10	Algoritmos de buscas diretas (sem uso de derivadas)	Exposição e exemplos
07/11	Algoritmos de Nelder & Mead, MDS e Pattern Search	Exposição e exemplos
09/11	Algoritmos de gradientes descendentes	Exposição e exemplos
14/11	Variantes de gradientes descendentes	Exposição
16/11	Apresentação de trabalhos de implementacao	Exposição pelos alunos
21/11	Apresentação de trabalhos de implementacao	Exposição pelos alunos
23/11	Aula de exercícios	Exercícios
27/11 a 04/12	Semana da A2	
14/12 a 20/12	Semana da AS	

#### 5. Procedimentos de avaliação

Serão aplicadas duas provas e um trabalho de implementação computacional. Cada prova têm nota máxima 10, e o trabalho de implementação pode valer de zero a 1 na média final.

## 6. Bibliografia Obrigatória

- S. Boyd, L. Vanderberghe. Convex Optimization. Cambridge University Press, 2004.  
P. E. Gill, W. Murray, M. H. Wright, Practical Optimization, 1982.  
J. Nocedal and S. J. Wright, Numerical Optimization, 2nd Ed, Springer, 2006.  
M. S. Bazaraa, H. D. Sherali, C. M. Shetty, Nonlinear Programming Theory and Algorithms, Ed. atual 2013.

## 7. Bibliografia Complementar

- Kecman, Vojislav. Learning and soft computing: support vector machines, neural networks, and fuzzy logic models. MIT press, 2001.  
T. Hastie, R. Tibshirani, J. Friedman. The elements of statistical learning, Springer. 2009.  
J. Nocedal, S. J. Wright, Numerical Optimization, 2nd Ed, Springer, 2006.  
P. Pedregal, Introduction to Optimization, Springer, 2004.  
Friedlander, A., Elementos de Programação Não-Linear, disponível na Internet.  
S. Bubeck, Convex optimization: Algorithms and complexity. *Foundations and Trends® in Machine Learning* 8.3-4 (2015): 231-357.  
C. T. Kelley, Iterative methods for Optimization, SIAM Book, ed. 1999.  
J. M. Martínez, S. A. Santos. Métodos Computacionais de Otimização. Departamento de Matemática Aplicada. IMECC-UNICAMP. 1995, disponível na Internet.  
Wendel Melo. Introdução às Redes Neurais Artificiais, slides de aulas, Faculdade de Computação, Universidade Federal de Uberlândia  
Ivan Nunes da Silva et al., Redes Neurais Artificiais para Engenharia e Ciências Aplicadas. Artliber, 2ª edição 2016.

## 8. Minicurrículo do(s) Professor(s)

Possui graduação em Matemática pela Universidade Federal do Rio de Janeiro (1987), mestrado (1991) e doutorado (1998) em Engenharia de Sistemas e Computação pela Universidade Federal do Rio de Janeiro. Atuou em atividades de ensino e pesquisa no LNCC até 2007. Foi professora do quadro principal do Departamento de Engenharia Industrial da PUC-Rio de 2007 a 2013, voltando a ser professora horista de 2017 a 2019. Atuou na coordenação de projetos de pesquisa e de expansão e obras no IMPA de 2014 a 2021. Desde 2021, está envolvida em atividades de ensino na Escola de Matemática Aplicada da FGV, no curso de graduação em Ciência de Dados e Inteligência Artificial.

## 9. Link para o Currículo Lattes