



Plano de Desenvolvimento da Disciplina

MC826(MO431) - Fundamentos de Álgebra Linear e Otimização para Aprendizado de Máquina

Docente: Prof. Marcos M. Raimundo

Descrição

Este documento descreve, de forma sucinta, o plano de desenvolvimento da disciplina (PDD) de MC826(MO431) - Álgebra linear e otimização para aprendizado de máquina. Em particular, são destacados, de acordo com os requisitos do Regimento Geral de Graduação, o cronograma de atividades, os critérios de avaliação, punição para fraudes e plágios e a bibliografia a ser utilizada ao longo do semestre.

1. Programa da disciplina

O programa desta turma da disciplina cobrirá, em diferentes níveis de profundidade, tópicos relacionados à aplicação da Álgebra Linear em Machine Learning (ML). O objetivo terminal da disciplina é capacitar o aluno a: a) Compreender como a Álgebra Linear fundamenta os principais algoritmos de aprendizado de máquina, permitindo uma análise mais profunda de seu funcionamento e potencialidades. b) Aplicar os conceitos de Álgebra Linear para otimizar o desempenho de modelos de ML, utilizando técnicas como o gradiente descendente e suas variações. Para isso, serão abordados os seguintes assuntos:

- **Conteúdo 1:** Regressão Linear, Vetores e Matrizes
- **Conteúdo 2:** PCA, Base e Posto, Transformações Lineares e Espaços Afins
- **Conteúdo 3:** k-NN, Produtos Internos, Distâncias, Ângulos e Ortogonalidade
- **Conteúdo 4:** SVMs, Base Ortonormal, Complemento Ortonormal, Produto Interno de Funções, Projeções Ortonormais, Rotações
- **Conteúdo 5:** GMMs, Determinantes, Traço, Autovalores e Autovetores, Decomposição de Cholesky e Decomposições Espectrais
- **Conteúdo 6:** Filtragem Colaborativa, SVD, Aproximação de Matrizes e Filogenia de Matrizes
- **Conteúdo 7:** Regressão Logística, Diferenciação Parcial e Gradientes, Gradiente de Funções Vetoriais, Gradiente de Matrizes
- **Conteúdo 8:** Redes Neurais, Backpropagation, Diferenciação Automática, Derivadas de Ordem Superior, Linearização e Séries de Taylor

- **Conteúdo 9:** Teorema de Taylor, Caracterização de Mínimos de Funções Suaves, Conjuntos e Funções Convexas, Funções Fortemente Convexas
- **Conteúdo 10:** Métodos de Descida, Caso Geral, Caso Convexo, Caso Fortemente Convexo, Comparação entre Taxas de Convergência
- **Conteúdo 11:** Métodos de Busca Linear, Convergência para Pontos de Segunda Ordem Necessários, Descida Espelhada, Propriedades KL e PL
- **Conteúdo 12:** Métodos de Gradiente com Momentum, Motivação, Método de Nesterov, Convergência para Funções Fortemente Convexas
- **Conteúdo 13:** Gradiente Descendente Estocástico

Cada conteúdo será coberto com um determinado número de aulas, que deverá variar entre uma e duas aulas.

2. Atividades

A avaliação da disciplina de Álgebra Linear para Machine Learning será composta por quizzes semanais (40%), atividades práticas (30%) e uma avaliação teórica final (30%). Os quizzes semanais visam a acompanhar o aprendizado contínuo dos alunos e fornecer feedback rápido. As atividades práticas permitirão a aplicação dos conceitos em problemas reais de aprendizado de máquina, todas as atividades práticas deverão ser implementadas usando Jax. Enquanto a avaliação teórica final avaliará a compreensão global dos alunos, essa atividade poderá ser uma prova presencial ou entregue em 24 horas. A participação e colaboração serão incentivadas, mas não formalmente avaliadas. Os critérios de avaliação e o feedback individualizado serão fornecidos aos alunos, e a avaliação poderá ser adaptada para diferentes modalidades de ensino.

3. Critérios de avaliação

A avaliação do curso será baseada em três componentes principais: quizzes semanais (Q), atividades práticas (P) e uma avaliação teórica final (T). A nota final (NF) será calculada da seguinte forma:

$$NF = 0.4Q + 0.3P + 0.3T$$

onde:

- Q é a média ponderada das notas dos quizzes semanais (40% do total).
- P é a média aritmética das notas das atividades práticas (30% do total).
- T é a nota da avaliação teórica final (30% do total).

As prova individual será aplicada no dia **25 de novembro**.

Essa estrutura de avaliação busca promover o aprendizado contínuo através dos quizzes semanais, a aplicação prática dos conceitos nas atividades e a consolidação do conhecimento teórico na avaliação final.

Para a pós-graduação (MO431) e alunos de graduação cursando simultaneamente, o sistema de conceitos irá se basear nas seguintes notas:

A - Acima de 8,5.

- B - Entre 7 e 8,5.
- C - Entre 5,5 e 7.
- D - Abaixo de 5,5.

4. Punição para fraudes e plágios

Detecção de fraude ou plágio em um trabalho ou quiz implica em nota zero para todos os envolvidos (quem recebeu ajuda e também quem ajudou) na atividade específica. Reincidência implica em $NF = 0$ para todos os envolvidos. Detecção de plágio em prova implica em $NF = 0$.

5. Bibliografia a ser utilizada

O docente se baseará fortemente nas seguintes referências:

- Deisenroth, Marc Peter, A. Aldo Faisal, and Cheng Soon Ong. Mathematics for machine learning. Cambridge University Press, 2020.
- Wright, Stephen J., and Benjamin Recht. Optimization for data analysis. Cambridge University Press, 2022.
- Boyd, Stephen, and Lieven Vandenberghe. Introduction to applied linear algebra: vectors, matrices, and least squares. Cambridge university press, 2018.
- Boyd, Stephen, and Lieven Vandenberghe. Convex optimization. Cambridge university press, 2004.