



Plano de Desenvolvimento da Disciplina

MC847 - Aprendizado Não Supervisionado

Docente: Prof. Marcos M. Raimundo

Descrição

Este documento descreve o plano de desenvolvimento da disciplina (PDD) de MC847 - Aprendizado Não Supervisionado e de Representação. Em conformidade com o Regimento Geral da Unicamp, este plano detalha o programa do curso, a fundamentação teórica dos blocos de conteúdo, o cronograma das avaliações, os critérios de nota, a política contra fraudes e plágio e a bibliografia recomendada.

1 Programa da disciplina

O programa desta disciplina aborda os fundamentos do Aprendizado de Máquina Não Supervisionado sob uma perspectiva probabilística, estatística e de Teoria da Informação. O objetivo terminal é capacitar o aluno a: a) Modelar a estrutura subjacente e a distribuição de dados não rotulados; b) Conectar algoritmos práticos de agrupamento, redução de dimensionalidade e aprendizado auto-supervisionado às suas raízes teóricas (estimação de densidade, modelos de variáveis latentes e maximização de informação mútua); c) Formular e implementar abordagens rigorosas para descoberta de padrões e extração de representações em dados complexos.

O curso está organizado em três blocos principais:

- **Bloco 1: Estruturas de Densidade e Agrupamento (Clustering e Variáveis Latentes)**

Objetivo: Compreender como modelar distribuições empíricas e estimar topografias de densidade locais e globais em dados não rotulados.

Conteúdo: Modelagem paramétrica generativa e detecção de anomalias por verossimilhança; espaços vetoriais de alta dimensão, maldição da dimensionalidade e Estimação de Densidade por Kernel (KDE); topografia de densidade, grafos e agrupamento hierárquico (HDBSCAN); Misturas de Gaussianas (GMM) e o algoritmo de Expectativa-Maximização (EM); seleção de modelos (BIC), Inferência Variacional e formulação do ELBO (*Evidence Lower Bound*).

- **Bloco 2: Redução de Dimensionalidade e Aprendizado Auto-Supervisionado**

Objetivo: Projetar manifolds e representações comprimidas conectando projeções algébricas lineares a modelos profundos não-lineares.

Conteúdo: Redução linear via PCA, Probabilistic PCA (PPCA) e Autoencoders lineares; Autoencoders não-lineares e Variational Autoencoders (VAE) com o truque da reparametrização; redução de dimensionalidade para visualização conservando estruturas locais e topológicas (MDS e t-SNE via divergência KL com distribuição *t*-Student).

- **Bloco 3: Descoberta de Informação e Estruturas de Larga Escala**

Objetivo: Extrair dependências complexas, alinhar distribuições e construir representações não supervisionadas robustas em grande escala.

Conteúdo: Mineração de regras de associação e Modelos Gráficos Probabilísticos (PGMs) para isolamento de variáveis de confusão; Sistemas de Recomendação via Fatoração Matricial (SVD Truncado e NMF com restrições de não-negatividade); detecção de *Data Drift* e desalinhamento de domínio via testes de hipótese não-paramétricos (Maximum Mean Discrepancy - MMD); Aprendizado de Representação Contrastivo fundamentado na maximização do limite inferior da Informação Mútua (perda InfoNCE).

2 Atividades e Avaliação

A avaliação da disciplina será composta por três testes teóricos/práticos individuais (T_1, T_2, T_3), aplicados ao longo do semestre ao término de cada bloco de conteúdo, e um Trabalho Final prático (TF) focado no desenvolvimento e análise rigorosa de um projeto em Aprendizado Não Supervisionado.

A nota final (NF) será calculada da seguinte forma:

$$NF = 0.20T_1 + 0.20T_2 + 0.20T_3 + 0.40TF$$

onde:

- T_1 é a nota do Teste 1 (com foco no Bloco 1), aplicado no dia **16 de setembro**.
- T_2 é a nota do Teste 2 (com foco no Bloco 2), aplicado no dia **21 de outubro**.
- T_3 é a nota do Teste 3 (com foco no Bloco 3), aplicado no dia **02 de dezembro**.
- TF é a nota do Trabalho Final (40% do total), a ser entregue no encerramento do semestre.

3 Punição para fraudes e plágios

Detecção de fraude ou plágio em qualquer teste ou no trabalho final resultará em nota zero na atividade específica para todos os envolvidos. Casos de reincidência ou plágio grave acarretarão em nota final zero ($NF = 0$) com conceito D para todos os envolvidos, além da devida notificação à coordenação do IC/Unicamp.

4 Bibliografia Recomendada

- Hastie, Trevor, Robert Tibshirani, and Jerome Friedman. *The elements of statistical learning: data mining, inference, and prediction*. Springer, 2009.
- Bishop, Christopher M., and Hugh Bishop. *Deep learning: Foundations and concepts*. Springer, 2023.
- Murphy, Kevin P. *Probabilistic machine learning: An introduction*. MIT Press, 2022.
- Goodfellow, Ian, Yoshua Bengio, and Aaron Courville. *Deep learning*. MIT Press, 2016.