

CAMPUS NOVA GAMELEIRA

DISCIPLINA: Aprendizado de Máquina

CÓDIGO: G00AMQ0.01

Início: 01/2023

Carga Horária: Total: 60 horas-aula

Semanal: 04 horas-aula

Créditos: 04

Natureza: Teórica

Área de Formação - DCN: Específica

Competências/habilidades a serem desenvolvidas:

Dominar fundamentos teórico-conceituais de inteligência artificial e analisar as diversas técnicas existentes, compreendendo suas aplicações práticas, seus pontos fortes e suas fragilidades.

Departamento que oferta a disciplina: Departamento de Computação

Ementa:

Introdução ao aprendizado de máquina. Técnicas de aprendizado supervisionado: *K Nearest Neighbors* (KNN), regressão linear, regressão logística, redes neurais artificiais, *Support Vector Machine* - SVM (linear e *kernels*). Avaliação das técnicas de aprendizado supervisionado: *underfitting* e *overfitting*, dilema *bias – variance*. Divisão de dados em treinamento e teste. Validação cruzada. Regularização. Métricas de avaliação de erro. Técnicas de meta-aprendizado: *bagging*, *boosting* e *stacking*. Aprendizado semi-supervisionado: *expectation maximization*, *cotraining*. Aprendizado ativo. Aprendizado não supervisionado: algoritmos particionais, avaliação de desempenho. Redução de dimensionalidade. Tópicos avançados em aprendizado de máquina. Aplicações práticas.

Curso	Período	Eixo	Obrigatória	Optativa
Engenharia de Computação	8º	Sistemas Inteligentes	X	

Interdisciplinaridades:

Prerrequisitos

Inteligência Artificial

Correquisitos

Objetivos: A disciplina deverá possibilitar ao estudante

1	Apresentar ao aluno os fundamentos teórico-conceituais e práticos relacionados ao aprendizado de máquina.
2	Estudar os principais métodos de aprendizado de máquina.
3	Saber analisar o desempenho, bem como os erros dos métodos de aprendizado de máquina.
4	Modelar, projetar e implementar um sistema completo de aprendizado de máquina aplicando-o em diversos contextos.

Unidades de ensino	Carga horária horas-aula
--------------------	--------------------------

Plano de Ensino

1	Introdução ao Aprendizado Supervisionado: Aprendizado supervisionado e sua aplicação a problemas de regressão e classificação; Algoritmo K vizinhos mais próximos (<i>K Nearest Neighbors</i> - KNN) para classificação; <i>Underfitting</i> e <i>overfitting</i> ; Dilema <i>Bias – Variance</i> ; Divisão de dados em treinamento e teste; Validação cruzada; Complexidade do modelo vs Erro.	8
2	Regressão Linear: Introdução a regressão linear; funções de custo, regularização, seleção de recursos e hiper-parâmetros; Gradiente descendente.	8
3	Regressão Logística: Introdução a regressão logística; Métricas de erro de classificação; <i>Grid Search</i> e <i>Pipelines</i> .	4
4	Redes Neurais Artificiais (RNA): Introdução a Redes Neurais Artificiais (RNA); Arquiteturas e Processamento Neural; Ajuste de uma rede neural: Backpropagation, Funções de ativação e treinamento, Regularização e Otimizadores.	8
5	Preprocessamento e extração de Atributos: Limpeza e imputação de dados; tipos de representação de dados, suas vantagens e desvantagens; normalização, discretização e transformação de dados.	4
6	Support Vector Machines (SVM): Regressão logística vs SVM; Classificação com SVMs; Função de custo; Regularização; SVM linear; SVM não lineares (Kernels).	4
7	Técnicas de Meta-aprendizado: Os conceitos de <i>bootstrapping</i> e agregação (<i>bagging</i>) para reduzir a variância; <i>Boosting</i> ; <i>Stacking</i> ; Algoritmos de <i>bagging</i> e <i>boosting</i> .	8
8	Aprendizado Semi-Supervisionado: Expectation Maximization; Co-training; Aprendizado ativo.	4
9	Aprendizado Não Supervisionado: Introdução ao aprendizado não supervisionado; Algoritmos de agrupamento particionais; Algoritmos de agrupamento hierárquicos.	4
10	Redução de Dimensionalidade: Principal Component Analysis (PCA); Multi-Dimensional Scaling (MDS); Aplicações.	4
11	Tópicos Avançados em Aprendizado de Máquina: Estudo de técnicas modernas e aplicações na área de aprendizado de máquina.	4
Total		60

Bibliografia Básica

1	GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep learning . [s.l.] MIT press, 2016.
2	JAMES, G. et al. An introduction to statistical learning . New York: springer, 2021.
3	MOHRI, M.; ROSTAMIZADEH, A; TALWALKAR, A. Foundations of machine learning . 2nd ed. Cambridge, MA: MIT Press, 2018.

Bibliografia Complementar

1	BISHOP, C. M. Pattern recognition and machine learning . New York: Springer, 2006
2	FLACH, P. Machine learning: the art and science of algorithms that make sense of data . Cambridge: Cambridge University Press, 2012.
3	GRUS, J. Data science from scratch: first principles with Python . 2nd ed. [s.l.] O'Reilly Media, 2019.
4	MURPHY, K. P. Machine Learning: a probabilistic perspective . Cambridge (Ma): Mit



MINISTÉRIO DA EDUCAÇÃO
CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
DIRETORIA DE GRADUAÇÃO

Plano de Ensino

	Press, 2012.
5	IZBICKI, R.; SANTOS, T. M. Aprendizado de máquina : uma abordagem estatística. São Carlos, SP: Rafael Izbicki, 2020.



PLANO DE ENSINO Nº 1588/2024 - CECOM (11.51.11)

(Nº do Protocolo: NÃO PROTOCOLADO)

(Assinado digitalmente em 26/07/2024 16:25)

BRUNO ANDRE SANTOS

COORDENADOR

CECOM (11.51.11)

Matrícula: ###594#8

Visualize o documento original em <https://sig.cefetmg.br/documentos/> informando seu número: **1588**, ano: **2024**,
tipo: **PLANO DE ENSINO**, data de emissão: **26/07/2024** e o código de verificação: **049bcd99c**