

CAMPUS TIMÓTEO	
DISCIPLINA: Inteligência Artificial II	CÓDIGO: G07IART2.01

Início: 08/2026

Carga Horária: Total: 60 horas-aula Semanal: 04 aulas Créditos: 04

Natureza: Teórico-prática

Área de Formação - DCN: Profissionalizante

Competências/habilidades: C02, C03, C06, C07, C11, C12, C13

Departamento que oferta a disciplina: DECOMTM

EMENTA

Fundamentos das redes neurais artificiais: aprendizado, associação, generalização, abstração e robustez. Histórico das redes neurais artificiais. Estruturas de interconexão. Tipos de aprendizado: supervisionado e não-supervisionado. Perceptron simples, perceptron de múltiplas camadas, algoritmo de mínimos quadrados, algoritmo de retropropagação de erros e problemas de treinamento. Redes de aprendizado profundo (*deep learning*). Estudo de casos selecionados envolvendo projeto, implementação, treinamento e avaliação de redes neurais artificiais, utilizando ferramentas para simulação computacional, e.g., Python, TensorFlow, Matlab ou similares.

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

INTERDISCIPLINARIDADES

Prerrequisitos: Inteligência Artificial I
Correquisitos:

Objetivos: <i>A disciplina deverá possibilitar ao estudante</i>	
1	Compreender os fundamentos das redes neurais artificiais.
2	Entender as arquiteturas de MLP e CNN.
3	Aplicar técnicas de treinamento de redes neurais.
4	Analisar funções de ativação e operações de convolução e <i>pooling</i> .
5	Implementar modelos utilizando ferramentas computacionais.
6	Avaliar o desempenho e ajustar modelos.
7	Comparar a aplicabilidade dos diferentes modelos.
8	

Plano de Ensino

Unidades de ensino		Carga Horária Horas-aula
1	INTRODUÇÃO – Conceituação de Inteligência Artificial (IA-I) e Inteligência Artificial II (IA-II) como sucessora de IA-I.	4
2	INTRODUÇÃO ÀS REDES NEURAIS – Histórico e motivação. O neurônio biológico vs neurônio artificial. Perceptron simples. Limitações do perceptron (ex: problema do XOR).	4
3	ESTRUTURA DO MLP – Camadas: entrada, ocultas e saída. Arquitetura de redes profundas (<i>deep learning</i>). Representação matemática de um MLP. Inicialização de pesos.	4
4	PROPAGAÇÃO DIRETA (<i>Forward Propagation</i>) – Cálculo da saída da rede. Combinação linear e ativação. Funções de ativação: Sigmoid, Tanh, ReLU e Softmax.	4
5	RETROPROPAGAÇÃO DO ERRO (<i>Backpropagation</i>) – Função de perda (<i>loss</i>). Gradiente e regra da cadeia. Atualização de pesos. Taxa de aprendizado (<i>learning rate</i>).	6
6	TREINAMENTO E OTIMIZAÇÃO – Algoritmos de otimização (SGD, Adam). <i>Batch</i> , <i>mini-batch</i> e <i>online learning</i> . <i>Overfitting</i> e <i>underfitting</i> . Técnicas de regularização (Dropout, L2).	4
7	IMPLEMENTAÇÃO PRÁTICA – Introdução ao TensorFlow/Keras ou PyTorch. Construção de um MLP simples. Aplicações. Classificação (ex: dataset Iris). Regressão simples. Avaliação de desempenho.	4
8	AVALIAÇÃO E BOAS PRÁTICAS – Métricas. Acurácia. Precisão, recall e F1-score. Erro quadrático médio (MSE). Ajuste de hiper parâmetros. Boas práticas no treinamento.	2
9	INTRODUÇÃO ÀS CNNs – Motivação. Limitações das redes neurais tradicionais (MLP). Conceito de visão computacional. Estrutura geral de uma CNN. Exemplos de aplicações reais.	4
10	FUNDAMENTOS MATEMÁTICOS – Operação de convolução. Filtros (<i>kernels</i>) e mapas de características. <i>Padding</i> e <i>stride</i> . Dimensionalidade das saídas.	4
11	CAMADAS E TREINAMENTO DE UMA CNN – Camadas convolucionais. Funções de ativação (ReLU, Softmax). Camadas de <i>pooling</i> (MAX e Average). <i>Flatten</i> e camadas densas (<i>Fully Connected</i>). Função de perda (<i>loss</i>). Backpropagation em CNNs. Otimizadores (SGD, Adam). <i>Overfitting</i> e <i>underfitting</i> .	12
12	IMPLEMENTAÇÃO PRÁTICA – Introdução ao TensorFlow/Keras ou PyTorch. Construção de uma CNN simples. Treinamento com dataset (ex: MNIST ou CIFAR-10). Avaliação do modelo.	12
Total:		60

Bibliografia Básica	
1	HAYKIN, Simon. Redes Neurais: princípios e prática. Porto Alegre: Bookman, 2001. ISBN-10: 8573077182
2	NGUYEN, Hung T.; WALKER, Elbert A. A first course in fuzzy logic. 3rd. ed. Boca Raton: Chapman & Hall/ CRC, 2006. x, 430 p., il. ISBN 1-58488-526-2
3	LINDEN, Ricardo. Algoritmos genéticos: uma importante ferramenta da inteligência computacional. 2. ed. Rio de Janeiro: Brasport, 2008. 400 p., il. ISBN 978-85-7452-373-6

Bibliografia Complementar	
1	RUSSELL, S. J., NORVIG, P. Artificial Intelligence: a modern approach. Prentice-Hall, 1st edition, 1994. ISBN-10: 8595158878
2	ANSARI, Nirwan; HOU, Edwin. Computational intelligence for optimization. Boston: Kluwer Academic, 1997. 225 p. ISBN 0-7923-9838-6
3	ANGELES, Jorge. Fundamentals of robotic mechanical systems: theory, methods, and algorithms. 3. ed. Nova Iorque: Springer, 2007. 549 p., il. ISBN 0-387-29412-0
4	COPPIN, Ben. Inteligência artificial. Tradução de Jorge Duarte Pires Valério. Rio de Janeiro: LTC, 2010. 636 p. ISBN 9788521617297
5	FERNANDES, Anita Maria da Rocha. Inteligência artificial: noções gerais. Florianópolis: Visual Books, 2003. 160 p., il. ISBN 85-7502-114-1



PLANO DE ENSINO Nº 617/2026 - CECOMTM (11.51.22)

(Nº do Protocolo: NÃO PROTOCOLADO)

(Assinado digitalmente em 24/04/2026 19:51)

RODRIGO GAIBA DE OLIVEIRA

COORDENADOR - TITULAR

CECOMTM (11.51.22)

Matrícula: ###924#3

Visualize o documento original em <https://sig.cefetmg.br/documentos/> informando seu número: **617**, ano: **2026**, tipo:
PLANO DE ENSINO, data de emissão: **24/04/2026** e o código de verificação: **a3b503538d**