

Mestrado Próprio

Inteligência Artificial





Mestrado Próprio Inteligência Artificial

- » Modalidade: online
- » Duração: 12 meses
- » Certificado: TECH Universidade Tecnológica
- » Dedicção: 16h/semana
- » Horário: no seu próprio ritmo
- » Provas: online

Acesso ao site: www.techtute.com/br/engenharia/mestrado-proprio/mestrado-proprio-inteligencia-artificial

Índice

01

Apresentação

pág. 4

02

Objetivos

pág. 8

03

Competências

pág. 16

04

Direção do curso

pág. 20

05

Estrutura e conteúdo

pág. 24

06

Metodologia

pág. 38

07

Certificado

pág. 46

01

Apresentação

A Inteligência Artificial teve um avanço impressionante, desde os primeiros passos da pesquisa com redes neurais até o atual estado do *Deep Learning*. A IA provou ser capaz de gerar avanços revolucionários, aplicáveis em áreas tão diversas quanto saúde, logística e educação. Nesse contexto, a crescente demanda por profissionais altamente qualificados nessa área se tornou uma realidade para a maioria das empresas. Por esse motivo, a TECH criou este programa acadêmico exclusivo, que oferece aos alunos uma oportunidade única de se aprofundar nos últimos avanços da Inteligência Artificial. Em um mundo onde a inovação é fundamental, esta capacitação acadêmica preparará os especialistas para os desafios futuros.



“

Com este Mestrado Próprio, você descobrirá como a inteligência artificial está transformando os setores e se preparará para liderar a mudança”

A IA está transformando muitos setores, da saúde à logística, do automotivo ao comércio eletrônico. Sua capacidade de automatizar tarefas repetitivas e melhorar a eficiência levou a uma demanda crescente por profissionais capazes de dominar diferentes tipos de algoritmos de aprendizado de máquina. Em um setor tão novo e em constante evolução, é fundamental manter-se atualizado para competir em um mercado de trabalho cada vez mais voltado para a tecnologia.

Precisamente por esse motivo, a TECH desenvolveu um programa que é apresentado como uma resposta estratégica para melhorar as perspectivas de emprego e o potencial de promoção dos engenheiros. Dessa forma, foi elaborada uma grade curricular inovadora, na qual os alunos se aprofundarão nos fundamentos da IA e conhecerão melhor a mineração de dados.

Ao longo do desenvolvimento deste Mestrado Próprio, os alunos se aprofundarão nos fundamentos essenciais, traçando a evolução histórica da IA e explorando suas projeções futuras. Dessa forma, eles se integrarão mais detalhadamente aos aplicativos de uso massivo, para entender como essas plataformas melhoram a experiência do usuário e otimizam a eficiência operacional.

Trata-se, portanto, de uma capacitação acadêmica exclusiva, graças à qual os profissionais poderão desenvolver processos de otimização inspirados na evolução biológica, encontrando e aplicando soluções eficientes para problemas complexos com um profundo domínio da Inteligência Artificial.

Para facilitar a integração de novos conhecimentos, a TECH criou este programa abrangente com base na metodologia exclusiva *Relearning*. Com essa abordagem, os alunos reforçarão a compreensão por meio da repetição de conceitos-chave ao longo do programa, que serão apresentados em uma variedade de mídias audiovisuais para a aquisição progressiva e eficaz de conhecimento. Tudo isso em um sistema inovador e flexível, totalmente online, que permite que o aprendizado seja adaptado aos horários dos participantes.

Este **Mestrado Próprio em Inteligência Artificial** conta com o conteúdo mais completo e atualizado do mercado. Suas principais características são:

- ♦ O desenvolvimento de estudos de caso apresentados por especialistas em Inteligência Artificial
- ♦ Os conteúdos gráficos, esquemáticos e extremamente práticos fornece informação atualizada e prática sobre aquelas disciplinas essenciais para o exercício da profissão
- ♦ Exercícios práticos onde o processo de autoavaliação é realizado para melhorar a aprendizagem
- ♦ Destaque especial para as metodologias inovadoras
- ♦ Lições teóricas, perguntas a especialistas, fóruns de discussão sobre temas controversos e trabalhos de reflexão individual
- ♦ Disponibilidade de acesso a todo o conteúdo a partir de qualquer dispositivo, fixo ou portátil, com conexão à Internet



Aprimore seu perfil profissional desenvolvendo soluções avançadas baseadas em IA com o programa mais abrangente do cenário acadêmico digital”

“

Você abordará tudo, desde a evolução das redes neurais até a aprendizagem profunda e adquirirá habilidades sólidas na implementação de soluções avançadas de inteligência artificial”


O corpo docente deste programa inclui profissionais da área que transferem a experiência do seu trabalho para esta capacitação, além de especialistas reconhecidos de sociedades científicas de referência e universidades de prestígio.

O conteúdo multimídia, desenvolvido com a mais recente tecnologia educacional, permitirá ao profissional uma aprendizagem contextualizada, ou seja, realizada através de um ambiente simulado, proporcionando uma capacitação imersiva e programada para praticar diante de situações reais.

A estrutura deste programa se concentra na Aprendizagem Baseada em Problemas, onde o profissional deverá tentar resolver as diferentes situações de prática profissional que surgirem ao longo do curso acadêmico. Para isso, contará com a ajuda de um inovador sistema de vídeo interativo realizado por especialistas reconhecidos.

Você otimizará o potencial do armazenamento de dados na melhor universidade digital do mundo, de acordo com a Forbes.

Você poderá acessar conteúdo exclusivo no campus virtual 24 horas por dia, sem restrições geográficas ou de horário.



02

Objetivos

Os muitos avanços feitos no campo da Inteligência Artificial geraram uma necessidade de atualização constante por parte dos profissionais. Por esse motivo, a TECH criou um programa exclusivo e abrangente que permitirá que os alunos dominem os algoritmos complexos que fazem a Inteligência Artificial "ganhar vida". Assim, o objetivo final dessa capacitação é fornecer aos alunos as informações mais recentes do setor, com uma abordagem capacitadora e de última geração. Dessa forma, os alunos terão acesso a um programa acadêmico exclusivo, ministrado 100% online.




“

Você dominará as principais informações ocultas em grandes conjuntos de dados e aumentará a visibilidade do seu trabalho em um mercado em constante expansão”



Objetivos gerais

- ♦ Compreender os fundamentos teóricos da Inteligência Artificial
- ♦ Estudar os diferentes tipos de dados e entender o ciclo de vida dos dados
- ♦ Avaliar o papel crucial dos dados no desenvolvimento e na implementação de soluções de Inteligência Artificial
- ♦ Aprofundar os algoritmos e a complexidade para resolver problemas específicos
- ♦ Explorar a base teórica das redes neurais para o desenvolvimento do *Deep Learning*
- ♦ Explorar a computação bioinspirada e sua relevância para o desenvolvimento de sistemas inteligentes
- ♦ Analisar as estratégias atuais de Inteligência Artificial em vários campos, identificando oportunidades e desafios





Objetivos específicos

Módulo 1. Fundamentos da Inteligência Artificial

- ♦ Analisar a evolução histórica da Inteligência Artificial, desde seus primórdios até o estado atual, identificando os principais marcos e desenvolvimentos
- ♦ Compreender o funcionamento das redes neurais e sua aplicação em modelos de aprendizado em Inteligência Artificial
- ♦ Estudar os princípios e as aplicações dos algoritmos genéticos, analisando sua utilidade na solução de problemas complexos
- ♦ Analisar a importância de tesouros, vocabulários e taxonomias na estruturação e no processamento de dados para sistemas de IA
- ♦ Explore o conceito da Web semântica e sua influência na organização e compreensão das informações em ambientes digitais

Módulo 2. Tipos e Ciclo de Vida dos Dados

- ♦ Compreender os conceitos fundamentais de estatística e sua aplicação na análise de dados
- ♦ Identificar e classificar diferentes tipos de dados estatísticos, desde dados quantitativos até qualitativos
- ♦ Analisar o ciclo de vida dos dados, desde a geração até o descarte, identificando os principais estágios
- ♦ Explorar os estágios iniciais do ciclo de vida dos dados, destacando a importância do planejamento e da estrutura dos dados
- ♦ Estudar os processos de coleta de dados, incluindo metodologia, ferramentas e canais de coleta
- ♦ Explorar o conceito de *Datawarehouse* (armazenamento de dados), com ênfase em seus elementos constituintes e projeto
- ♦ Analisar os aspectos regulatórios relacionados à gestão de dados, cumprindo as normas de privacidade e segurança e as práticas recomendadas

Módulo 3. Os dados na Inteligência Artificial

- ♦ Dominar os fundamentos da ciência de dados, abrangendo ferramentas, tipos e fontes de análise de informações
- ♦ Explorar o processo de transformação de dados em informações usando técnicas de mineração e visualização de dados
- ♦ Estudar a estrutura e as características dos *datasets*, compreendendo sua importância na preparação e no uso de dados para modelos de Inteligência Artificial
- ♦ Analisar modelos supervisionados e não supervisionados, incluindo métodos e classificação
- ♦ Usar ferramentas específicas e práticas recomendadas no manejo e processamento de dados, garantindo eficiência e qualidade na implementação da Inteligência Artificial

Módulo 4. Mineração de dados Seleção, pré-processamento e transformação

- ♦ Dominar as técnicas de inferência estatística para entender e aplicar métodos estatísticos na mineração de dados
- ♦ Conduzir análises exploratórias detalhadas de conjuntos de dados para identificar padrões, anomalias e tendências relevantes
- ♦ Desenvolver habilidades na preparação de dados, incluindo limpeza, integração e formatação de dados para uso em mineração de dados
- ♦ Implementar estratégias eficazes para lidar com valores ausentes em conjuntos de dados, aplicando métodos de imputação ou eliminação de acordo com o contexto
- ♦ Identificar e atenuar o ruído nos dados, usando técnicas de filtragem e suavização para melhorar a qualidade do conjunto de dados
- ♦ Abordar o pré-processamento de dados em ambientes de Big Data

Módulo 5. Algoritmo e complexidade em inteligência artificial

- ♦ Introduzir estratégias de projeto de algoritmos, proporcionando uma sólida compreensão das abordagens fundamentais para a solução de problemas
- ♦ Analisar a eficiência e a complexidade dos algoritmos, aplicando técnicas de análise para avaliar o desempenho em termos de tempo e espaço
- ♦ Estudar e aplicar algoritmos de classificação, compreendendo como eles funcionam e comparando sua eficiência em diferentes contextos
- ♦ Explorar algoritmos baseados em árvores, compreensão de sua estrutura e aplicações
- ♦ Investigar algoritmos com *Heaps*, analisando sua implementação e utilidade na manipulação eficiente de dados
- ♦ Analisar algoritmos baseados em gráficos, explorando sua aplicação na representação e solução de problemas que envolvem relacionamentos complexos
- ♦ Estudar algoritmos *Greedy*, compreendendo sua lógica e aplicações na solução de problemas de otimização
- ♦ Pesquisar e aplicar a técnica de *backtracking* para a solução sistemática de problemas, analisando sua eficácia em uma variedade de ambientes

Módulo 6. Sistemas inteligentes

- ♦ Explorar a teoria dos agentes, compreendendo os conceitos fundamentais de como eles funcionam e sua aplicação em Inteligência Artificial e engenharia de software
- ♦ Estudar a representação do conhecimento, incluindo a análise de ontologias e sua aplicação na organização de informações estruturadas
- ♦ Analisar o conceito da Web semântica e seu impacto sobre a organização e a recuperação de informações em ambientes digitais

- ♦ Avaliar e comparar diferentes representações de conhecimento, integrando-as para melhorar a eficiência e a precisão dos sistemas inteligentes
- ♦ Estudar raciocinadores semânticos, sistemas baseados em conhecimento e sistemas especializados, compreendendo sua funcionalidade e aplicações na tomada de decisões inteligentes

Módulo 7. Machine learning e mineração de dados

- ♦ Apresentar os processos de descoberta de conhecimento e os conceitos fundamentais de aprendizado de máquina
- ♦ Estudar árvores de decisão como modelos de aprendizado supervisionado, compreendendo sua estrutura e aplicações
- ♦ Avaliar classificadores usando técnicas específicas para medir seu desempenho e precisão na classificação de dados
- ♦ Estudar redes neurais, compreendendo sua operação e arquitetura para resolver problemas complexos de aprendizado de máquina
- ♦ Explorar os métodos bayesianos e sua aplicação no aprendizado de máquina, incluindo redes bayesianas e classificadores bayesianos
- ♦ Analisar modelos de regressão e de resposta contínua para prever valores numéricos a partir de dados
- ♦ Estudar técnicas de *clustering* para identificar padrões e estruturas em conjuntos de dados não rotulados
- ♦ Explorar a mineração de texto e o processamento de linguagem natural (NLP), compreendendo como as técnicas de aprendizado de máquina são aplicadas para analisar e compreender o texto

Módulo 8. Redes Neurais como Base do *Deep Learning*

- ♦ Dominar os fundamentos da aprendizagem profunda, compreender sua função essencial no *Deep Learning*
- ♦ Explorar as operações fundamentais das redes neurais e entender sua aplicação na criação de modelos
- ♦ Analisar as diferentes camadas usadas em redes neurais e aprender a selecioná-las adequadamente
- ♦ Compreender a vinculação eficaz de camadas e operações para projetar arquiteturas de redes neurais complexas e eficientes
- ♦ Utilizar treinadores e otimizadores para ajustar e melhorar o desempenho das redes neurais
- ♦ Explorar a conexão entre neurônios biológicos e artificiais para uma compreensão mais profunda do design de modelos
- ♦ Definir hiperparâmetros para o *Fine Tuning* de redes neurais, otimizando seu desempenho em tarefas específicas

Módulo 9. Treinamento de Redes Neurais Profundas

- ♦ Resolver problemas relacionados ao gradiente no treinamento de redes neurais profundas
- ♦ Explorar e aplicar diferentes otimizadores para melhorar a eficiência e a convergência dos modelos
- ♦ Programar a taxa de aprendizado para ajustar dinamicamente a velocidade de convergência do modelo
- ♦ Compreender e lidar com o superajuste por meio de estratégias específicas durante o treinamento
- ♦ Aplicar diretrizes práticas para garantir o treinamento eficiente e eficaz de redes neurais profundas

- ♦ Implementar *Transfer Learning* como uma técnica avançada para melhorar o desempenho do modelo em tarefas específicas
- ♦ Explorar e aplicar técnicas de *Data Augmentation* para enriquecer conjuntos de dados e melhorar a generalização do modelo
- ♦ Desenvolver aplicativos práticos usando *Transfer Learning* para resolver problemas do mundo real
- ♦ Compreender e aplicar técnicas de regularização para melhorar a generalização e evitar o excesso de ajuste em redes neurais profundas

Módulo 10. Personalização de Modelos e Treinamento com *TensorFlow*

- ♦ Dominar os conceitos básicos de *TensorFlow* e sua integração com o NumPy para o manejo eficiente de dados e cálculos
- ♦ Personalizar modelos e algoritmos de treinamento usando os recursos avançados do *TensorFlow*
- ♦ Explorar a API *tfdataset* para gerenciar e manipular conjuntos de dados com eficiência
- ♦ Implementar o formato *TFRecord* para armazenar e acessar grandes conjuntos de dados em *TensorFlow*
- ♦ Utilizar camadas de pré-processamento do Keras para facilitar a construção de modelos personalizados
- ♦ Explorar o projeto *TensorFlow Datasets* para acessar conjuntos de dados predefinidos e aumentar a eficiência do desenvolvimento
- ♦ Desenvolver um aplicativo para *Deep Learning* com *TensorFlow*, integrando o conhecimento adquirido no módulo
- ♦ Aplicar de forma prática todos os conceitos aprendidos na construção e no treinamento de modelos personalizados usando *TensorFlow* em situações do mundo real

Módulo 11. *Deep Computer Vision* com Redes Neurais Convolucionais

- ♦ Compreender a arquitetura do córtex visual e sua importância para o *Deep Computer Vision*
- ♦ Explorar e aplicar camadas convolucionais para extrair os principais recursos das imagens
- ♦ Implementar camadas de agrupamento e seu uso em modelos de *Deep Computer Vision* com Keras
- ♦ Analisar várias arquiteturas de rede neural convolucional (CNN) e sua aplicabilidade em diferentes contextos
- ♦ Desenvolver e implementar uma CNN ResNet usando a biblioteca Keras para melhorar a eficiência e o desempenho do modelo
- ♦ Use modelos Keras pré-treinados para aproveitar a aprendizagem por transferência para tarefas específicas
- ♦ Aplicar técnicas de classificação e rastreamento em um *Deep Computer Vision*
- ♦ Explorar estratégias de detecção e rastreamento de objetos usando Redes Neurais Convolucionais
- ♦ Implementar técnicas de segmentação semântica para entender e classificar objetos em imagens de forma detalhada

Módulo 12. Processamento de Linguagem Natural (PLN) com Redes Neurais Recorrentes (RNN) e Atenção

- ♦ Desenvolver habilidades na geração de texto usando Redes Neurais Recorrentes (RNN)
- ♦ Aplicar RNN na classificação de opiniões para análise de sentimentos em textos
- ♦ Compreender e aplicar mecanismos de atenção em modelos de processamento de linguagem natural
- ♦ Analisar e usar modelos *Transformers* em tarefas específicas de PLN

- ♦ Explorar a aplicação de modelos *Transformers* no contexto do processamento de imagens e da visão computacional
- ♦ Familiarizar-se com a biblioteca de *Transformers* de *Hugging Face* para a implementação eficiente de modelos avançados
- ♦ Comparar diferentes bibliotecas de *Transformers* para avaliar sua adequação a tarefas específicas
- ♦ Desenvolver um aplicativo prático de PLN que integre RNN e mecanismos de atenção para resolver problemas do mundo real

Módulo 13. *Autoencoders*, GANs, e Modelos de Difusão

- ♦ Desenvolver representações eficientes de dados por meio de *Autoencoders*, GANs e modelos de difusão
- ♦ Realizar PCA usando um codificador automático linear incompleto para otimizar a representação de dados
- ♦ Implementar e compreender a operação de codificadores de empilhamento automático
- ♦ Explorar e aplicar autoencodificadores convolucionais para representações eficientes de dados visuais
- ♦ Analisar e aplicar a eficácia de codificadores automáticos esparsos na representação de dados
- ♦ Gerar imagens de moda a partir do conjunto de dados MNIST usando *Autoencoders*
- ♦ Compreender o conceito de Redes Adversárias Generativas (GANs) e Modelos de Difusão
- ♦ Implementar e avaliar o desempenho dos modelos de difusão e GANs na geração de dados

Módulo 14. Computação bioinspirada

- ♦ Apresentar os conceitos fundamentais da computação bioinspirada
- ♦ Explorando algoritmos socialmente adaptáveis como uma abordagem fundamental para a computação bioinspirada
- ♦ Analisar estratégias de exploração de espaço em algoritmos genéticos
- ♦ Examinar modelos de computação evolutiva no contexto da otimização
- ♦ Continuar a análise detalhada dos modelos de computação evolutiva
- ♦ Aplicar a programação evolutiva a problemas específicos de aprendizado
- ♦ Abordar a complexidade de problemas com vários objetivos na estrutura da computação bioinspirada
- ♦ Explorar a aplicação de redes neurais no campo da computação bioinspirada
- ♦ Aprofundar a implementação e a utilidade das redes neurais na computação bioinspirada

Módulo 15. Inteligência Artificial: estratégias e aplicações

- ♦ Desenvolver estratégias para a implementação de inteligência artificial em serviços financeiros
- ♦ Analisar as implicações da inteligência artificial para a prestação de serviços de saúde
- ♦ Identificar e avaliar os riscos associados ao uso da IA no campo da saúde
- ♦ Avaliar os possíveis riscos associados ao uso da IA no setor
- ♦ Aplicar técnicas de inteligência artificial no setor para melhorar a produtividade

- ♦ Projetar soluções de inteligência artificial para otimizar processos na administração pública
- ♦ Avaliar a implementação de tecnologias de IA no setor educacional
- ♦ Aplicar técnicas de inteligência artificial na silvicultura e na agricultura para melhorar a produtividade
- ♦ Otimizar os processos de recursos humanos por meio do uso estratégico da inteligência artificial



Você dominará as tecnologias do futuro com esse exclusivo programa universitário 100% online. Tudo isso somente na TECH!"

03

Competências

A estrutura deste Mestrado Próprio foi projetada de tal forma que, ao final do programa, o aluno terá adquirido as competências sólidas para se destacar na implementação e no desenvolvimento de *Autoencoders*, *GANs*, e Modelos de Difusão. Para isso, o profissional se aprofundará na mineração de Dados e no processamento de linguagem natural (NLP), graças aos quais as máquinas podem entender e gerar linguagem humana de forma eficaz. Tudo isso em apenas 12 meses de aprendizado totalmente online, sem precisar se deslocar ou se adaptar a um *timing* pré-definido.



“

Não perca essa oportunidade única de aumentar suas habilidades de mineração de dados e se posicionar como um especialista em Inteligência Artificial”




Competências gerais

- ♦ Dominar as técnicas de mineração de dados, incluindo a seleção, o pré-processamento e a transformação de dados complexos
- ♦ Projetar e desenvolver sistemas inteligentes capazes de aprender e se adaptar a ambientes em constante mudança
- ♦ Controlar ferramentas de aprendizado de máquina e sua aplicação em mineração de dados para tomada de decisões
- ♦ Usar Autoencoders, GANs e Modelos de Difusão para resolver desafios específicos em Inteligência Artificial
- ♦ Implementar uma rede codificadora-decodificadora para tradução automática neuronal
- ♦ Aplicar os princípios fundamentais das redes neurais para resolver problemas específicos



Você aprimorará suas habilidades graças às ferramentas de ensino da TECH, incluindo vídeos explicativos e resumos interativos”





Competências específicas

- ♦ Aplicar técnicas e estratégias de IA para melhorar a eficiência no setor de varejo
- ♦ Aprofundar a compreensão e a aplicação de algoritmos genéticos
- ♦ Implementar técnicas de redução de ruído usando codificadores automáticos
- ♦ Crie efetivamente conjuntos de dados de treinamento para tarefas de processamento de linguagem natural (NLP)
- ♦ Executar camadas de agrupamento e seu uso em modelos de *Deep Computer Vision* com Keras
- ♦ Usar funções e gráficos de *TensorFlow* para otimizar o desempenho de modelos personalizados
- ♦ Otimizar o desenvolvimento e a implementação de *chatbots* e assistentes virtuais, entendendo como eles funcionam e suas possíveis aplicações
- ♦ Dominar a reutilização de camadas pré-treinadas para otimizar e acelerar o processo de treinamento
- ♦ Construir a primeira rede neural, aplicando os conceitos aprendidos na prática
- ♦ Ativação do MLP (Multilayer Perceptron) usando a biblioteca Keras
- ♦ Aplicar técnicas de exploração e pré-processamento de dados, identificando e preparando dados para uso eficaz em modelos de aprendizado de máquina
- ♦ Implementar estratégias eficazes para lidar com valores ausentes em conjuntos de dados, aplicando métodos de imputação ou eliminação de acordo com o contexto
- ♦ Investigar linguagens e softwares para a criação de ontologias, usando ferramentas específicas para o desenvolvimento de modelos semânticos
- ♦ Desenvolver técnicas de limpeza de dados para garantir a qualidade e a precisão das informações usadas em análises subsequentes

04

Direção do curso

Em seu compromisso com o ensino de qualidade, a TECH selecionou cuidadosamente os professores responsáveis pelo desenvolvimento do programa de estudos para este Mestrado Próprio. Por esse motivo, esse programa acadêmico conta com um corpo docente experiente com um histórico excepcional no desenvolvimento e na implementação de soluções de IA. Dessa forma, os alunos deste Mestrado Próprio terão acesso a uma experiência educacional de alto nível. Eles também obterão uma combinação única de conhecimento, apresentada em uma variedade de mídias audiovisuais, para uma integração mais eficaz e dinâmica do conhecimento.





“


Fique por dentro das últimas tendências em Inteligência Artificial com os melhores especialistas da área”

Direção



Dr. Arturo Peralta Martín-Palomino

- ♦ CEO e CTO na Prometeus Global Solutions
- ♦ CTO na Korporate Technologies
- ♦ CTO na AI Shephers GmbH
- ♦ Consultor e assessor estratégico de negócios da Alliance Medical
- ♦ Diretor de Design e Desenvolvimento na DocPath
- ♦ Doutor em Engenharia da Computação pela Universidade de Castilla - la Mancha
- ♦ Doutorado em Economia, Negócios e Finanças pela Universidade Camilo José Cela
- ♦ Doutor em Psicologia pela Universidade de Castilla - La Mancha
- ♦ Mestrado em MBA Executivo pela Universidade Isabel I
- ♦ Mestrado em Gestão Comercial e Marketing pela Universidade Isabel I
- ♦ Mestrado especializado em Big Data por formação Hadoop
- ♦ Mestrado em Tecnologias de Informação Avançadas pela Universidade de Castilla-La Mancha
- ♦ Membro: Grupo de pesquisa SMILE



05

Estrutura e conteúdo

Este plano de estudos foi elaborado por uma equipe de especialistas na área de Inteligência Artificial, com ênfase especial nos processos de descoberta de conhecimento e aprendizado de máquina. Dessa forma, o aluno terá uma visão do desenvolvimento de algoritmos e modelos que permitem que as máquinas aprendam padrões e executem tarefas sem serem explicitamente programadas para isso. Além disso, a TECH emprega a metodologia pioneira *Relearning*, graças à qual os profissionais integrarão conhecimentos sólidos na avaliação de modelos de forma progressiva e eficaz.



“

Você se aprofundará na formulação de algoritmos genéticos por meio de 12 meses do melhor ensino digital. Impulsione seu desenvolvimento profissional com a TECH”

Módulo 1. Fundamentos da Inteligência Artificial

- 1.1. História da inteligência artificial
 - 1.1.1. Quando começamos a falar de inteligência artificial?
 - 1.1.2. Referências no cinema
 - 1.1.3. Importância da inteligência artificial
 - 1.1.4. Tecnologias que habilitam e dão suporte à inteligência artificial
- 1.2. Inteligência Artificial em jogos
 - 1.2.1. Teoria dos jogos
 - 1.2.2. *Minimax* e Poda Alfa-Beta
 - 1.2.3. Simulação: Monte Carlo
- 1.3. Redes de neurônios
 - 1.3.1. Fundamentos biológicos
 - 1.3.2. Modelo computacional
 - 1.3.3. Redes de neurônios supervisionadas e não supervisionadas
 - 1.3.4. Perceptron simples
 - 1.3.5. Perceptrão multicamadas
- 1.4. Algoritmos genéticos
 - 1.4.1. História
 - 1.4.2. Base biológica
 - 1.4.3. Codificação de problemas
 - 1.4.4. Geração da população inicial
 - 1.4.5. Algoritmo principal e operadores genéticos
 - 1.4.6. Avaliação de indivíduos: Fitness
- 1.5. Tesouros, vocabulários, taxonomias
 - 1.5.1. Vocabulários
 - 1.5.2. Taxonomias
 - 1.5.3. Tesouros
 - 1.5.4. Ontologias
 - 1.5.5. Representação do conhecimento: web semântica

- 1.6. Web Semântica
 - 1.6.1. Especificações RDF, RDFS e OWL
 - 1.6.2. Inferência/raciocínio
 - 1.6.3. *Linked Data*
- 1.7. Sistemas especializados e DSS
 - 1.7.1. Sistemas especializados
 - 1.7.2. Sistemas de suporte à decisão
- 1.8. *Chatbots* e assistentes virtuais
 - 1.8.1. Tipos de assistentes: assistentes de voz e texto
 - 1.8.2. Partes fundamentais para o desenvolvimento de um assistente: *Intents*, entidades e fluxo de diálogo
 - 1.8.3. Integração Web, *Slack*, *Whatsapp*, *Facebook*
 - 1.8.4. Ferramentas para o desenvolvimento de assistentes: *Dialog Flow*, *Watson Assistant*
- 1.9. Estratégia de implementação da IA
- 1.10. O futuro da inteligência artificial
 - 1.10.1. Entendemos como detectar emoções através de algoritmos
 - 1.10.2. Criar uma personalidade: linguagem, expressões e conteúdo
 - 1.10.3. Tendências da inteligência artificial
 - 1.10.4. Reflexões

Módulo 2. Tipos e Ciclo de Vida dos Dados

- 2.1. Estatísticas
 - 2.1.1. Estatísticas: descritivas e inferências
 - 2.1.2. População, amostra, individual
 - 2.1.3. Variáveis: definição, escalas de medição
- 2.2. Tipos de dados estatísticos
 - 2.2.1. De acordo com o tipo
 - 2.2.1.1. Quantitativos: dados contínuos e dados discretos
 - 2.2.1.2. Qualitativo: dados binomiais, dados nominais, dados ordinais

- 2.2.2. De acordo com sua forma
 - 2.2.2.1. Numérico
 - 2.2.2.2. Texto
 - 2.2.2.3. Lógico
- 2.2.3. De acordo com a fonte
 - 2.2.3.1. Primários
 - 2.2.3.2. Secundários
- 2.3. Ciclo de vida dos dados
 - 2.3.1. Etapas do ciclo
 - 2.3.2. Marcos do ciclo
 - 2.3.3. Princípios FAIR
- 2.4. Etapas iniciais do ciclo
 - 2.4.1. Definição de objetivos
 - 2.4.2. Determinação de recursos necessários
 - 2.4.3. Diagrama de Gantt
 - 2.4.4. Estruturas dos dados
- 2.5. Coleta de dados
 - 2.5.1. Metodologia de coleta
 - 2.5.2. Ferramentas de coleta
 - 2.5.3. Canais de coleta
- 2.6. Limpeza de dados
 - 2.6.1. Fases da limpeza de dados
 - 2.6.2. Qualidade dos dados
 - 2.6.3. Manipulação de dados (com R)
- 2.7. Análise de dados, interpretação e avaliação dos resultados
 - 2.7.1. Medidas estatísticas
 - 2.7.2. Índices de relação
 - 2.7.3. Mineração de dados
- 2.8. Armazém de dados (*datawarehouse*)
 - 2.8.1. Elementos que o compõem
 - 2.8.2. Planejamento
 - 2.8.3. Aspectos a considerar

- 2.9. Disponibilidade de dados
 - 2.9.1. Acesso
 - 2.9.2. Utilidade
 - 2.9.3. Segurança
- 2.10. Aspectos regulamentares
 - 2.10.1. Lei Geral de Proteção de Dados
 - 2.10.2. Boas práticas
 - 2.10.3. Outros aspectos regulamentares

Módulo 3. Os dados na Inteligência Artificial

- 3.1. Ciência de dados
 - 3.1.1. Ciência de dados
 - 3.1.2. Ferramentas avançadas para o cientista de dados
- 3.2. Dados, informações e conhecimentos
 - 3.2.1. Dados, informações e conhecimentos
 - 3.2.2. Tipos de dados
 - 3.2.3. Fontes de dados
- 3.3. De dados a informações
 - 3.3.1. Análise de dados
 - 3.3.2. Tipos de análise
 - 3.3.3. Extração de informações de um *Dataset*
- 3.4. Extração de informações através da visualização
 - 3.4.1. A visualização como ferramenta de análise
 - 3.4.2. Métodos de visualização
 - 3.4.3. Visualização de um conjunto de dados
- 3.5. Qualidade dos dados
 - 3.5.1. Dados de qualidade
 - 3.5.2. Limpeza de dados
 - 3.5.3. Pré-processamento básico de dados

- 3.6. *Dataset*
 - 3.6.1. Enriquecimento do *Dataset*
 - 3.6.2. A maldição da dimensionalidade
 - 3.6.3. Modificação de nosso conjunto de dados
- 3.7. Desequilíbrio
 - 3.7.1. Desequilíbrio de classes
 - 3.7.2. Técnicas de mitigação do desequilíbrio
 - 3.7.3. Equilíbrio de um *Dataset*
- 3.8. Modelos não supervisionados
 - 3.8.1. Modelo não supervisionado
 - 3.8.2. Métodos
 - 3.8.3. Classificação com modelos não supervisionados
- 3.9. Modelos supervisionados
 - 3.9.1. Modelo supervisionado
 - 3.9.2. Métodos
 - 3.9.3. Classificação com modelos supervisionados
- 3.10. Ferramentas e práticas recomendadas
 - 3.10.1. Práticas recomendadas para um cientista de dados
 - 3.10.2. O melhor modelo
 - 3.10.3. Ferramentas úteis

Módulo 4. Mineração de dados Seleção, pré-processamento e transformação

- 4.1. Inferência estatística
 - 4.1.1. Estatística descritiva vs. Inferência estatística
 - 4.1.2. Procedimentos paramétricos
 - 4.1.3. Procedimentos paramétricos
- 4.2. Análise exploratória
 - 4.2.1. Análise descritiva
 - 4.2.2. Visualização
 - 4.2.3. Preparação dos dados
- 4.3. Preparação dos dados
 - 4.3.1. Integração e limpeza de dados
 - 4.3.2. Normalização de dados
 - 4.3.3. Transformando atributos
- 4.4. Os Valores Perdidos
 - 4.4.1. Tratamento de valores perdidos
 - 4.4.2. Métodos de imputação de máxima verosimilhança
 - 4.4.3. Imputação de valores perdidos utilizando a aprendizado de máquinas
- 4.5. O ruído nos dados
 - 4.5.1. Classes de ruído e seus atributos
 - 4.5.2. Filtragem de ruídos
 - 4.5.3. O efeito do ruído
- 4.6. A maldição da dimensionalidade
 - 4.6.1. *Oversampling*
 - 4.6.2. *Undersampling*
 - 4.6.3. Redução de dados multidimensionais
- 4.7. De atributos contínuos a discretos
 - 4.7.1. Dados contínuos versus discretos
 - 4.7.2. Processo de discretização
- 4.8. Os dados
 - 4.8.1. Seleção de dados
 - 4.8.2. Perspectivas e critérios de seleção
 - 4.8.3. Métodos de seleção
- 4.9. Seleção de Instâncias
 - 4.9.1. Métodos para seleção de instâncias
 - 4.9.2. Seleção de protótipos
 - 4.9.3. Métodos avançados para seleção de instâncias
- 4.10. Pré-processamento de dados em ambientes Big Data

Módulo 5. Algoritmo e complexidade em inteligência artificial

- 5.1. Introdução às Estratégias de design de algoritmos
 - 5.1.1. Recursividade
 - 5.1.2. Divisão e conquista
 - 5.1.3. Outras estratégias
- 5.2. Eficiência e análise de algoritmos
 - 5.2.1. Medidas de eficiência
 - 5.2.2. Como medir o tamanho da entrada
 - 5.2.3. Como medir o tempo de execução
 - 5.2.4. Melhor, pior e médio caso
 - 5.2.5. Notação assintótica
 - 5.2.6. Critérios de análise matemática para algoritmos não-recursivos
 - 5.2.7. Análise matemática de algoritmos recursivos
 - 5.2.8. Análise empírica de algoritmos
- 5.3. Algoritmos de ordenação
 - 5.3.1. Conceito de ordenação
 - 5.3.2. Ordenação bolha (Bubble sort)
 - 5.3.3. Ordenação por seleção (Selection sort)
 - 5.3.4. Ordenação por inserção (Insertion Sort)
 - 5.3.5. Ordenação por mistura (*merge_sort*)
 - 5.3.6. Classificação rápida (*quick_sort*)
- 5.4. Algoritmos com árvores
 - 5.4.1. Conceito de árvore
 - 5.4.2. Árvores binárias
 - 5.4.3. Caminhos de árvores
 - 5.4.4. Representar expressões
 - 5.4.5. Árvores binárias ordenadas
 - 5.4.6. Árvores binárias balanceadas
- 5.5. Algoritmos com *Heaps*
 - 5.5.1. Os *Heaps*
 - 5.5.2. O algoritmo *Heapsort*
 - 5.5.3. As filas de prioridade
- 5.6. Algoritmos com grafos
 - 5.6.1. Representação
 - 5.6.2. Caminho em largura
 - 5.6.3. Caminho em profundidade
 - 5.6.4. Ordenação topológica
- 5.7. Algoritmos *Greedy*
 - 5.7.1. A estratégia *Greedy*
 - 5.7.2. Elementos da estratégia *Greedy*
 - 5.7.3. Conversor de moedas
 - 5.7.4. Problema do Caixeiro Viajante
 - 5.7.5. Problema da mochila
- 5.8. Busca do caminho mínimo
 - 5.8.1. O problema do caminho mínimo
 - 5.8.2. Arco e ciclos negativos
 - 5.8.3. Algoritmo de Dijkstra
- 5.9. Algoritmos *Greedy* sobre Grafos
 - 5.9.1. A árvore de extensão mínima
 - 5.9.2. O algoritmo de Prim (algoritmo guloso)
 - 5.9.3. O algoritmo de Kruskal
 - 5.9.4. Análise de complexidade
- 5.10. *Backtracking*
 - 5.10.1. O *Backtracking*
 - 5.10.2. Técnicas alternativas

Módulo 6. Sistemas inteligentes

- 6.1. Teoria de Agentes
 - 6.1.1. História do conceito
 - 6.1.2. Definição de agente
 - 6.1.3. Agentes em Inteligência Artificial
 - 6.1.4. Agentes em Engenharia de Software
- 6.2. Arquiteturas de agentes
 - 6.2.1. O processo de raciocínio de um agente
 - 6.2.2. Agentes reativos
 - 6.2.3. Agentes dedutivos
 - 6.2.4. Agentes híbridos
 - 6.2.5. Comparativa
- 6.3. Informação e conhecimento
 - 6.3.1. Distinção entre dados, informações e conhecimentos
 - 6.3.2. Avaliação da qualidade dos dados
 - 6.3.3. Métodos de captura de dados
 - 6.3.4. Métodos de aquisição de informações
 - 6.3.5. Métodos de aquisição de conhecimentos
- 6.4. Representação do conhecimento
 - 6.4.1. A importância da representação do conhecimento
 - 6.4.2. Definição da representação do conhecimento através de suas funções
 - 6.4.3. Características de uma representação do conhecimento
- 6.5. Ontologias
 - 6.5.1. Introdução aos metadados
 - 6.5.2. Conceito filosófico de ontologia
 - 6.5.3. Conceito informático de ontologia
 - 6.5.4. Ontologias de domínio e ontologias de nível superior
 - 6.5.5. Como construir uma ontologia?
- 6.6. Linguagens para ontologias e software para criação de ontologias
 - 6.6.1. Tríade RDF, Turtle e N
 - 6.6.2. RDF Schema
 - 6.6.3. OWL
 - 6.6.4. SPARQL
 - 6.6.5. Introdução às diferentes ferramentas para a criação de ontologias
 - 6.6.6. Instalação e uso do *Protégé*
- 6.7. Web Semântica
 - 6.7.1. O estado atual e futuro da segurança ad web semântica
 - 6.7.2. Aplicações da web semântica
- 6.8. Outros modelos de representação do conhecimento
 - 6.8.1. Vocabulários
 - 6.8.2. Visão global
 - 6.8.3. Taxonomias
 - 6.8.4. Tesouros
 - 6.8.5. Folksonomias
 - 6.8.6. Comparativa
 - 6.8.7. Mapas mentais
- 6.9. Avaliação e integração das representações do conhecimento
 - 6.9.1. Lógica de ordem zero
 - 6.9.2. Lógica de primeira ordem
 - 6.9.3. Lógica descritiva
 - 6.9.4. Relação entre diferentes tipos de lógica
 - 6.9.5. *Prolog*: programação baseada em lógica de primeira ordem
- 6.10. Raciocinadores Semânticos, Sistemas Baseados no Conhecimento e Sistemas Especialistas
 - 6.10.1. Conceito de raciocinador
 - 6.10.2. Aplicações de um raciocinador
 - 6.10.3. Sistemas baseados no conhecimento
 - 6.10.4. MYCIN, história dos Sistemas Especialistas
 - 6.10.5. Elementos e Arquitetura de Sistemas Especialistas
 - 6.10.6. Criação de Sistemas Especialistas

Módulo 7. Machine learning e mineração de dados

- 7.1. Introdução aos processos de descoberta de conhecimento e conceitos básicos de machine learning
 - 7.1.1. Conceitos-chave dos processos de descoberta do conhecimento
 - 7.1.2. Perspectiva histórica dos processos de descoberta do conhecimento
 - 7.1.3. Fases dos processos de descoberta do conhecimento
 - 7.1.4. Técnicas utilizadas nos processos de descoberta do conhecimento
 - 7.1.5. Características dos bons modelos de machine learning
 - 7.1.6. Tipos de informações de machine learning
 - 7.1.7. Noções básicas de aprendizagem
 - 7.1.8. Noções básicas de aprendizagem não supervisionada
- 7.2. Exploração e pré-processamento de dados
 - 7.2.1. Processamento de dados
 - 7.2.2. Tratamento de dados no fluxo de análise de dados
 - 7.2.3. Tipos de dados
 - 7.2.4. Transformações de dados
 - 7.2.5. Visualização e exploração de variáveis contínuas
 - 7.2.6. Visualização e exploração de variáveis categóricas
 - 7.2.7. Medidas de correlação
 - 7.2.8. Representações gráficas mais comuns
 - 7.2.9. Introdução à análise multivariada e redução da dimensionalidade
- 7.3. Árvore de decisão
 - 7.3.1. Algoritmo ID
 - 7.3.2. Algoritmo
 - 7.3.3. Overtraining e poda
 - 7.3.4. Análise de resultados
- 7.4. Avaliação de classificadores
 - 7.4.1. Matrizes de confusão
 - 7.4.2. Matrizes de avaliação numérica
 - 7.4.3. Estatístico de Kappa
 - 7.4.4. Curvas Roc
- 7.5. Regras de classificação
 - 7.5.1. Medidas de avaliação de regras
 - 7.5.2. Introdução à representação gráfica
 - 7.5.3. Algoritmo de sobreposição sequencial
- 7.6. Redes Neurais
 - 7.6.1. Conceitos básicos
 - 7.6.2. Redes de neurônios simples
 - 7.6.3. Algoritmo de *backpropagation*
 - 7.6.4. Introdução às redes neurais recorrentes
- 7.7. Métodos bayesianos
 - 7.7.1. Conceitos básicos de probabilidade
 - 7.7.2. Teorema de Bayes
 - 7.7.3. Naive Bayes
 - 7.7.4. Introdução às redes bayesianas
- 7.8. Modelos de regressão e de resposta contínua
 - 7.8.1. Regressão linear simples
 - 7.8.2. Regressão Linear Múltipla
 - 7.8.3. Regressão logística
 - 7.8.4. Árvores de regressão
 - 7.8.5. Introdução às Máquinas de Vetores de Suporte (SVM)
 - 7.8.6. Medidas de bondade do ajuste
- 7.9. *Clustering*
 - 7.9.1. Conceitos básicos
 - 7.9.2. *Clustering* hierárquico
 - 7.9.3. Métodos probabilísticos
 - 7.9.4. Algoritmo EM
 - 7.9.5. Método *B-Cubed*
 - 7.9.6. Métodos implícitos

- 7.10. Mineração de texto e processamento de linguagem natural (PNL)
 - 7.10.1. Conceitos básicos
 - 7.10.2. Criação do corpus
 - 7.10.3. Análise descritiva
 - 7.10.4. Introdução à análise de sentimentos

Módulo 8. Redes Neurais como Base do *Deep Learning*

- 8.1. Aprendizagem profunda
 - 8.1.1. Tipos de aprendizagem profunda
 - 8.1.2. Aplicativos de aprendizagem profunda
 - 8.1.3. Vantagens e desvantagens da aprendizagem profunda
- 8.2. Operações
 - 8.2.1. Soma
 - 8.2.2. Produtos
 - 8.2.3. Transferência
- 8.3. Camadas
 - 8.3.1. Camada de entrada
 - 8.3.2. Camada oculta
 - 8.3.3. Camada de saída
- 8.4. União de Camadas e Operações
 - 8.4.1. Design de arquiteturas
 - 8.4.2. Conexão entre camadas
 - 8.4.3. Propagação para frente
- 8.5. Construção da primeira rede neural
 - 8.5.1. Design da rede
 - 8.5.2. Definição dos pesos
 - 8.5.3. Treinamento da rede
- 8.6. Treinador e Otimizador
 - 8.6.1. Seleção do otimizador
 - 8.6.2. Definição de uma função de perda
 - 8.6.3. Definição de uma métrica

- 8.7. Aplicação dos princípios das redes neurais
 - 8.7.1. Funções de ativação
 - 8.7.2. Retropropagação
 - 8.7.3. Ajuste dos parâmetros
- 8.8. Dos neurônios biológicos para os artificiais
 - 8.8.1. Funcionamento de um neurônio biológico
 - 8.8.2. Transferência de conhecimento para os neurônios artificiais
 - 8.8.3. Estabelecimento de relações entre ambos
- 8.9. Implementação de MLP (Perceptron multicamadas) com Keras
 - 8.9.1. Definição da estrutura da rede
 - 8.9.2. Compilação do modelo
 - 8.9.3. Treinamento do modelo
- 8.10. Hiperparâmetros de *Fine tuning* de Redes Neurais
 - 8.10.1. Seleção da função de ativação
 - 8.10.2. Estabelecer o *learning rate*
 - 8.10.3. Ajuste dos pesos

Módulo 9. Treinamento de Redes Neurais Profundas

- 9.1. Problemas de Gradientes
 - 9.1.1. Técnicas de otimização de gradiente
 - 9.1.2. Gradientes Estocásticos
 - 9.1.3. Técnicas de inicialização de pesos
- 9.2. Reutilização de camadas pré-treinadas
 - 9.2.1. Treinamento de transferência de aprendizagem
 - 9.2.2. Extração de características
 - 9.2.3. Aprendizado profundo
- 9.3. Otimizadores
 - 9.3.1. Otimizadores de descida de gradiente estocástico
 - 9.3.2. Otimizadores Adam e *RMSprop*
 - 9.3.3. Otimizadores de momento

- 9.4. Programação da taxa de aprendizagem
 - 9.4.1. Controle de taxa de aprendizagem automática
 - 9.4.2. Ciclos de aprendizagem
 - 9.4.3. Termos de suavização
- 9.5. Sobreajuste
 - 9.5.1. Validação cruzada
 - 9.5.2. Regularização
 - 9.5.3. Métricas de avaliação
- 9.6. Diretrizes práticas
 - 9.6.1. Design de modelos
 - 9.6.2. Seleção de métricas e parâmetros de avaliação
 - 9.6.3. Testes de hipóteses
- 9.7. *Transfer Learning*
 - 9.7.1. Treinamento de transferência de aprendizagem
 - 9.7.2. Extração de características
 - 9.7.3. Aprendizado profundo
- 9.8. *Data Augmentation*
 - 9.8.1. Transformações de imagem
 - 9.8.2. Geração de dados sintéticos
 - 9.8.3. Transformação de texto
- 9.9. Aplicação prática de *Transfer Learning*
 - 9.9.1. Treinamento de transferência de aprendizagem
 - 9.9.2. Extração de características
 - 9.9.3. Aprendizado profundo
- 9.10. Regularização
 - 9.10.1. L e L
 - 9.10.2. Regularização por máxima entropia
 - 9.10.3. *Dropout*

Módulo 10. Personalização de Modelos e Treinamento com *TensorFlow*

- 10.1. *TensorFlow*
 - 10.1.1. Uso da biblioteca *TensorFlow*
 - 10.1.2. Treinamento de modelos com *TensorFlow*
 - 10.1.3. Operações com gráficos no *TensorFlow*
- 10.2. *TensorFlow* e NumPy
 - 10.2.1. Ambiente computacional NumPy para *TensorFlow*
 - 10.2.2. Utilização de arrays NumPy com *TensorFlow*
 - 10.2.3. Operações NumPy para gráficos do *TensorFlow*
- 10.3. Personalização de modelos e algoritmos de treinamento
 - 10.3.1. Construção de modelos personalizados com *TensorFlow*
 - 10.3.2. Gestão de parâmetros de treinamento
 - 10.3.3. Utilização de técnicas de otimização para treinamento
- 10.4. Funções e gráficos do *TensorFlow*
 - 10.4.1. Funções com *TensorFlow*
 - 10.4.2. Utilização de gráficos para treinamento de modelos
 - 10.4.3. Otimização de gráficos com operações do *TensorFlow*
- 10.5. Carregamento e pré-processamento de dados com *TensorFlow*
 - 10.5.1. Carregamento de conjuntos de dados com *TensorFlow*
 - 10.5.2. Pré-processamento de dados com *TensorFlow*
 - 10.5.3. Utilização de ferramentas do *TensorFlow* para manipulação de dados
- 10.6. A API *tf.data*
 - 10.6.1. Utilização da API *tf.data* para processamento de dados
 - 10.6.2. Construção de fluxos de dados com *tf.data*
 - 10.6.3. Uso da API *tf.data* para treinamento de modelos
- 10.7. O formato *TFRecord*
 - 10.7.1. Utilização da API *TFRecord* para serialização de dados
 - 10.7.2. Carregamento de arquivos *TFRecord* com *TensorFlow*
 - 10.7.3. Utilização de arquivos *TFRecord* para treinamento de modelos

- 10.8. Camadas de pré-processamento do Keras
 - 10.8.1. Utilização da API de pré-processamento do Keras
 - 10.8.2. Construção de *pipelines* de pré-processamento com Keras
 - 10.8.3. Uso da API de pré-processamento do Keras para treinamento de modelos
- 10.9. Projeto *TensorFlow Datasets*
 - 10.9.1. Utilização do *TensorFlow Datasets* para carregamento de dados
 - 10.9.2. Pré-processamento de dados com o *TensorFlow Datasets*
 - 10.9.3. Uso do *TensorFlow Datasets* para treinamento de modelos
- 10.10. Construção de uma aplicação de *Deep Learning* com *TensorFlow*
 - 10.10.1. Aplicação Prática
 - 10.10.2. Construção de uma aplicação de *Deep Learning* com *TensorFlow*
 - 10.10.3. Treinamento de um modelo com *TensorFlow*
 - 10.10.4. Utilização da aplicação para previsão de resultados

Módulo 11. *Deep Computer Vision* com Redes Neurais Convolucionais

- 11.1. A Arquitetura do *Visual Cortex*
 - 11.1.1. Funções do córtex visual
 - 11.1.2. Teorias da visão computacional
 - 11.1.3. Modelos de processamento de imagens
- 11.2. Camadas convolucionais
 - 11.2.1. Reutilização de pesos na convolução
 - 11.2.2. Convolução
 - 11.2.3. Funções de ativação
- 11.3. Camadas de agrupamento e implementação de camadas de agrupamento com o Keras
 - 11.3.1. *Pooling* e *Striding*
 - 11.3.2. *Flattening*
 - 11.3.3. Tipos de *Pooling*

- 11.4. Arquiteturas CNN
 - 11.4.1. Arquitetura VGG
 - 11.4.2. Arquitetura *AlexNet*
 - 11.4.3. Arquitetura *ResNet*
- 11.5. Implementação de uma CNN *ResNet*- usando o Keras
 - 11.5.1. Inicialização de pesos
 - 11.5.2. Definição da camada de entrada
 - 11.5.3. Definição da saída
- 11.6. Uso de modelos pré-treinados do Keras
 - 11.6.1. Características dos modelos pré-treinados
 - 11.6.2. Usos dos modelos pré-treinados
 - 11.6.3. Vantagens dos modelos pré-treinados
- 11.7. Modelos pré-treinados para aprendizado por transferência
 - 11.7.1. Aprendizagem por transferência
 - 11.7.2. Processo de aprendizagem por transferência
 - 11.7.3. Vantagens do aprendizado por transferência
- 11.8. Classificação e localização em *Deep Computer Vision*
 - 11.8.1. Classificação de imagens
 - 11.8.2. Localização de objetos em imagens
 - 11.8.3. Detecção de objetos
- 11.9. Detecção e rastreamento de objetos
 - 11.9.1. Métodos de detecção de objetos
 - 11.9.2. Algoritmos de rastreamento de objetos
 - 11.9.3. Técnicas de rastreamento e localização
- 11.10. Segmentação semântica
 - 11.10.1. Aprendizagem profunda para segmentação semântica
 - 11.10.2. Detecção de bordas
 - 11.10.3. Métodos de segmentação baseados em regras

Módulo 12. Processamento de Linguagem Natural (PLN) com Redes Neurais Recorrentes (RNN) e Atenção

- 12.1. Geração de texto usando RNN
 - 12.1.1. Treinamento de uma RNN para geração de texto
 - 12.1.2. Geração de linguagem natural com RNN
 - 12.1.3. Aplicações de geração de texto com RNN
- 12.2. Criação do conjunto de dados de treinamento
 - 12.2.1. Preparação dos dados para treinamento de uma RNN
 - 12.2.2. Armazenamento do conjunto de dados de treinamento
 - 12.2.3. Limpeza e transformação dos dados
 - 12.2.4. Análise de sentimento
- 12.3. Classificação de opiniões com RNN
 - 12.3.1. Detecção de temas nos comentários
 - 12.3.2. Análise de sentimento com algoritmos de aprendizagem profunda
- 12.4. Rede codificador-decodificador para tradução automática neural
 - 12.4.1. Treinamento de uma RNN para tradução automática
 - 12.4.2. Uso de uma rede *encoder-decoder* para tradução automática
 - 12.4.3. Aumento da precisão da tradução automática com RNN
- 12.5. Mecanismos de atenção
 - 12.5.1. Aplicação de mecanismos de atenção em RNN
 - 12.5.2. Uso de mecanismos de atenção para melhorar a precisão dos modelos
 - 12.5.3. Vantagens dos mecanismos de atenção em redes neurais
- 12.6. Modelos *Transformers*
 - 12.6.1. Uso de modelos *Transformers* para processamento de linguagem natural
 - 12.6.2. Aplicação de modelos *Transformers* para visão
 - 12.6.3. Vantagens dos modelos *Transformers*
- 12.7. *Transformers* para visão
 - 12.7.1. Uso de modelos *Transformers* para visão
 - 12.7.2. Processamento de dados Imagem
 - 12.7.3. Treinamento de modelos *Transformers* para visão

- 12.8. Biblioteca *Transformers* de *Hugging Face*
 - 12.8.1. Uso da Biblioteca *Transformers* de *Hugging Face*
 - 12.8.2. Aplicação da Biblioteca *Transformers* de *Hugging Face*
 - 12.8.3. Vantagens da Biblioteca *Transformers* de *Hugging Face*
- 12.9. Outras bibliotecas *Transformers*. Comparativa
 - 12.9.1. Comparação entre as diferentes bibliotecas *Transformers*
 - 12.9.2. Uso das diferentes bibliotecas *Transformers*
 - 12.9.3. Vantagens das diferentes bibliotecas *Transformers*
- 12.10. Desenvolvimento de um aplicativo de PLN com RNN e atenção. Aplicação Prática
 - 12.10.1. Desenvolvimento de um aplicativo de processamento de linguagem natural com RNN e atenção
 - 12.10.2. Uso de RNN, mecanismos de atenção e modelos *Transformers* no aplicativo
 - 12.10.3. Avaliação da aplicação prática

Módulo 13. *Autoencoders*, *GANs*, e Modelos de Difusão

- 13.1. Representação de dados eficientes
 - 13.1.1. Redução da dimensionalidade
 - 13.1.2. Aprendizado profundo
 - 13.1.3. Representações compactas
- 13.2. Realização de PCA com um codificador automático linear incompleto
 - 13.2.1. Processo de treinamento
 - 13.2.2. Implementação em Python
 - 13.2.3. Utilização de dados de teste
- 13.3. Codificadores automáticos empilhados
 - 13.3.1. Redes neurais profundas
 - 13.3.2. Construção de arquiteturas de codificação
 - 13.3.3. Uso da regularização
- 13.4. *Autoencoders* convolucionais
 - 13.4.1. Design de modelos convolucionais
 - 13.4.2. Treinamento de modelos convolucionais
 - 13.4.3. Avaliação de resultados

- 13.5. Eliminação de ruído de codificadores automáticos
 - 13.5.1. Aplicação de filtros
 - 13.5.2. Design de modelos de codificação
 - 13.5.3. Uso de técnicas de regularização
- 13.6. Codificadores automáticos dispersos
 - 13.6.1. Aumentando a eficiência da codificação
 - 13.6.2. Minimizando o número de parâmetros
 - 13.6.3. Utilização de técnicas de regularização
- 13.7. Codificadores automáticos variacionais
 - 13.7.1. Utilização de otimização variacional
 - 13.7.2. Aprendizagem profunda não supervisionada
 - 13.7.3. Representações latentes profundas
- 13.8. Geração de imagens MNIST de moda
 - 13.8.1. Reconhecimento de padrões
 - 13.8.2. Geração de imagens
 - 13.8.3. Treinamento de Redes Neurais Profundas
- 13.9. Redes adversárias generativas e modelos de difusão
 - 13.9.1. Geração de conteúdo a partir de imagens
 - 13.9.2. Modelagem de distribuições de dados
 - 13.9.3. Uso de redes adversárias
- 13.10. Implementação dos Modelos
 - 13.10.1. Aplicação Prática
 - 13.10.2. Implementação dos modelos
 - 13.10.3. Uso de dados reais
 - 13.10.4. Avaliação de resultados

Módulo 14. Computação bioinspirada

- 14.1. Introdução à computação bioinspirada
 - 14.1.1. Introdução à computação bioinspirada
- 14.2. Algoritmos de adaptação social
 - 14.2.1. Computação bioinspirada baseada em colônias de formigas
 - 14.2.2. Variantes dos algoritmos das colônias de formigas
 - 14.2.3. Computação baseada em nuvens de partículas

- 14.3. Algoritmos genéticos
 - 14.3.1. Estrutura geral
 - 14.3.2. Implementações dos principais operadores
- 14.4. Estratégias de exploração do espaço para algoritmos genéticos
 - 14.4.1. Algoritmo CHC
 - 14.4.2. Problemas multimodais
- 14.5. Modelos de computação evolutiva (I)
 - 14.5.1. Estratégias evolutivas
 - 14.5.2. Programação evolutiva
 - 14.5.3. Algoritmos baseados na evolução diferencial
- 14.6. Modelos de computação evolutiva (II)
 - 14.6.1. Modelos de evolução baseados em estimativas de distribuições (EDA)
 - 14.6.2. Programação genética
- 14.7. Programação evolutiva aplicada a dificuldades de aprendizagem
 - 14.7.1. Aprendizagem baseada em regras
 - 14.7.2. Métodos evolutivos em problemas de seleção de instâncias
- 14.8. Problemas multiobjetivo
 - 14.8.1. Conceito de dominância
 - 14.8.2. Aplicação de algoritmos evolutivos a problema multiobjetivo
- 14.9. Redes neurais (I)
 - 14.9.1. Introdução às redes neurais
 - 14.9.2. Exemplo prático com redes neurais
- 14.10. Redes neurais (II)
 - 14.10.1. Casos de uso de redes neurais na pesquisa médica
 - 14.10.2. Casos de uso de redes neurais em economia
 - 14.10.3. Casos de uso de redes neurais em visão artificial

Módulo 15. Inteligência Artificial: estratégias e aplicações

- 15.1. Serviços financeiros
 - 15.1.1. As implicações da Inteligência Artificial (IA) nos serviços financeiros
 - 15.1.2. Casos de uso
 - 15.1.3. Riscos potenciais relacionados ao uso de IA
 - 15.1.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.2. Implicações da Inteligência Artificial no serviço de saúde
 - 15.2.1. Implicações da IA no setor da saúde Oportunidades e desafios
 - 15.2.2. Casos de uso
- 15.3. Riscos relacionados com o uso de IA no serviço de saúde
 - 15.3.1. Riscos potenciais relacionados ao uso de IA
 - 15.3.2. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.4. *Retail*
 - 15.4.1. Participação da IA no Varejo Oportunidades e desafios
 - 15.4.2. Casos de uso
 - 15.4.3. Riscos potenciais relacionados ao uso de IA
 - 15.4.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.5. Indústria
 - 15.5.1. Participação da IA no Indústria Oportunidades e desafios
 - 15.5.2. Casos de uso
- 15.6. Potenciais riscos relacionados ao uso de IA da Indústria
 - 15.6.1. Casos de uso
 - 15.6.2. Riscos potenciais relacionados ao uso de IA
 - 15.6.3. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.7. Administração pública
 - 15.7.1. Participação da IA na administração pública Oportunidades e desafios
 - 15.7.2. Casos de uso
 - 15.7.3. Riscos potenciais relacionados ao uso de IA
 - 15.7.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.8. Educação
 - 15.8.1. Implicações da IA na educação. Oportunidades e desafios
 - 15.8.2. Casos de uso
 - 15.8.3. Riscos potenciais relacionados ao uso de IA
 - 15.8.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.9. Silvicultura e agricultura
 - 15.9.1. Participação da IA na silvicultura e na agricultura Oportunidades e desafios
 - 15.9.2. Casos de uso
 - 15.9.3. Riscos potenciais relacionados ao uso de IA
 - 15.9.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.10. Recursos Humanos
 - 15.10.1. Implicações da IA para os recursos humanos. Oportunidades e desafios
 - 15.10.2. Casos de uso
 - 15.10.3. Riscos potenciais relacionados ao uso de IA
 - 15.10.4. Potenciais desenvolvimentos/utilizações futuras da IA



Destaque-se no mercado de trabalho com um programa 100% online que se adapta às suas necessidades e permite uma aprendizagem imersiva e sólida”

06

Metodologia

Este curso oferece uma maneira diferente de aprender. Nossa metodologia é desenvolvida através de um modo de aprendizagem cíclico: o **Relearning**. Este sistema de ensino é utilizado, por exemplo, nas faculdades de medicina mais prestigiadas do mundo e foi considerado um dos mais eficazes pelas principais publicações científicas, como o **New England Journal of Medicine**.





“

Descubra o Relearning, um sistema que abandona a aprendizagem linear convencional para realizá-la através de sistemas de ensino cíclicos: uma forma de aprendizagem que se mostrou extremamente eficaz, especialmente em disciplinas que requerem memorização”

Estudo de caso para contextualizar todo o conteúdo

Nosso programa oferece um método revolucionário para desenvolver as habilidades e o conhecimento. Nosso objetivo é fortalecer as competências em um contexto de mudança, competitivo e altamente exigente.

“

Com a TECH você irá experimentar uma maneira de aprender que está revolucionando as bases das universidades tradicionais em todo o mundo”



Você terá acesso a um sistema de aprendizagem baseado na repetição, por meio de um ensino natural e progressivo ao longo de todo o programa.



Um método de aprendizagem inovador e diferente

Este curso da TECH é um programa de ensino intensivo, criado do zero, que propõe os desafios e decisões mais exigentes nesta área, em âmbito nacional ou internacional. Através desta metodologia, o crescimento pessoal e profissional é impulsionado em direção ao sucesso. O método do caso, técnica que constitui a base deste conteúdo, garante que a realidade econômica, social e profissional mais atual seja adotada.

“*Nosso programa prepara você para enfrentar novos desafios em ambientes incertos e alcançar o sucesso na sua carreira*”

Através de atividades de colaboração e casos reais, o aluno aprenderá a resolver situações complexas em ambientes reais de negócios.

O método do caso é o sistema de aprendizagem mais utilizado pelas melhores faculdades do mundo. Desenvolvido em 1912 para que os alunos de Direito pudessem aprender a lei não apenas com base no conteúdo teórico, o método do caso consistia em apresentar situações reais e complexas para que os alunos tomassem decisões e justificassem como resolvê-las. Em 1924 foi estabelecido como o método de ensino padrão em Harvard.

Em uma determinada situação, o que um profissional deveria fazer? Esta é a pergunta que abordamos no método do caso, um método de aprendizagem orientado para a ação. Ao longo do programa, os alunos irão se deparar com diversos casos reais. Terão que integrar todo o conhecimento, pesquisar, argumentar e defender suas ideias e decisões.

Metodologia Relearning

A TECH utiliza de maneira eficaz a metodologia do estudo de caso com um sistema de aprendizagem 100% online, baseado na repetição, combinando 8 elementos didáticos diferentes em cada aula.

Potencializamos o Estudo de Caso com o melhor método de ensino 100% online: o Relearning.

Em 2019 alcançamos os melhores resultados de aprendizagem entre todas as universidades online do mundo.

Na TECH você aprende através de uma metodologia de vanguarda, desenvolvida para capacitar os profissionais do futuro. Este método, na vanguarda da pedagogia mundial, se chama Relearning.

Nossa universidade é uma das únicas que possui a licença para usar este método de sucesso. Em 2019 conseguimos melhorar os níveis de satisfação geral dos nossos alunos (qualidade de ensino, qualidade dos materiais, estrutura dos curso, objetivos, entre outros) com relação aos indicadores da melhor universidade online.



No nosso programa, a aprendizagem não é um processo linear, ela acontece em espiral (aprender, desaprender, esquecer e reaprender). Portanto, combinamos cada um desses elementos de forma concêntrica. Esta metodologia já capacitou mais de 650 mil universitários com um sucesso sem precedentes em campos tão diversos como a bioquímica, a genética, a cirurgia, o direito internacional, habilidades administrativas, ciência do esporte, filosofia, direito, engenharia, jornalismo, história, mercados e instrumentos financeiros. Tudo isso em um ambiente altamente exigente, com um corpo discente com um perfil socioeconômico médio-alto e uma média de idade de 43,5 anos.

O Relearning permitirá uma aprendizagem com menos esforço e mais desempenho, fazendo com que você se envolva mais em sua especialização, desenvolvendo o espírito crítico e sua capacidade de defender argumentos e contrastar opiniões: uma equação de sucesso.

A partir das últimas evidências científicas no campo da neurociência, sabemos como organizar informações, ideias, imagens, memórias, mas sabemos também que o lugar e o contexto onde aprendemos algo é fundamental para nossa capacidade de lembrá-lo e armazená-lo no hipocampo, para mantê-lo em nossa memória a longo prazo.

Desta forma, no que se denomina Neurocognitive context-dependent e-learning, os diferentes elementos do nosso programa estão ligados ao contexto onde o aluno desenvolve sua prática profissional.



Neste programa, oferecemos o melhor material educacional, preparado especialmente para os profissionais:



Material de estudo

Todo o conteúdo foi criado especialmente para o curso pelos especialistas que irão ministrá-lo, o que faz com que o desenvolvimento didático seja realmente específico e concreto.

Posteriormente, esse conteúdo é adaptado ao formato audiovisual, para criar o método de trabalho online da TECH. Tudo isso, com as técnicas mais inovadoras que proporcionam alta qualidade em todo o material que é colocado à disposição do aluno.



Masterclasses

Há evidências científicas sobre a utilidade da observação de terceiros especialistas.

O "Learning from an expert" fortalece o conhecimento e a memória, além de gerar segurança para a tomada de decisões difíceis no futuro.




Práticas de habilidades e competências

Serão realizadas atividades para desenvolver competências e habilidades específicas em cada área temática. Práticas e dinâmicas para adquirir e ampliar as competências e habilidades que um especialista precisa desenvolver no contexto globalizado em que vivemos.



Leituras complementares

Artigos recentes, documentos de consenso e diretrizes internacionais, entre outros. Na biblioteca virtual da TECH o aluno terá acesso a tudo o que for necessário para complementar a sua capacitação.





Estudos de caso

Os alunos irão completar uma seleção dos melhores estudos de caso escolhidos especialmente para esta capacitação. Casos apresentados, analisados e orientados pelos melhores especialistas do cenário internacional.



Resumos interativos

A equipe da TECH apresenta o conteúdo de forma atraente e dinâmica através de pílulas multimídia que incluem áudios, vídeos, imagens, gráficos e mapas conceituais para consolidar o conhecimento.

Este sistema exclusivo de capacitação por meio da apresentação de conteúdo multimídia foi premiado pela Microsoft como "Caso de sucesso na Europa".



Testing & Retesting

Avaliamos e reavaliamos periodicamente o conhecimento do aluno ao longo do programa, através de atividades e exercícios de avaliação e autoavaliação, para que possa comprovar que está alcançando seus objetivos.



07

Certificado

O Mestrado Próprio em Inteligência Artificial garante, além da capacitação mais rigorosa e atualizada, o acesso a um título de Mestrado Próprio emitido pela TECH Universidade Tecnológica.



“

*Conclua este programa de estudos
com sucesso e receba o seu certificado
sem sair de casa e sem burocracias”*

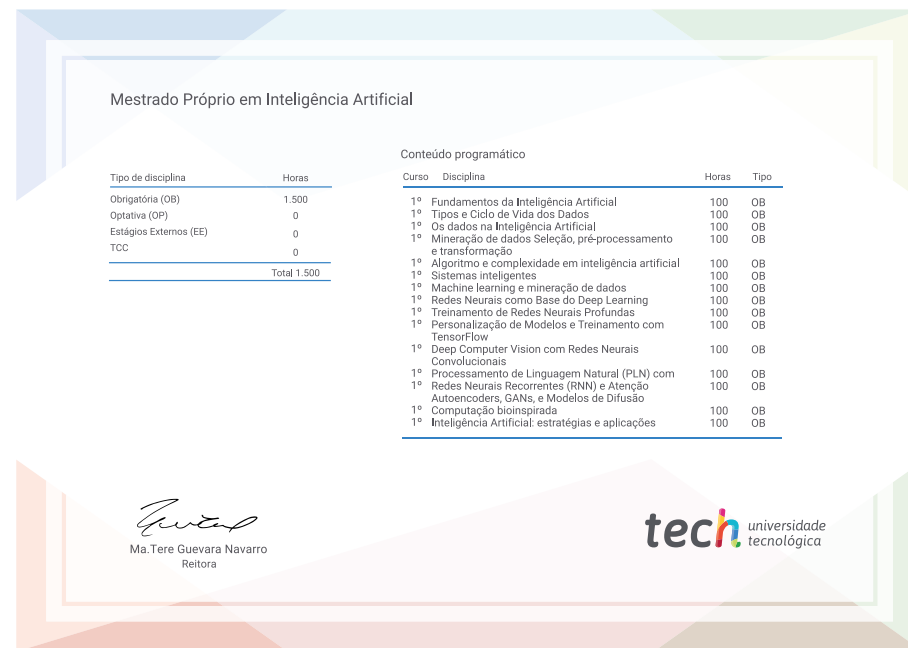
Este **Mestrado Próprio em Inteligência Artificial** conta com o conteúdo mais completo e atualizado do mercado.

Uma vez aprovadas as avaliações, o aluno receberá por correio o certificado* correspondente ao título de **Mestrado Próprio** emitido pela **TECH Universidade Tecnológica**.

O certificado emitido pela **TECH Universidade Tecnológica** expressará a qualificação obtida no Mestrado Próprio, atendendo aos requisitos normalmente exigidos pelas bolsas de empregos, concursos públicos e avaliação de carreira profissional.

Título: **Mestrado Próprio em Inteligência Artificial**

N.º de Horas Oficiais: **1.500h**



*Apostila de Haia: Caso o aluno solicite que seu certificado seja apostilado, a TECH EDUCATION providenciará a obtenção do mesmo a um custo adicional.

futuro
saúde confiança pessoas
informação orientadores
educação certificação ensino
garantia aprendizagem
instituições tecnologia
comunidade compreensão
atenção personalizada
conhecimento inovação
presente qualificação
desenvolvimento simulação

tech universidade
tecnológica

Mestrado Próprio Inteligência Artificial

- » Modalidade: online
- » Duração: 12 meses
- » Certificado: TECH Universidade Tecnológica
- » Dedicção: 16h/semana
- » Horário: no seu próprio ritmo
- » Provas: online

Mestrado Próprio

Inteligência Artificial