

Mestrado Próprio

Inteligência Artificial na Educação



tech universidade
tecnológica

Mestrado Próprio Inteligência Artificial na Educação

- » Modalidade: online
- » Duração: 12 meses
- » Certificado: TECH Universidade Tecnológica
- » Horário: no seu próprio ritmo
- » Provas: online

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

Índice

01

Apresentação

pág. 4

02

Objetivos

pág. 8

03

Competências

pág. 18

04

Direção do curso

pág. 22

05

Estrutura e conteúdo

pág. 26

06

Metodologia

pág. 44

07

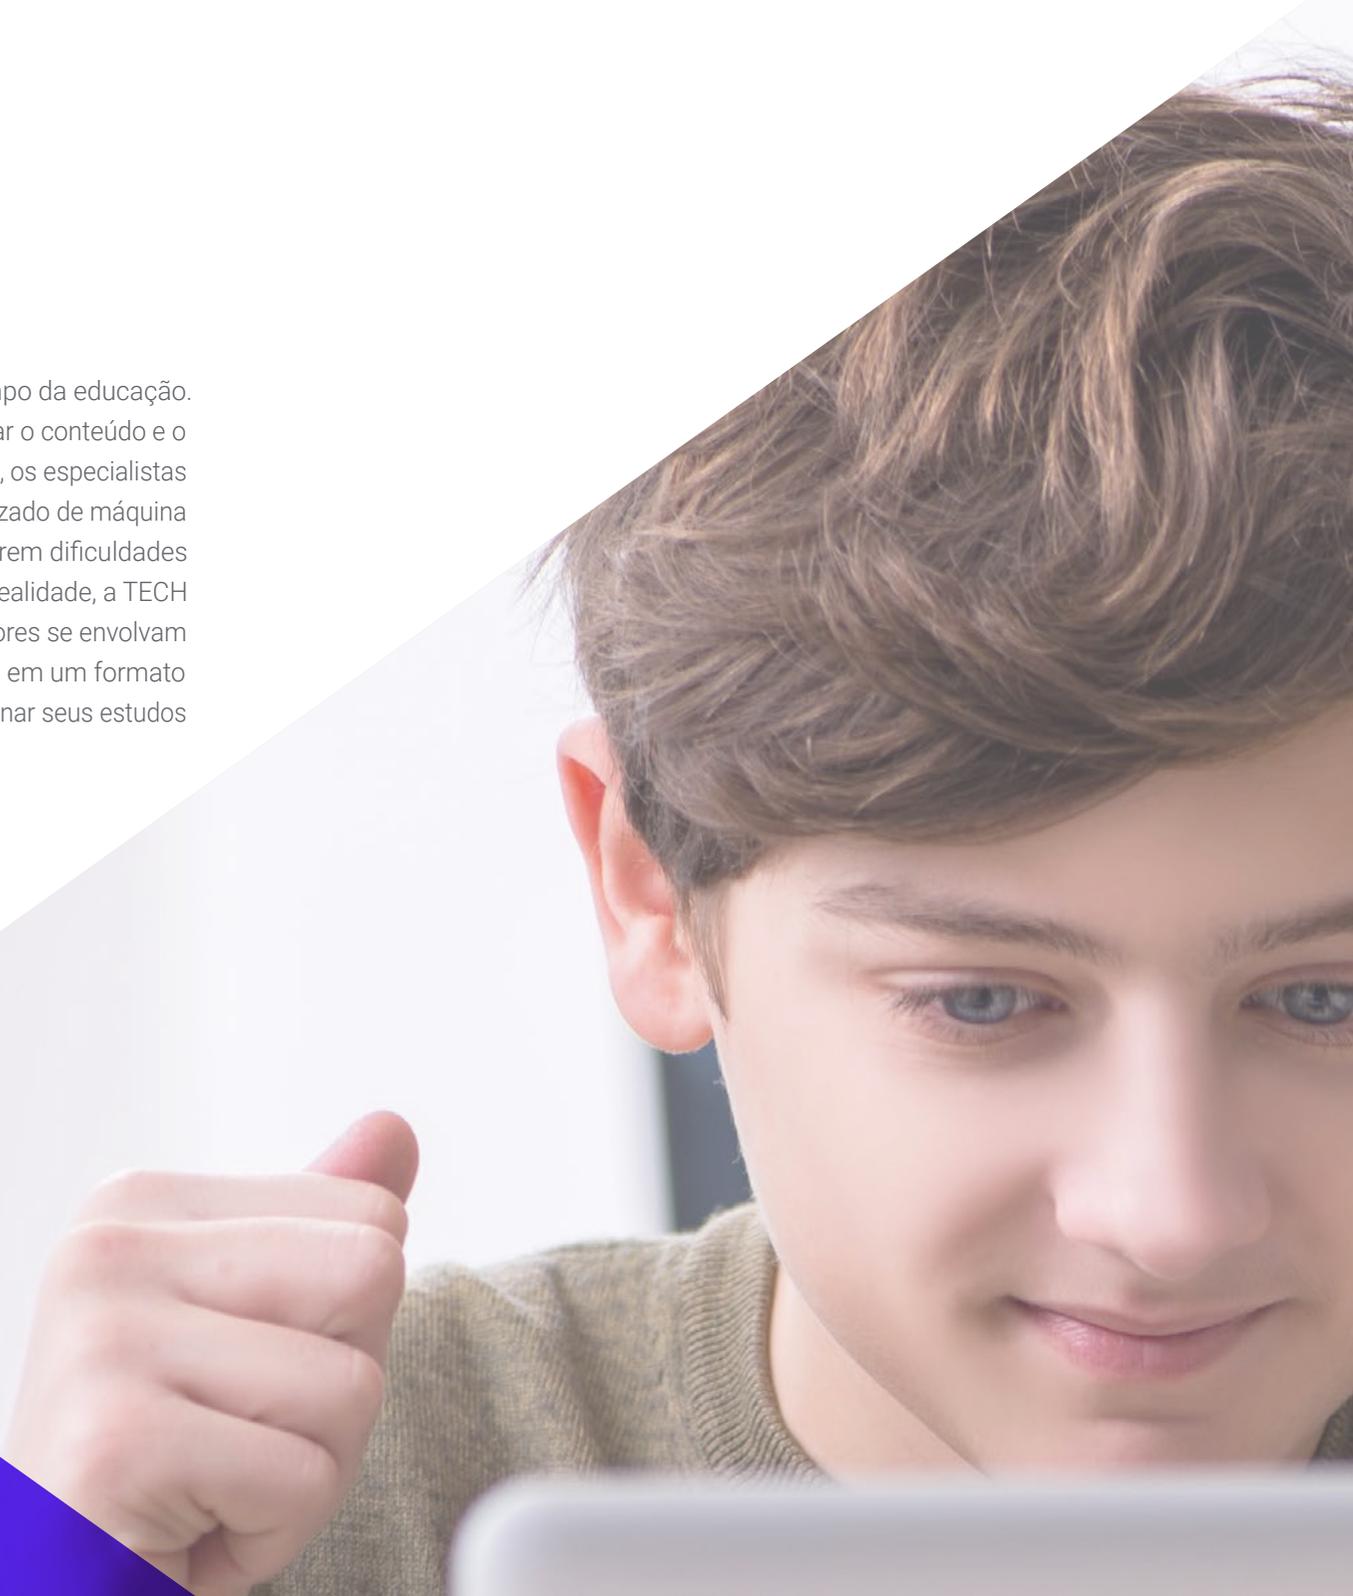
Certificado

pág. 52

01

Apresentação

A inteligência artificial (IA) tornou-se uma ferramenta útil para o campo da educação. Graças a essas tecnologias avançadas, os professores podem adaptar o conteúdo e o nível de dificuldade de acordo com as necessidades dos alunos. Assim, os especialistas promovem um aprendizado mais eficiente. Na mesma linha, o aprendizado de máquina serve para identificar padrões no desempenho dos alunos que sugerem dificuldades de aprendizagem, permitindo a intervenção precoce. Diante dessa realidade, a TECH desenvolveu um programa universitário que fará com que os professores se envolvam com a inovação em sua especialidade. Este programa é ministrado em um formato 100% online, permitindo que os alunos tenham flexibilidade para combinar seus estudos e o restante de suas atividades.



“

Por meio deste programa 100% online, você integrará ferramentas de Inteligência Artificial generativa no planejamento, na implementação e na avaliação de atividades educacionais"

Para otimizar os projetos educacionais, os professores usam ferramentas de IA para enriquecer a experiência dos alunos. Entretanto, para alcançar os resultados esperados, os profissionais precisam ter um amplo conhecimento das estratégias de implementação da IA em sala de aula. Assim, eles poderão desenvolver recursos como *chatbots*, jogos dinâmicos de aprendizagem e até mesmo ferramentas para avaliar o desempenho dos alunos.

Neste contexto, a TECH implementa este programa sobre Inteligência Artificial na Educação, no qual as considerações éticas, legais e sociais associadas também serão abordadas. Com uma abordagem eminentemente prática, os professores adquirirão habilidades tangíveis para implementar procedimentos de IA no ambiente educacional. Os alunos aprofundarão sua prática de ensino concentrando-se em fatores como a personalização da aprendizagem e o aprimoramento contínuo, indispensáveis para a adaptabilidade no processo educacional. Por último, o plano de estudos examinará em detalhes as tendências emergentes em IA para educação, garantindo que os participantes estejam cientes das últimas inovações em tecnologia educacional.

Deve-se observar que este programa universitário é baseado em uma metodologia 100% online para que os alunos possam aprender em seu próprio ritmo. Para isso, tudo o que eles precisam para acessar os recursos é de um dispositivo com acesso à Internet.

O programa acadêmico é baseado no método inovador do *Relearning*. Trata-se de um modelo de ensino apoiado na repetição do conteúdo mais importante, para que o conhecimento fique gravado na mente dos alunos. Para enriquecer o aprendizado, os materiais são complementados por uma ampla variedade de recursos multimídia (como resumos interativos, leituras complementares ou infográficos) para reforçar o conhecimento e as habilidades. Dessa forma, os alunos aprenderão de forma gradual e natural, sem ter que recorrer a esforços extras, como a memorização.

Este **Mestrado Próprio em Inteligência Artificial na Educação** 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 na Educação
- O conteúdo gráfico, esquemático e eminentemente prático, fornece informações teórica e práticas sobre as disciplinas fundamentais para a prática profissional
- Exercícios práticos em que o processo de autoavaliação é realizado para melhorar a aprendizagem
- Destaque especial para as metodologias inovadoras
- Aulas 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



Você quer facilitar o feedback instantâneo? Com esta capacitação, você identificará áreas de melhoria e oferecerá suporte personalizado"

“

Graças à revolucionária metodologia Relearning, você integrará todo o conhecimento de forma otimizada para alcançar com sucesso os resultados que está buscando”

O corpo docente deste curso 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, através da qual o profissional deverá 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 promoverá a inovação e a melhoria contínua na educação por meio do uso responsável da tecnologia.

Você contará com um programa avançado e exclusivo e será capaz de enfrentar os desafios do cenário educacional orientado pelo aprendizado de máquina.



02

Objetivos

Este Mestrado Próprio fornecerá aos professores as habilidades e o conhecimento necessários para revolucionar o cenário educacional. Ao combinar a IA com a pedagogia moderna, os alunos poderão desenvolver ambientes de aprendizagem personalizados. Além disso, eles promoverão a inovação na sala de aula e elaborarão estratégias educacionais adaptadas às necessidades dos alunos. Os especialistas também obterão um prisma abrangente para dominar os aplicativos de IA, otimizando assim o processo de ensino-aprendizagem. Dessa forma, os especialistas poderão enfrentar os desafios e cultivar uma educação muito mais eficiente.



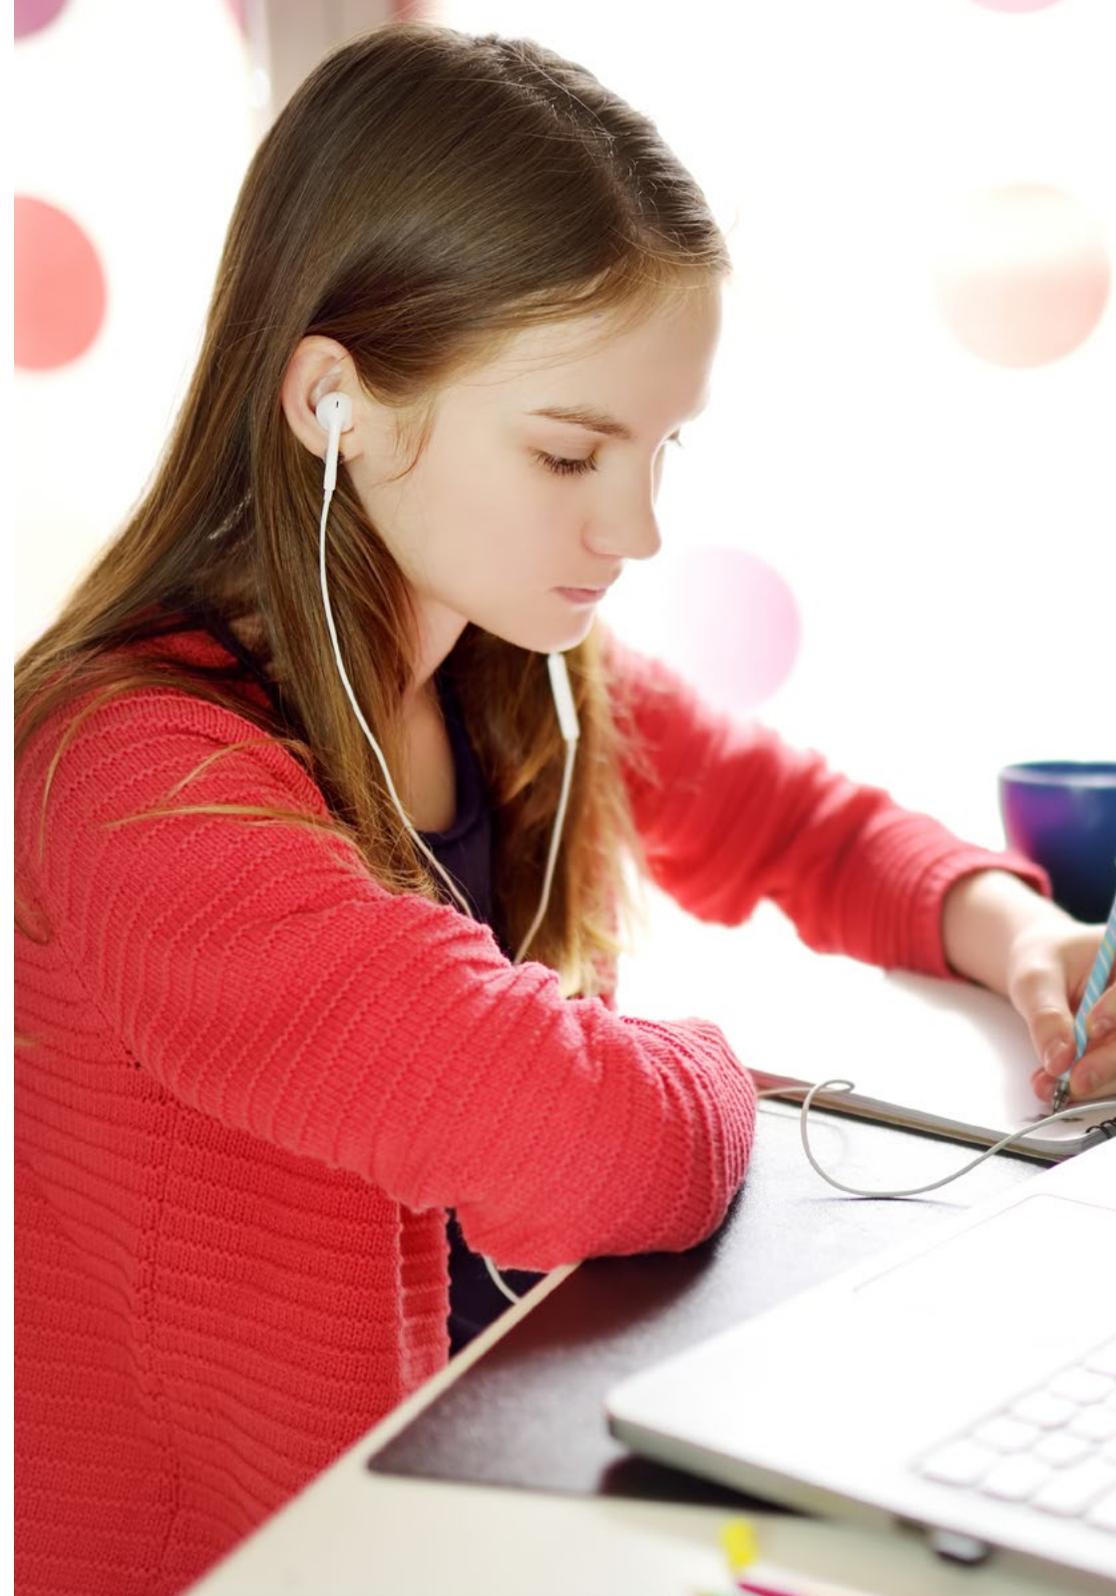
“

*Em pouco mais de um ano, será possível
impulsionar sua carreira e dominar a
tecnologia mais sofisticada para enriquecer
sua prática docente”*



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 conhecimentos sobre os algoritmos e a complexidade para resolver problemas específicos
- ♦ Explorar a base teórica das redes neurais para o desenvolvimento do *Deep Learning*
- ♦ Analisar 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
- ♦ Compreender os princípios éticos fundamentais relacionados à aplicação da IA em ambientes educacionais
- ♦ Analisar a estrutura legislativa atual e os desafios associados à implementação da IA no contexto educacional
- ♦ Incentivar o projeto e o uso responsáveis de soluções de IA em contextos educacionais, considerando a diversidade cultural e a igualdade de gênero
- ♦ Fornecer um entendimento completo dos fundamentos teóricos da IA, incluindo aprendizado de máquina, redes neurais e processamento de linguagem natural
- ♦ Compreender as aplicações e o impacto da IA no ensino e na aprendizagem, avaliando criticamente seus usos atuais e potenciais





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 aprendizagem 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
- ♦ Explorar 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 as principais etapas
- ♦ Conhecer 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* (Data Warehouse), com ênfase em seus elementos constituintes e design
- ♦ Analisar os aspectos regulatórios relacionados à gestão de dados, cumprindo as normas de privacidade e segurança e as práticas recomendadas

Módulo 3. Dados em 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*, compreender 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 manuseio 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
- ♦ Realizar 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 perdidos em conjuntos de dados, aplicando métodos de imputação ou eliminação de acordo com o contexto
- ♦ Identificar e mitigar o ruído em dados, usando técnicas de filtragem e suavização para melhorar a qualidade do conjunto de dados
- ♦ Abordar o pré-processamento de dados em ambientes *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, compreender sua estrutura e aplicações
- ♦ Investigar algoritmos com *Heaps*, analisar 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 relações complexas
- ♦ Estudar algoritmos *Greedy*, entendendo 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 aprendizagem supervisionada, 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, compreendendo sua função essencial no *Deep Learning*
- ♦ Analisar 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 união 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 aprendizagem 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 os 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 fundamentos de *TensorFlow* e sua integração com o NumPy para um 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 no desenvolvimento
- ♦ Desenvolver um aplicativo de *Deep Learning* com *TensorFlow*, integrando o conhecimento adquirido no módulo
- ♦ Aplicar de forma prática todos os conceitos aprendidos na construção e 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 no *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 Redes Neurais Convolucionais (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
- ◆ Utilizar modelos Keras pré-treinados para aproveitar a aprendizagem por transferência para tarefas específicas
- ◆ Aplicar técnicas de classificação e rastreamento em um ambiente de *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 utilizar modelos *Transformers* em tarefas específicas de NPL
- ◆ 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 NLP 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 automáticos empilhados
- ♦ 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
- ♦ Explorar os 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 aprendizagem
- ♦ 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
- ♦ Definir 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

Módulo 16. Análise de dados e aplicação de técnicas de IA para personalização educacional

- ♦ Aplicar IA na análise e avaliação de dados educacionais para promover a melhoria contínua em ambientes educacionais
- ♦ Definir indicadores de desempenho com base em dados educacionais para medir e melhorar o desempenho dos alunos
- ♦ Implementar tecnologias e algoritmos de IA para realizar análises preditivas em dados de desempenho acadêmico
- ♦ Realizar diagnósticos personalizados de dificuldades de aprendizagem por meio da análise de dados de IA, identificando necessidades educacionais específicas e projetando intervenções específicas
- ♦ Abordar a segurança e a privacidade no processamento de dados educacionais ao aplicar ferramentas de IA, garantindo a conformidade regulatória e ética

Módulo 17. Desenvolvimento de projetos de Inteligência Artificial em sala de aula

- ♦ Planejar e projetar projetos educativos que integrem de forma eficaz a IA em ambientes educacionais, dominando ferramentas específicas para seu desenvolvimento
- ♦ Planejar estratégias eficazes para implementar projetos de IA em ambientes de aprendizagem, integrando-os em disciplinas específicas para enriquecer e melhorar o processo educativo
- ♦ Desenvolver projetos educativos aplicando aprendizado de máquina para aprimorar a experiência de aprendizado, integrando a IA no design de jogos educativos no aprendizado lúdico
- ♦ Criar *chatbots* educacionais que auxiliem os alunos em seus processos de aprendizado e resolução de dúvidas, incluindo agentes inteligentes em plataformas educativas para melhorar a interação e o ensino

- ♦ Realizar uma análise contínua dos projetos de IA em Educação para identificar áreas de melhoria e otimização

Módulo 18. Prática de ensino com Inteligência Artificial generativa

- ♦ Dominar tecnologias de IA generativa para sua aplicação e uso efetivo em ambientes educacionais, planejando atividades educativas eficazes
- ♦ Criar materiais didáticos usando IA generativa para melhorar a qualidade e variedade de recursos de aprendizagem, bem como para medir o progresso dos alunos de maneira inovadora
- ♦ Utilizar IA generativa para corrigir atividades e testes avaliativos, agilizando e otimizando esse processo
- ♦ Integrar ferramentas de IA generativa em estratégias pedagógicas para melhorar a eficácia do processo educativo e projetar ambientes de aprendizado inclusivos, sob o enfoque do design universal
- ♦ Avaliar a eficácia da IA generativa na Educação, analisando seu impacto nos processos de ensino e aprendizagem

Módulo 19. Inovações e tendências emergentes em IA para educação

- ♦ Dominar ferramentas e tecnologias emergentes de IA aplicadas ao campo educacional para seu uso efetivo em ambientes de aprendizagem
- ♦ Integrar a Realidade Aumentada e Virtual na Educação para enriquecer e melhorar a experiência de aprendizado
- ♦ Aplique a IA conversacional para facilitar o suporte educacional e promover o aprendizado interativo entre os alunos
- ♦ Implementar tecnologias de reconhecimento facial e emocional para monitorar a participação e o bem-estar dos alunos na sala de aula

- ♦ Explorar a integração de *Blockchain* e IA na Educação para transformar a administração educacional e validar certificações

Módulo 20. Ética e legislação da inteligência artificial na educação

- ♦ Identificar e aplicar práticas éticas no manuseio de dados sensíveis no contexto educacional, priorizando a responsabilidade e o respeito
- ♦ Analisar o impacto social e cultural da IA na Educação, avaliando sua influência nas comunidades educacionais
- ♦ Compreender a legislação e as políticas relacionadas ao uso de dados em ambientes educacionais que envolvem IA
- ♦ Definir a interseção entre IA, diversidade cultural e equidade de gênero no contexto educacional
- ♦ Avaliar o impacto da IA na acessibilidade educacional, garantindo equidade no acesso ao conhecimento



Este Mestrado Próprio combina aspectos técnicos de Inteligência Artificial com um foco prático no desenvolvimento de projetos educacionais"

03

Competências

Este programa universitário permitirá que os alunos obtenham uma vantagem competitiva que os diferenciará dos demais. Dessa forma, eles dominarão aspectos como ética, legislação e desenvolvimento prático de projetos de IA projetados especificamente para a área educacional. Além disso, os profissionais adquirirão habilidades práticas para aplicar em seus projetos, enriquecendo muito a experiência dos alunos em sala de aula. Com este Mestrado Próprio, os especialistas poderão superar os desafios que surgem durante o exercício de sua profissão.



“

Você entrará em um campo em constante evolução, onde a inovação da Inteligência Artificial se funde com o aprendizado na educação”



Competências gerais

- ♦ Dominar as técnicas de mineração de dados, incluindo a seleção, o pré-processamento e a transformação de dados complexos
- ♦ Planejar e desenvolver sistemas inteligentes capazes de aprender e se adaptar a ambientes em constante mudança
- ♦ Controlar as ferramentas de aprendizado de máquina e sua aplicação na mineração de dados para a tomada de decisões
- ♦ Utilizar *Autoencoders*, *GANs* e modelagem de difusão para resolver desafios específicos em Inteligência Artificial
- ♦ Implementar de uma rede codificador-decodificador para tradução automática neuronal
- ♦ Aplicar os princípios fundamentais das redes neurais na resolução de problemas específicos
- ♦ Usar ferramentas, plataformas e técnicas de IA, desde a análise de dados até a aplicação de redes neurais e modelagem preditiva
- ♦ Desenvolver habilidades críticas para avaliar o impacto ético e social da IA na educação
- ♦ Capacitar para a criação e implementação de projetos de IA no campo educacional
- ♦ Desenvolver habilidades para integrar projetos de IA de forma eficaz e ética ao currículo educacional





Competências específicas

- ♦ Aplicar técnicas e estratégias de IA para melhorar a eficiência do setor *retail*
- ♦ Aprofundar a compreensão e a aplicação de algoritmos genéticos
- ♦ Implementar técnicas de redução de ruído usando codificadores automáticos
- ♦ Criar com eficiência 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 aplicação 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
- ♦ Ativar o Perceptron de múltiplas camadas (MLP) 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 perdidos em conjuntos de dados, aplicando métodos de imputação ou eliminação de acordo com o contexto
- ♦ Analisar 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
- ♦ Desenvolver habilidades críticas para avaliar o impacto ético e social da IA na educação
- ♦ Elaborar e implementar projetos de IA em contextos educacionais
- ♦ Aplicar a IA generativa no contexto educacional
- ♦ Criar materiais educacionais personalizados e adaptáveis
- ♦ Utilizar a IA para melhorar a avaliação e o feedback educacional
- ♦ Integrar de forma eficaz as tecnologias emergentes de IA à grade curricular educacional



Você projetará e implementará estratégias educacionais altamente inovadoras, por meio da integração da Inteligência Artificial"

04

Direção do curso

Com o objetivo de proporcionar uma capacitação baseada na excelência, a TECH conta com um plano de estudos exclusivo elaborado por especialistas do setor educacional. Estes profissionais possuem ampla experiência em IA aplicada à educação, tendo trabalhado para empresas de prestígio nesse campo. Por este motivo, a jornada acadêmica enfatiza o conteúdo com os mais recentes desenvolvimentos tecnológicos nesta área. Desta forma, o aluno contará com as garantias necessárias para se tornar um profissional, aprimorando seus conhecimentos com o apoio da melhor equipe de professores.



“

A diversidade de talentos e conhecimentos da equipe de professores criará um ambiente de aprendizagem dinâmico e enriquecedor" Capacite-se com os melhores!"

Direção



Dr. Arturo Peralta Martín-Palomino

- ♦ CEO e CTO em Prometeus Global Solutions
- ♦ CTO em Korporate Technologies
- ♦ CTO em AI Shephers GmbH
- ♦ Consultor e Assessor Estratégico de Negócios da Alliance Medical
- ♦ Diretor de Design e Desenvolvimento da DocPath
- ♦ Doutorado em Engenharia da Computação pela Universidade de Castilla - La Mancha
- ♦ Doutorado em Economia, Negócios e Finanças pela Universidade Camilo José Cela
- ♦ Doutorado em Psicologia pela Universidade de Castilla - La Mancha
- ♦ Mestrado em Executive MBA pela Universidade Isabel I
- ♦ Mestrado em Gestão Comercial e de Marketing pela Universidade Isabel I
- ♦ Mestrado Especialista em Big Data por Formação Hadoop
- ♦ Mestrado em Tecnologia da Informação Avançada pela Universidade de Castilla-La Mancha
- ♦ Membro: Grupo de pesquisa SMILE



Sr. Juan Felipe Nájera Puente

- ♦ Diretor de Estudos e Pesquisa no Conselho de Garantia da Qualidade do Ensino Superior
- ♦ Analista de Dados e Cientista de Dados
- ♦ Programador de Produção na Confiteca C.A
- ♦ Consultor de Processos na Esefex Consulting
- ♦ Analista de Planejamento Acadêmico na Universidad San Francisco de Quito
- ♦ Mestrado em *Big Data* e Ciência de Dados pela Universidade Internacional de Valência
- ♦ Engenheiro Industrial pela Universidad San Francisco de Quito

Professores

Sra. Yésica Martínez Cerrato

- ♦ Responsável por Capacitações Técnicas na Securitas Segurança Espanha
- ♦ Especialista em Educação, Negócios e Marketing
- ♦ *Product Manager* em Segurança Eletrônica na Securitas Segurança Espanha
- ♦ Analista de Inteligência Empresarial na Ricopia Technologies
- ♦ Técnico de Informática e Responsável por Salas de Informática OTEC na Universidade de Alcalá de Henares
- ♦ Colaboradora na Associação ASALUMA
- ♦ Graduado em Engenharia Eletrônica de Comunicações na Escola Politécnica Superior, Universidade de Alcalá de Henares

05

Estrutura e conteúdo

Composto por 20 módulos, este programa se destaca por sua abordagem abrangente e especializada. Os objetivos vão além dos aspectos técnicos da IA na educação, aprofundando-se nas considerações éticas, legais e sociais associadas. Ao mesmo tempo, o programa de estudos fornecerá aos alunos ferramentas tecnológicas de última geração, de modo que seu trabalho como professores integre inovações como Realidade Aumentada ou Análise Preditiva. A capacitação também destacará o foco na personalização da aprendizagem e na melhoria contínua, aspectos fundamentais para a adaptabilidade no processo educacional.



“

Esta capacitação inclui casos clínicos para que o desenvolvimento do programa seja o mais próximo possível da realidade do atendimento pedagógico"

Módulo 1. Fundamentos da Inteligência Artificial

- 1.1. História da inteligência artificial
 - 1.1.1. Quando começamos a falar sobre 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: *Intenções*, 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. Criação de 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: Estatísticas descritivas, inferências estatísticas
 - 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. Quantitativo: Dados contínuos e dados discretos
 - 2.2.1.2. Qualitativos: Dados binomiais, dados nominais e 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. Desenho
 - 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. Dados em 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 aprendizagem 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. Triade 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 C
 - 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 básicas 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. Aprendizado profundo
 - 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. 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 *pipelined* 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 D
 - 11.2.3. Funções de ativação
 - 11.3. Camadas de agrupamento e implementação de camadas de agrupamento com o Keras
 - 11.3.1. *Agrupamento e Deslocamento*
 - 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 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 aprendizagem 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
 - 11.10.1. Detecção de bordas
 - 11.10.1. 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 Oportunidades e desafios
 - 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 na área 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 ao uso de IA na área 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 *Retail*. 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 na Indústria. Oportunidades e desafios
 - 15.5.2. Casos de uso
- 15.6. Riscos potenciais relacionados ao uso de IA na 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. Implicações 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. Participação da IA nos 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
- Módulo 16. Análise de dados e aplicação de técnicas de IA para personalização educacional**
- 16.1. Identificação, Extração e Preparação de Dados Educacionais
 - 16.1.1. Aplicação do H2O.ai nos Métodos de coleta e seleção de dados relevantes em ambientes educacionais
 - 16.1.2. Técnicas de limpeza e normalização de dados para análises educacionais
 - 16.1.3. Importância da integridade e qualidade dos dados em pesquisas educacionais
 - 16.2. Análise e Avaliação de Dados Educacionais com IA para Melhoria Contínua na Sala de Aula
 - 16.2.1. Implementação do TensorFlow na interpretação de tendências e padrões educacionais por meio de técnicas de machine learning
 - 16.2.2. Implementação do TensorFlow na interpretação de tendências e padrões educacionais por meio de técnicas de machine learning
 - 16.2.3. Aplicação do Trinka na integração de feedback baseado em IA para a otimização do processo de ensino
 - 16.3. Definição de indicadores de desempenho acadêmico a partir de dados educacionais
 - 16.3.1. Estabelecimento de métricas-chave para avaliar o desempenho estudantil
 - 16.3.2. Análise comparativa de indicadores para identificar áreas de melhoria
 - 16.3.3. Correlação entre indicadores acadêmicos e fatores externos por meio de IA
 - 16.4. Ferramentas de IA para controle e tomada de decisões educacionais
 - 16.4.1. Sistemas de suporte à decisão com o tome.ai para administradores educacionais
 - 16.4.2. Utilização do Trello para planejamento e alocação de recursos educacionais
 - 16.4.3. Otimização de processos educacionais por meio de análise preditiva com Orange Data Mining
 - 16.5. Tecnologias e algoritmos de IA para análise preditiva de dados de desempenho acadêmico
 - 16.5.1. Fundamentos de modelos preditivos em educação
 - 16.5.2. Uso de algoritmos de classificação e regressão para prever tendências educacionais
 - 16.5.3. Estudos de caso de previsões bem-sucedidas em ambientes educacionais
 - 16.6. Aplicação de análise de dados com IA para prevenção e solução de problemas educacionais
 - 16.6.1. Identificação precoce de riscos acadêmicos por meio de análise preditiva
 - 16.6.2. Estratégias de intervenção baseadas em dados para abordar desafios educacionais
 - 16.6.3. Avaliação do impacto de soluções baseadas em IA do DataRobot na educação
 - 16.7. Diagnóstico personalizado de dificuldades de aprendizagem a partir de análise de dados com IA
 - 16.7.1. Técnicas de IA para identificação de estilos e dificuldades de aprendizagem com o IBM Watson Education
 - 16.7.2. Integração de análise de dados em planos de apoio educacional individualizados
 - 16.7.3. Estudo de casos de diagnósticos aprimorados pelo uso de IA
 - 16.8. Análise de dados e aplicação de IA para identificação de necessidades educacionais particulares
 - 16.8.1. Abordagens de IA para detecção de necessidades educacionais especiais com o Gooroo
 - 16.8.2. Personalização de estratégias de ensino com base na análise de dados
 - 16.8.3. Avaliação do impacto da IA na inclusão educacional
 - 16.9. Personalização da aprendizagem com IA a partir de análise de dados de desempenho acadêmico
 - 16.9.1. Criação de itinerários de aprendizagem adaptativos utilizando o Smart Sparrow
 - 16.9.2. Implementação de sistemas de recomendação para recursos educacionais
 - 16.9.3. Medição do progresso individual e ajustes em tempo real com o Squirrel AI Learning

- 16.10. Segurança e privacidade no tratamento de dados educacionais
 - 16.10.1. Princípios éticos e legais na gestão de dados educacionais
 - 16.10.2. Técnicas de proteção de dados e privacidade em sistemas educacionais com o Google Cloud Security
 - 16.10.3. Estudos de caso sobre violações de segurança e seu impacto na educação

Módulo 17. Desenvolvimento de projetos de Inteligência Artificial em sala de aula

- 17.1. Planejamento e criação de projetos de IA na educação
 - 17.1.1. Primeiros passos para planejar o projeto
 - 17.1.2. Bases de Conhecimento
 - 17.1.3. Criação de projetos de IA na educação
- 17.2. Ferramentas para o Desenvolvimento de Projetos Educacionais com IA
 - 17.2.1. Ferramentas para o desenvolvimento de projetos educacionais: TensorFlow Playground
 - 17.2.2. Ferramentas para projetos educacionais em História
 - 17.2.3. Ferramentas para projetos educacionais em Matemática: Wolfram Alpha
 - 17.2.4. Ferramentas para projetos educacionais em Inglês: Grammarly
- 17.3. Estratégias de implementação de projetos de IA na sala de aula
 - 17.3.1. Quando implantar um projeto de IA
 - 17.3.2. Por que implantar um projeto de IA
 - 17.3.3. Estratégias a serem realizadas
- 17.4. Integração de projetos de IA em disciplinas específicas
 - 17.4.1. Matemática e IA: Thinkster Math
 - 17.4.2. História e IA
 - 17.4.3. Idiomas e IA: DeepL
 - 17.4.4. Outras disciplinas: Watson Studio
- 17.5. Projeto 1: Desenvolvimento de projetos educacionais utilizando aprendizado de máquina com Khan Academy
 - 17.5.1. Primeiros passos
 - 17.5.2. Levantamento de requisitos
 - 17.5.3. Ferramentas a serem utilizadas
 - 17.5.4. Definição do projeto

- 17.6. Projeto 2: Integração da IA no desenvolvimento de jogos educacionais
 - 17.6.1. Primeiros passos
 - 17.6.2. Tomada de exigências
 - 17.6.3. Ferramentas a ser utilizadas
 - 17.6.4. Definição do projeto
- 17.7. Projeto 3: Desenvolvimento de *chatbots* educacionais para assistência estudantil
 - 17.7.1. Primeiros passos
 - 17.7.2. Tomada de exigências
 - 17.7.3. Ferramentas a ser utilizadas
 - 17.7.4. Definição do projeto
- 17.8. Projeto 4: Integração de agentes inteligentes em plataformas educacionais com Knewton
 - 17.8.1. Primeiros passos
 - 17.8.2. Tomada de exigências
 - 17.8.3. Ferramentas a ser utilizadas
 - 17.8.4. Definição do projeto
- 17.9. Avaliação e medição do impacto de projetos de IA na educação com Qualtrics
 - 17.9.1. Benefícios de trabalhar com IA na sala de aula
 - 17.9.2. Dados reais
 - 17.9.3. IA na sala de aula
 - 17.9.4. Estatísticas da IA na educação
- 17.10. Análise e melhoria contínua de projetos de IA na educação com Edmodo Insights
 - 17.10.1. Projetos atuais
 - 17.10.2. Implementação
 - 17.10.3. O que nos espera no futuro
 - 17.10.4. Transformando a sala de aula 360

Módulo 18. Prática de ensino com Inteligência Artificial generativa

- 18.1. Tecnologias de IA generativa para uso na Educação
 - 18.1.1. Mercado atual: Artbreeder, Runway ML e DeepDream Generator
 - 18.1.2. Tecnologias em uso
 - 18.1.3. O que está por vir
 - 18.1.4. O futuro da sala de aula

- 18.2. Aplicação de ferramentas de IA generativa no planejamento educacional
 - 18.2.1. Ferramentas de planejamento: Altitude Learning
 - 18.2.2. Ferramentas e sua aplicação
 - 18.2.3. Educação e IA
 - 18.2.4. Evolução
 - 18.3. Criação de materiais didáticos com IA generativa usando Story Ai, Pix2Pix e NeouralTalk2
 - 18.3.1. IA e seus usos na sala de aula
 - 18.3.2. Ferramentas para criar material didático
 - 18.3.3. Como trabalhar com as ferramentas
 - 18.3.4. Comandos
 - 18.4. Desenvolvimento de provas de avaliação com IA generativa usando Quizgecko
 - 18.4.1. IA e seus usos no desenvolvimento de provas de avaliação
 - 18.4.2. Ferramentas para o desenvolvimento de provas de avaliação
 - 18.4.3. Como trabalhar com as ferramentas
 - 18.4.4. Comandos
 - 18.5. Feedback e comunicação aprimorados com IA generativa
 - 18.5.1. A IA na comunicação
 - 18.5.2. Aplicação de ferramentas no desenvolvimento da comunicação em sala de aula
 - 18.5.3. Vantagens e Desvantagens
 - 18.6. Correção de atividades e provas avaliativas com IA generativa usando Gradescope AI
 - 18.6.1. IA e seus usos na correção de atividades e provas avaliativas
 - 18.6.2. Ferramentas para a correção de atividades e provas avaliativas
 - 18.6.3. Como trabalhar com as ferramentas
 - 18.6.4. Comandos
 - 18.7. Geração de pesquisas de avaliação da qualidade docente com IA generativa
 - 18.7.1. IA e seus usos na geração de pesquisas de avaliação da qualidade docente com IA
 - 18.7.2. Ferramentas para a geração de pesquisas de avaliação da qualidade docente com IA
 - 18.7.3. Como trabalhar com as ferramentas
 - 18.7.4. Comandos
 - 18.8. Integração de ferramentas de IA generativa em estratégias pedagógicas
 - 18.8.1. Aplicações da IA nas estratégias pedagógicas
 - 18.8.2. Usos corretos
 - 18.8.3. Vantagens e Desvantagens
 - 18.8.4. Ferramentas de IA generativa em estratégias pedagógicas: GANs
 - 18.9. Utilização de IA generativa para o design universal para a aprendizagem
 - 18.9.1. IA generativa, por que agora
 - 18.9.2. IA na aprendizagem
 - 18.9.3. Vantagens e Desvantagens
 - 18.9.4. Aplicações da IA na aprendizagem
 - 18.10. Avaliação da efetividade da IA generativa na Educação
 - 18.10.1. Dados sobre efetividade
 - 18.10.2. Projetos
 - 18.10.3. Propósitos de design
 - 18.10.4. Avaliar a efetividade da IA na Educação
- Módulo 19. Inovações e tendências emergentes em IA para educação**
- 19.1. Ferramentas e tecnologias emergentes de IA no âmbito educacional
 - 19.1.1. Ferramentas obsoletas de IA
 - 19.1.2. Ferramentas atuais: ClassDojo e Seesaw
 - 19.1.3. Ferramentas futuras
 - 19.2. Realidade Aumentada e Virtual na Educação
 - 19.2.1. Ferramentas de realidade aumentada
 - 19.2.2. Ferramentas de realidade virtual
 - 19.2.3. Aplicação de ferramentas e seus usos
 - 19.2.4. Vantagens e Desvantagens
 - 19.3. IA conversacional para apoio educacional e aprendizado interativo com Wysdom AI e SnatchBot
 - 19.3.1. IA conversacional, por que agora
 - 19.3.2. IA na aprendizagem
 - 19.3.3. Vantagens e Desvantagens
 - 19.3.4. Aplicações da IA na aprendizagem

- 19.4. Aplicação de IA para a melhoria da retenção de conhecimento
 - 19.4.1. IA como ferramenta de apoio
 - 19.4.2. Diretrizes a seguir
 - 19.4.3. Desempenho da IA na retenção de conhecimento
 - 19.4.4. IA e ferramentas de apoio
- 19.5. Tecnologias de reconhecimento facial e emocional para o acompanhamento da participação e do bem-estar dos estudantes
 - 19.5.1. Tecnologias de reconhecimento facial e emocional no mercado atual
 - 19.5.2. Usos
 - 19.5.3. Aplicações
 - 19.5.4. Margem de erro
 - 19.5.5. Vantagens e Desvantagens
- 19.6. *Blockchain* e IA na Educação para transformar a administração educacional e a certificação
 - 19.6.1. O que é o *Blockchain*
 - 19.6.2. *Blockchain* e suas aplicações
 - 19.6.3. *Blockchain* como elemento transformador
 - 19.6.4. Administração educacional e *Blockchain*
- 19.7. Ferramentas emergentes de IA para melhorar a experiência de aprendizado com Squirrel AI Learning
 - 19.7.1. Projetos atuais
 - 19.7.2. Implementação
 - 19.7.3. O que nos espera no futuro
 - 19.7.4. Transformando a sala de aula 360
- 19.8. Estratégias para o desenvolvimento de pilotos com IA emergente
 - 19.8.1. Vantagens e Desvantagens
 - 19.8.2. Estratégias a desenvolver
 - 19.8.3. Pontos-chave
 - 19.8.4. Projetos piloto

- 19.9. Análise de Casos de Sucesso em Inovações de IA
 - 19.9.1. Projetos inovadores
 - 19.9.2. Aplicação de IA e seus benefícios
 - 19.9.3. IA na sala de aula, casos de sucesso
- 19.10. Futuro da IA na Educação
 - 19.10.1. História da IA na educação
 - 19.10.2. Para onde vai a IA na Sala de Aula
 - 19.10.3. Projetos futuros

Módulo 20. Ética e legislação da inteligência artificial na educação

- 20.1. Identificação e tratamento ético de dados sensíveis no contexto educacional
 - 20.1.1. Princípios e práticas para o manejo ético de dados sensíveis na educação
 - 20.1.2. Desafios na proteção da privacidade e confidencialidade dos dados dos alunos
 - 20.1.3. Estratégias para garantir a transparência e o consentimento informado na coleta de dados
- 20.2. Impacto Social e Cultural da IA na Educação
 - 20.2.1. Análise do efeito da IA nas dinâmicas sociais e culturais em ambientes educacionais
 - 20.2.2. Exploração de como o Microsoft AI for Accessibility pode perpetuar ou mitigar preconceitos e desigualdades sociais
 - 20.2.3. Avaliação da responsabilidade social de desenvolvedores e educadores na implementação da IA
- 20.3. Legislação e política de dados em IA em ambientes educacionais
 - 20.3.1. Revisão das leis e regulamentos atuais sobre dados e privacidade aplicáveis à IA na educação
 - 20.3.2. Impacto das políticas de dados na prática educacional e na inovação tecnológica
 - 20.3.3. Desenvolvimento de políticas institucionais para o uso ético da IA na educação com AI Ethics Lab

- 20.4. Avaliação do impacto ético da IA
 - 20.4.1. Métodos para avaliar as implicações éticas das aplicações de IA na educação
 - 20.4.2. Desafios na medição do impacto social e ético da IA
 - 20.4.3. Criação de marcos éticos para guiar o desenvolvimento e uso da IA na educação
- 20.5. Desafios e oportunidades da IA na Educação
 - 20.5.1. Identificação dos principais desafios éticos e legais no uso da IA na educação
 - 20.5.2. Exploração das oportunidades para melhorar o ensino e a aprendizagem com Squirrel AI Learning
 - 20.5.3. Equilíbrio entre inovação tecnológica e considerações éticas na educação
- 20.6. Aplicação ética de soluções de IA no ambiente educacional
 - 20.6.1. Princípios para o design e implementação ética de soluções de IA na educação
 - 20.6.2. Estudo de casos sobre aplicações éticas da IA em diferentes contextos educacionais
 - 20.6.3. Estratégias para envolver todos os stakeholders na tomada de decisões éticas sobre IA
- 20.7. IA, diversidade cultural e equidade de gênero
 - 20.7.1. Análise do impacto da IA na promoção da diversidade cultural e da equidade de gênero na educação
 - 20.7.2. Estratégias para desenvolver sistemas de IA inclusivos e sensíveis à diversidade com Teachable Machine do Google
 - 20.7.3. Avaliação de como a IA pode influenciar a representação e o tratamento de diferentes grupos culturais e de gênero
- 20.8. Considerações éticas para o uso de ferramentas de IA na Educação
 - 20.8.1. Diretrizes éticas para o desenvolvimento e uso de ferramentas de IA na sala de aula
 - 20.8.2. Discussão sobre o equilíbrio entre automação e intervenção humana na educação
 - 20.8.3. Análise de casos em que o uso de IA na educação levantou questões éticas significativas
- 20.9. Impacto da IA na acessibilidade educacional
 - 20.9.1. Exploração de como a IA pode melhorar ou limitar a acessibilidade na educação
 - 20.9.2. Análise de soluções de IA projetadas para aumentar a inclusão e o acesso à educação para todos com o Google Read Along
 - 20.9.3. Desafios éticos na implementação de tecnologias de IA para melhorar a acessibilidade
- 20.10. Casos de estudo globais em IA e Educação
 - 20.10.1. Análise de casos de estudo internacionais sobre o uso de IA na educação
 - 20.10.2. Comparação de abordagens éticas e legais em diferentes contextos culturais educacionais
 - 20.10.3. Lições aprendidas e melhores práticas de casos globais em IA e educação

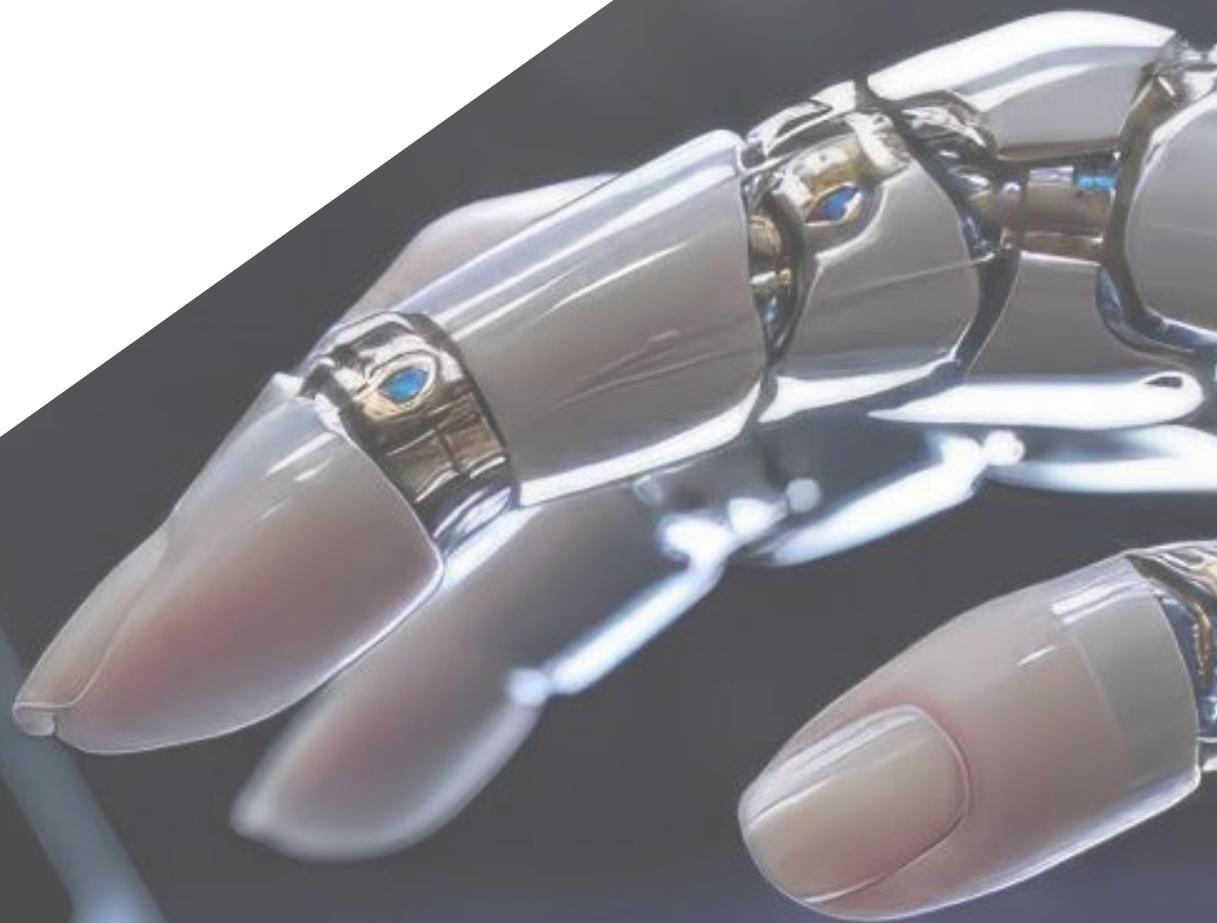


Um programa 100% online, sem horários rígidos e com um plano de estudos disponível desde o primeiro dia. Matricule-se hoje mesmo!"

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 forma 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 nas principais escolas de Informática do mundo, desde que elas existem. Desenvolvido em 1912 para que os estudantes de Direito não aprendessem a lei apenas com base no conteúdo teórico, o método do caso consistia em apresentar-lhes situações realmente complexas para que tomassem decisões conscientes e julgassem a melhor forma de 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 curso, os alunos vão se deparar com múltiplos 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 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 aprenderá 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.



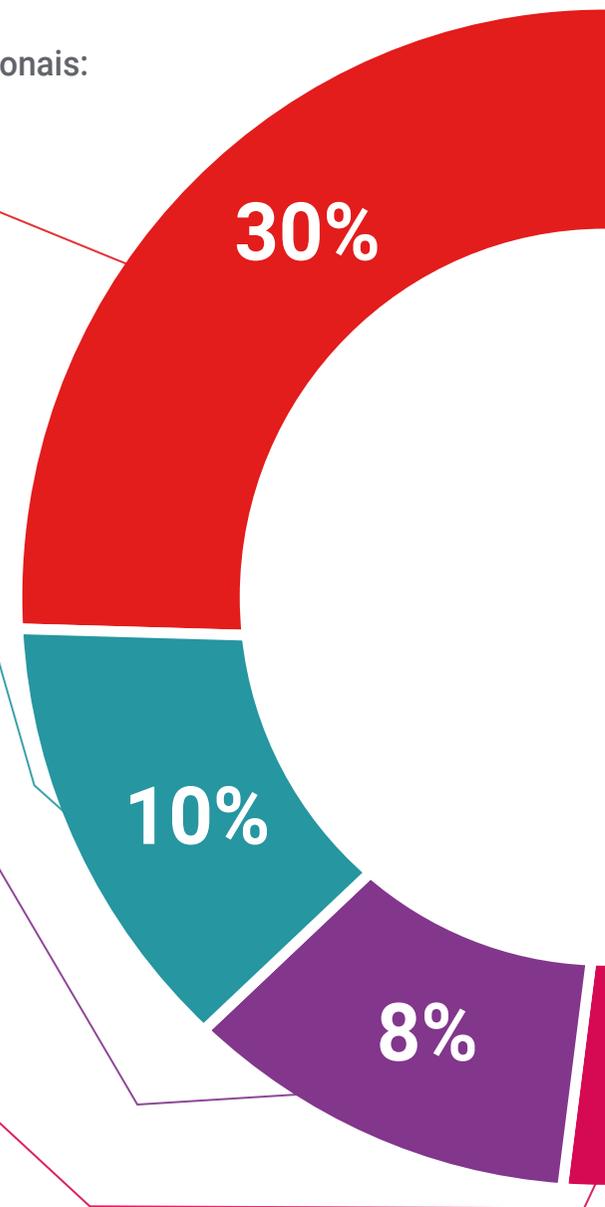
Práticas de habilidades e competências

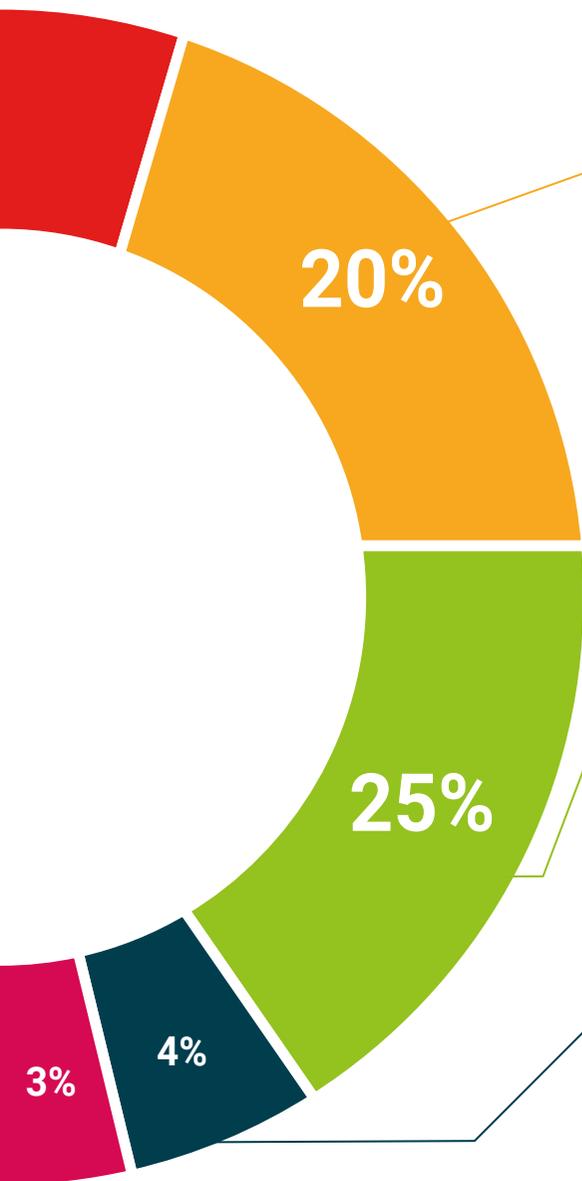
Serão realizadas atividades para desenvolver competências e habilidades específicas em cada área temática. Práticas e dinâmicas para adquirir e ampliar as competências e habilidades que um especialista precisa desenvolver no contexto globalizado em que vivemos.



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 na Educação 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 seu certificado sem sair de casa e sem burocracias”

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

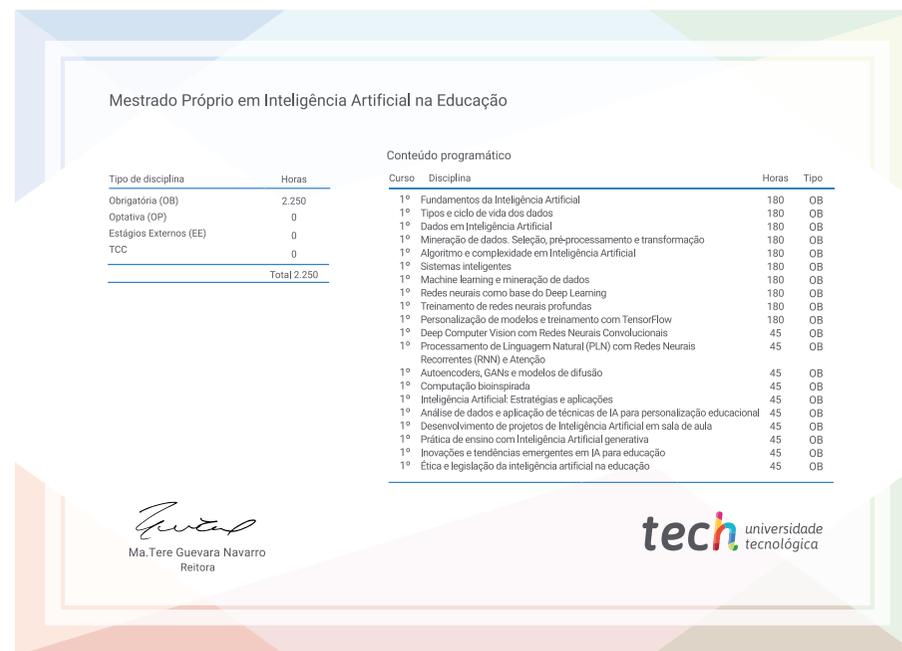
Uma vez aprovadas as avaliações, o aluno receberá por correio o certificado* correspondente ao título de **Mestrado Próprio** emitido pela **TECH Universidade Tecnológica**.

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 na Educação**

Modalidade: **online**

Duração: **12 meses**



*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 comunidade
atenção personalizada
conhecimento inovação
presente qualidade
desenvolvimento simulação

tech universidade
tecnológica

Mestrado Próprio
Inteligência Artificial
na Educação

- » Modalidade: online
- » Duração: 12 meses
- » Certificado: TECH Universidade Tecnológica
- » Horário: no seu próprio ritmo
- » Provas: online

Mestrado Próprio

Inteligência Artificial na Educação

