

Mestrado Próprio

Inteligência Artificial na Educação



Mestrado Próprio Inteligência Artificial na Educação

- » Modalidade: online
- » Duração: 12 meses
- » Certificação: TECH Global University
- » Acreditação: 90 ECTS
- » Horário: Ao seu próprio ritmo
- » Exames: online

Acesso ao site: www.techtute.com/pt/inteligencia-artificial/mestrado-proprio/mestrado-proprio-inteligencia-artificial-eduacao

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


Certificação

pág. 52

01

Apresentação

A Inteligência Artificial (IA) tornou-se uma ferramenta útil no domínio da Educação. Graças a estas tecnologias avançadas, os professores podem adaptar o conteúdo e o nível de dificuldade de acordo com as necessidades dos alunos. Assim, os especialistas promovem uma aprendizagem mais eficiente. Nesse sentido, a Aprendizagem Automática serve para identificar padrões no desempenho dos alunos que apresentam dificuldades de aprendizagem, permitindo uma intervenção precoce. Face a esta realidade, a TECH está a desenvolver uma certificação que irá mergulhar os professores na inovação na sua especialidade. É ministrado num formato 100% online, permitindo aos estudantes a flexibilidade de conciliar os seus estudos com o resto das suas atividades.



“

Através deste curso 100% online, irá integrar ferramentas generativas de Inteligência Artificial no planeamento, implementação e avaliação de atividades educativas"

A fins de otimizar os projetos educativos, os professores utilizam ferramentas de IA para enriquecer a experiência dos alunos. No entanto, para alcançar os resultados esperados, os profissionais precisam de ter um conhecimento alargado das estratégias de implementação da IA na sala de aula. Assim, poderão desenvolver recursos como o *chatbots*, jogos didáticos dinâmicos e até instrumentos para avaliar o desempenho dos alunos.

Neste contexto, a TECH implementa este curso sobre Inteligência Artificial na Educação, onde serão também abordadas as considerações éticas, jurídicas e sociais associadas. Com uma abordagem eminentemente prática, os professores adquirirão competências tangíveis para implementar procedimentos de IA no ambiente educativo. Os alunos aprofundarão a sua prática pedagógica, centrando-se em fatores como a personalização da aprendizagem e a melhoria contínua, indispensáveis à adaptabilidade do processo educativo. Por último, o plano de estudos analisará em pormenor as tendências emergentes da IA na Educação, garantindo que os alunos estejam a par das últimas inovações na tecnologia educativa.

É de salientar que este mestrado próprio baseia-se numa metodologia 100% online para que os estudantes possam aprender ao seu próprio ritmo. Assim, a única coisa de que necessita para aceder ao programa de estudos é um dispositivo com acesso à Internet. O plano de estudos baseia-se no método inovador do *Relearning*. Trata-se de um modelo de ensino apoiado na repetição dos conteúdos mais importantes, para que os conhecimentos se fixem na mente dos alunos. Para enriquecer a aprendizagem, os materiais são complementados com uma vasta gama de recursos multimédia (tais como resumos interativos, leituras suplementares ou infografias) para reforçar os conhecimentos e as competências. Desta forma, os alunos aprenderão de forma gradual e natural, sem terem de recorrer a esforços suplementares, como a memorização.

Este **Mestrado Próprio em Inteligência Artificial na Educação** conta com o conteúdo educativo mais completo e atualizado do mercado. As suas principais características são:

- O desenvolvimento de casos práticos apresentados por especialistas em Inteligência Artificial na Educação
- Os conteúdos gráficos, esquemáticos e predominantemente práticos com que está concebido fornecem informações científicas e práticas sobre as disciplinas que são essenciais para a prática profissional
- Os exercícios práticos onde o processo de autoavaliação pode ser efetuado a fim de melhorar a aprendizagem
- O seu foco especial em metodologias inovadoras
- As aulas teóricas, perguntas ao especialista, fóruns de discussão sobre temas controversos e atividades de reflexão individual
- A disponibilidade de acesso aos conteúdos a partir de qualquer dispositivo fixo ou portátil com ligação à Internet



Quer facilitar a retroalimentação instantânea? Com este certificado, identificará áreas a melhorar e oferecerá apoio personalizado"

“

Graças à revolucionária metodologia Relearning, integrará todos os conhecimentos de forma otimizada para alcançar com êxito os resultados que procura"

O corpo docente do programa inclui profissionais do sector que trazem a experiência do seu trabalho para esta formação, bem como especialistas reconhecidos das principais sociedades e universidades de prestígio.

Os seus conteúdos multimédia, desenvolvidos com a mais recente tecnologia educativa, permitirão ao profissional uma aprendizagem situada e contextual, ou seja, um ambiente simulado que proporcionará uma formação imersiva programada para treinar em situações reais.

O design deste programa foca-se na Aprendizagem Baseada em Problemas, através da qual o profissional deverá tentar resolver as diferentes situações da atividade profissional que surgem ao longo do curso. Para tal, contará com a ajuda de um sistema inovador de vídeo interativo desenvolvido por especialistas reconhecidos.

Irá promover a inovação e a melhoria contínua da educação através da utilização responsável da tecnologia.

Terá um curso avançado e único e será capaz de enfrentar os desafios do panorama educativo orientado para a Aprendizagem Automática.



02

Objetivos

Este Mestrado Próprio irá proporcionar aos professores as competências e os conhecimentos necessários para revolucionar o panorama educativo. Ao combinar a IA com a pedagogia moderna, os alunos poderão desenvolver ambientes de aprendizagem personalizados. Além disso, promoverão a inovação na sala de aula e designarão estratégias educativas adaptadas às necessidades dos alunos. Mais ainda, os especialistas ganharão um prisma abrangente para dominar as aplicações de IA, otimizando assim o processo de ensino-aprendizagem. Desta forma, os especialistas poderão enfrentar os desafios e cultivar uma educação muito mais eficiente.



“

Em pouco mais de um ano, dará à sua carreira o impulso de que necessita e dominará a tecnologia mais sofisticada para enriquecer a sua prática pedagógica"



Objetivos gerais

- ♦ Compreender os fundamentos teóricos da Inteligência Artificial
- ♦ Estudar os diferentes tipos de dados e compreender o ciclo de vida dos dados
- ♦ Avaliar o papel crucial dos dados no desenvolvimento e implementação de soluções de Inteligência Artificial
- ♦ Aprofundar a compreensão dos algoritmos e da complexidade para resolver problemas específicos
- ♦ Explorar a base teórica das redes neurais para o desenvolvimento da *Deep Learning*
- ♦ Analisar a computação bioinspirada e a sua relevância para o desenvolvimento de sistemas inteligentes
- ♦ Analisar as estratégias de Inteligência Artificial atuais em vários domínios, identificando oportunidades e desafios
- ♦ Compreender os princípios éticos fundamentais relacionados com a aplicação da IA em contextos educativos
- ♦ Analisar o atual quadro legislativo e os desafios associados à implementação da IA no contexto educativo
- ♦ Promover o design e a utilização responsável de soluções de IA em contextos educativos, tendo em conta a diversidade cultural e a equidade de género
- ♦ Proporcionar uma compreensão aprofundada dos fundamentos teóricos da IA, incluindo a aprendizagem automática, as redes neurais e o processamento de linguagem natural
- ♦ Compreender as aplicações e o impacto da IA no ensino e na aprendizagem, avaliando de forma crítica as suas utilizações atuais e potenciais





Objetivos específicos

Módulo 1. Fundamentos da Inteligência Artificial

- Analisar a evolução histórica da Inteligência Artificial, desde o seu início até ao seu estado atual, identificando os principais marcos e desenvolvimentos
- Compreender o funcionamento das redes neuronais e a sua aplicação em modelos de aprendizagem em Inteligência Artificial
- Estudar os princípios e aplicações dos algoritmos genéticos, analisando a sua utilidade na resolução de problemas complexos
- Analisar a importância dos thesauri, vocabulários e taxonomias na estruturação e processamento de dados para sistemas de IA
- Explorar o conceito de web semântica e a sua influência na organização e compreensão da informação em ambientes digitais

Módulo 2. Tipos e ciclo de vida do dado

- Compreender os conceitos fundamentais da estatística e a sua aplicação na análise de dados
- Identificar e classificar os diferentes tipos de dados estatísticos, desde os quantitativos aos qualitativos
- Analisar o ciclo de vida dos dados, desde a sua geração até à sua eliminação, identificando as principais etapas
- Explorar as fases iniciais do ciclo de vida dos dados, destacando a importância do planeamento e da estrutura dos dados
- Estudar os processos de recolha de dados, incluindo a metodologia, as ferramentas e os canais de recolha
- Explorar o conceito de *Datawarehouse* (Armazenamento de Dados), com ênfase nos seus elementos constituintes e no seu design
- Analisar os aspetos regulamentares relacionados com a gestão de dados, cumprindo as normas de privacidade e segurança, bem como as boas práticas

Módulo 3. O dado na Inteligência Artificial

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

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

- Dominar técnicas de inferência estatística para compreender e aplicar métodos estatísticos na mineração de dados
- Realizar análises exploratórias pormenorizadas de conjuntos de dados para identificar padrões, anomalias e tendências relevantes
- Desenvolver competências para a preparação de dados, incluindo a sua limpeza, integração e formatação para utilização na mineração de dados
- Implementar estratégias eficazes para tratar valores em falta em conjuntos de dados, aplicando métodos de imputação ou eliminação sensíveis ao contexto
- Identificar e atenuar o ruído nos dados, utilizando 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 na Inteligência Artificial

- ♦ Introduzir estratégias de concepção de algoritmos, proporcionando uma compreensão sólida das abordagens fundamentais para a resolução 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 ordenação, compreendendo o seu desempenho e comparando a sua eficiência em diferentes contextos
- ♦ Explorar algoritmos baseados em árvores, compreendendo a sua estrutura e aplicações
- ♦ Investigar algoritmos com *Heaps*, analisando a sua implementação e utilidade na manipulação eficiente de dados
- ♦ Analisar algoritmos baseados em grafos, explorando a sua aplicação na representação e resolução de problemas que envolvam relações complexas
- ♦ Estudar algoritmos *Greedy*, compreendendo a sua lógica e aplicações na resolução de problemas de otimização
- ♦ Investigar e aplicar a técnica de *backtracking* na resolução sistemática de problemas, analisando a sua eficácia numa variedade de cenários

Módulo 6. Sistemas inteligentes

- ♦ Explorar a teoria dos agentes, compreendendo os conceitos fundamentais do seu funcionamento e a sua aplicação na Inteligência Artificial e na engenharia de Software
- ♦ Estudar a representação do conhecimento, incluindo a análise de ontologias e a sua aplicação na organização de informação estruturada
- ♦ Analisar o conceito de web semântica e o seu impacto na organização e recuperação de informação em ambientes digitais

- ♦ Avaliar e comparar diferentes representações do conhecimento, integrando-as para melhorar a eficiência e a precisão dos sistemas inteligentes
- ♦ Estudar raciocinadores semânticos, sistemas baseados no conhecimento e sistemas periciais, compreendendo a sua funcionalidade e aplicações na tomada de decisões inteligentes

Módulo 7. Aprendizagem automática e mineração de dados

- ♦ Introduzir processos de descoberta de conhecimentos e os conceitos fundamentais da aprendizagem automática
- ♦ Estudar árvores de decisão como modelos de aprendizagem supervisionada, compreendendo a sua estrutura e aplicações
- ♦ Avaliar classificadores utilizando técnicas específicas para medir o seu desempenho e exatidão na classificação de dados
- ♦ Estudar as redes neuronais, compreendendo o seu funcionamento e arquitetura para resolver problemas complexos de aprendizagem automática
- ♦ Explorar os métodos bayesianos e a sua aplicação na aprendizagem automática, 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 extração de texto e o processamento de linguagem natural (PLN), compreendendo como as técnicas de aprendizagem automática são aplicadas para analisar e compreender texto

Módulo 8. As redes neurais, a base da *Deep Learning*

- ♦ Dominar os fundamentos da Aprendizagem Profunda, compreendendo o seu papel essencial na *Deep Learning*
- ♦ Explorar as operações fundamentais nas redes neurais e compreender a sua aplicação na construção de modelos
- ♦ Analisar as diferentes camadas utilizadas nas redes neurais e aprender a seleccioná-las adequadamente
- ♦ Compreender a ligação eficaz de camadas e operações para conceber arquiteturas de redes neurais complexas e eficientes
- ♦ Utilizar treinadores e otimizadores para ajustar e melhorar o desempenho das redes neurais
- ♦ Explorar a ligação entre neurónios biológicos e artificiais para uma compreensão mais profunda da conceção de modelos
- ♦ Afinar hiperparâmetros para o *Fine Tuning* de redes neurais, melhorando o seu desempenho em tarefas específicas

Módulo 9. Treino de redes neurais profundas

- ♦ Resolver problemas relacionados com gradientes na formação 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 abordar o sobreajuste através de estratégias específicas durante o treino

- ♦ Aplicar diretrizes práticas para garantir o treino eficiente e eficaz de redes neurais profundas
- ♦ Implementar a *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 aplicações práticas utilizando a *Transfer Learning* para resolver problemas do mundo real
- ♦ Compreender e aplicar técnicas de regularização para melhorar a generalização e evitar o sobreajuste em redes neurais profundas

Módulo 10. Personalização de modelos e treino com *TensorFlow*

- ♦ Dominar os fundamentos de *TensorFlow* e a sua integração com o NumPy para um tratamento de dados e cálculos eficientes
- ♦ Personalizar modelos e algoritmos de formação utilizando as capacidades avançadas do *TensorFlow*
- ♦ Explorar a API *tf.data* para gerir e manipular eficientemente conjuntos de dados
- ♦ Implementar o formato *TFRecord* para armazenar e aceder a 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 aceder a conjuntos de dados predefinidos e melhorar a eficiência no desenvolvimento
- ♦ Desenvolver uma aplicação de *Deep Learning* com *TensorFlow*, integrando os conhecimentos adquiridos no módulo
- ♦ Aplicar de forma prática todos os conceitos aprendidos na construção e treino de modelos personalizados com *TensorFlow* em situações do mundo real

Módulo 11. Deep Computer Vision com Redes Neurais Convolucionais

- ♦ Compreender a arquitetura do córtex visual e a sua relevância para a *Deep Computer Vision*
- ♦ Explorar e aplicar camadas convolucionais para extrair características chave de imagens
- ♦ Implementar camadas de agrupamento e sua utilização em modelos de *Deep Computer Vision* com o Keras
- ♦ Analisar várias arquiteturas de Redes Neurais Convolucionais (CNN) e a sua aplicabilidade em diferentes contextos
- ♦ Desenvolver e implementar uma CNN ResNet utilizando a biblioteca Keras para melhorar a eficiência e o desempenho do modelo
- ♦ Utilizar modelos Keras pré-treinados para tirar partido da aprendizagem por transferência para tarefas específicas
- ♦ Aplicar técnicas de classificação e localização em ambientes de *Deep Computer Vision*
- ♦ Explorar estratégias de detecção e seguimento de objetos utilizando Redes Neurais Convolucionais
- ♦ Implementar técnicas de segmentação semântica para compreender e classificar objetos em imagens de forma detalhada

Módulo 12. Processamento de linguagem natural (PLN) com Redes Neurais Recorrentes (RNN) e Atenção

- ♦ Desenvolver competências na geração de textos utilizando 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 PNL
- ♦ Explorando a aplicação de modelos *Transformers* no contexto do processamento de imagens e da visão computacional
- ♦ Familiarizar-se com a biblioteca *Transformers* de *Hugging Face* para a implementação eficiente de modelos avançados
- ♦ Comparar diferentes bibliotecas de *Transformers* para avaliar a sua adequação a tarefas específicas
- ♦ Desenvolver uma aplicação prática 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 de dados eficientes utilizando *Autoencoders*, *GANs* e Modelos de Difusão
- ♦ Realizar PCA utilizando um codificador automático linear incompleto para otimizar a representação dos dados
- ♦ Implementar e compreender o funcionamento de codificadores automáticos empilhados
- ♦ Explorar e aplicar codificadores automáticos convolucionais para representações visuais eficientes de dados
- ♦ Analisar e aplicar a eficácia dos codificadores automáticos esparsos na representação de dados
- ♦ Gerar imagens de moda a partir do conjunto de dados MNIST utilizando *Autoencoders*
- ♦ Compreender o conceito de Redes Generativas Antagônicas (*GANs*) e Modelos de Difusão
- ♦ Implementar e comparar o desempenho de modelos de difusão e *GANs* na geração de dados

Módulo 14. Computação bioinspirada

- ♦ Introduzir os conceitos fundamentais da computação bioinspirada
- ♦ Explorar os algoritmos de adaptação social como uma abordagem fundamental na computação bioinspirada
- ♦ Analisar estratégias de exploração do espaço em algoritmos genéticos
- ♦ Examinar modelos de computação evolutiva no contexto da otimização
- ♦ Continuar a análise pormenorizada de modelos de computação evolutiva
- ♦ Aplicar a programação evolutiva a problemas de aprendizagem específicos
- ♦ Abordar a complexidade de problemas multi-objetivo no âmbito da computação bioinspirada
- ♦ Explorar a aplicação de redes neuronais no domínio da computação bioinspirada
- ♦ Aprofundar a implementação e a utilidade das redes neuronais na computação bioinspirada

Módulo 15. Inteligência Artificial Estratégias e aplicações

- ♦ Desenvolver estratégias para a implementação da inteligência artificial nos serviços financeiros
- ♦ Analisar as implicações da inteligência artificial na prestação de serviços de saúde
- ♦ Identificar e avaliar os riscos associados à utilização da inteligência artificial no setor da saúde
- ♦ Avaliar os riscos potenciais associados à utilização da IA na indústria
- ♦ Aplicar técnicas de inteligência artificial na indústria para melhorar a produtividade
- ♦ Conceber soluções de inteligência artificial para otimizar os processos na administração pública
- ♦ Avaliar a aplicação de tecnologias de IA no setor da educação
- ♦ Aplicar técnicas de inteligência artificial na silvicultura e na agricultura para melhorar a produtividade

- ♦ Melhorar os processos de recursos humanos através da utilização estratégica da inteligência artificial

Módulo 16. Análise de dados e aplicação de técnicas de IA para a personalização do ensino

- ♦ Aplicar a IA na análise e avaliação de dados educativos para promover a melhoria contínua em contextos educativos
- ♦ Definir indicadores de desempenho baseados em dados educativos para medir e melhorar o desempenho dos alunos
- ♦ Implementar tecnologias e algoritmos de IA para realizar análises preditivas dos dados de desempenho académico
- ♦ Realizar diagnósticos personalizados de dificuldades de aprendizagem através da análise de dados de IA, identificando necessidades educativas particulares e designando intervenções específicas
- ♦ Abordar a segurança e a privacidade no tratamento de dados educativos aquando da aplicação de ferramentas de IA, garantindo a conformidade regulamentar e ética

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

- ♦ Planear e designar projetos educativos que integrem eficazmente a IA em ambientes educativos, dominar ferramentas específicas para o seu desenvolvimento
- ♦ Designar 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 a aprendizagem automática para melhorar a experiência de aprendizagem, integrando a IA no Design de jogos educativos na aprendizagem lúdica

- ♦ Criar *chatbots* educativos que ajudem os estudantes nos seus processos de aprendizagem e de resolução de problemas, incluindo agentes inteligentes em plataformas educativas para melhorar a interação e o ensino
- ♦ Efetuar uma análise contínua dos projetos de IA na educação para identificar áreas de melhoria e otimização

Módulo 18. Prática pedagógica com Inteligência Artificial generativa

- ♦ Dominar as tecnologias de IA generativa para a sua aplicação e utilização eficientes em contextos educativos, planeando actividades educativas eficazes
- ♦ Criar materiais didáticos utilizando a IA generativa para melhorar a qualidade e a variedade dos recursos de aprendizagem, bem como para medir o progresso dos alunos de formas inovadoras
- ♦ Utilizar a IA generativa para corrigir atividades e testes de avaliação, racionalizando e otimizando este processo
- ♦ Integrar ferramentas generativas de IA em estratégias pedagógicas para melhorar a eficácia do processo educativo e conceber ambientes de aprendizagem inclusivos, no âmbito da abordagem do design universal
- ♦ Avaliar a eficácia da IA generativa na educação, analisando o seu impacto nos processos de ensino e aprendizagem

Módulo 19. Inovações e tendências emergentes na IA para a Educação

- ♦ Dominar as ferramentas e tecnologias emergentes de IA aplicadas à educação para a sua utilização efetiva em ambientes de aprendizagem
- ♦ Integrar a Realidade Aumentada e Virtual na Educação para enriquecer e melhorar a experiência de aprendizagem
- ♦ Aplicar a IA de conversação para facilitar o apoio educativo e promover a aprendizagem interativa entre os estudantes

- ♦ Implementar tecnologias de reconhecimento facial e emocional para monitorizar a participação e o bem-estar dos alunos na sala de aula
- ♦ Explorar a integração de *Blockchain* e a IA na educação para transformar a administração da educação e validar certificações

Módulo 20. Ética e Legislação da Inteligência Artificial na Educação

- ♦ Identificar e aplicar práticas éticas no tratamento de dados sensíveis no contexto educativo, dando prioridade à responsabilidade e ao respeito.
- ♦ Analisar o impacto social e cultural da IA na educação, avaliando a sua influência nas comunidades educativas
- ♦ Compreender a legislação e as políticas relacionadas com a utilização de dados em contextos educativos que envolvam IA
- ♦ Definir a interseção entre IA, diversidade cultural e equidade de género no contexto educativo
- ♦ Avaliar o impacto da IA na acessibilidade educativa, garantindo a equidade no acesso ao conhecimento



Este Mestrado Próprio combina aspetos técnicos da Inteligência Artificial com um enfoque prático no desenvolvimento de projetos educativos"

03

Competências

Este curso permitirá que os alunos obtenham uma vantagem competitiva que os distinguirá dos demais. Desta forma, dominarão aspectos como a ética, a legislação e o desenvolvimento prático de projetos de IA especificamente designados para o campo da educação. Além disso, os profissionais adquirem competências práticas para aplicar nos seus projetos, o que enriquece muito a experiência dos alunos na sala de aula. Através deste Mestrado Próprio, os especialistas serão capazes de ultrapassar os desafios que surgem durante o exercício da sua profissão.



“


*Irá entrar num campo em constante evolução,
onde a inovação da Inteligência Artificial se
funde com a aprendizagem na educação"*



Competências gerais

- Dominar as técnicas de mineração de dados, incluindo a seleção, o pré-processamento e a transformação de dados complexos
- Conceber e desenvolver sistemas inteligentes capazes de aprender e de se adaptar a ambientes em mudança
- Controlar as ferramentas de aprendizagem automática e a sua aplicação na mineração de dados para a tomada de decisões
- Utilizar *Autoencoders*, *GANs* e Modelos de Difusão para resolver desafios específicos em Inteligência Artificial
- Implementar uma rede codificadora-descodificadora para tradução automática neuronal
- Aplicar os princípios fundamentais das redes neurais na resolução de problemas específicos
- Utilizar ferramentas, plataformas e técnicas de IA, abordando desde a análise de dados até à aplicação de redes neurais e modelação preditiva
- Desenvolver competências críticas para avaliar o impacto ético e social da IA na educação
- Formar para o design e implementação de projetos de IA no domínio da educação
- Desenvolver competências para integrar projetos de IA de forma eficaz e ética no currículo educativo





Competências específicas

- Aplicar técnicas e estratégias de IA para melhorar a eficiência no setor do *retalho*
- Aprofundar a compreensão e a aplicação dos algoritmos genéticos.
- Implementar técnicas de redução de ruído utilizando codificadores automáticos
- Criar eficazmente conjuntos de dados de treino para tarefas de processamento de linguagem natural (PLN)
- Executar camadas de agrupamento e a sua utilização em modelos de *Deep Computer Vision* com o Keras
- Utilizar funções e gráficos *TensorFlow* para otimizar o desempenho de modelos personalizados
- Melhorar o desenvolvimento e a aplicação de *chatbots* e assistentes virtuais, compreendendo o seu funcionamento e potenciais aplicações
- Dominar a reutilização de camadas pré-treinadas para otimizar e acelerar o processo de treino
- Construir a primeira rede neural, aplicando na prática os conceitos aprendidos
- Ativar o Perceptron Multicamadas (MLP) usando a biblioteca Keras
- Aplicar técnicas de exploração e pré-processamento de dados, identificando e preparando os dados para uma utilização efectiva em modelos de aprendizagem automática
- Implementar estratégias eficazes para tratar valores em falta em conjuntos de dados, aplicando métodos de imputação ou eliminação sensíveis ao contexto
- Investigar linguagens e software para a criação de ontologias, utilizando ferramentas específicas para o desenvolvimento de modelos semânticos
- Desenvolver técnicas de limpeza de dados para garantir a qualidade e a exatidão da informação utilizada nas análises posteriores
- Desenvolver competências críticas para avaliar o impacto ético e social da IA na educação
- Designar e implementar projetos de IA em contextos educativos
- Aplicar a IA generativa no contexto educativo
- Criar materiais didáticos personalizados e adaptativos
- Utilizar a IA para melhorar a avaliação e a retroalimentação educativa
- Integrar eficazmente as tecnologias emergentes de IA no currículo educativo



Desenhará e implementará estratégias educativas altamente inovadoras, através da integração da Inteligência Artificial"

04

Direção do curso

A fim de proporcionar uma formação baseada na excelência, a TECH dispõe de um programa de estudos exclusivo criado por especialistas do setor educativo. Estes profissionais têm uma vasta experiência na IA aplicada a Educação, tendo trabalhado para empresas de prestígio neste domínio. Por este motivo, o percurso académico privilegia os conteúdos com os desenvolvimentos mais recentes neste domínio. Assim, os alunos licenciados têm as garantias necessárias para se especializarem, onde aumentarão os seus conhecimentos com o apoio dos melhores professores.



“

A diversidade de talentos e conhecimentos do pessoal docente criará um ambiente de aprendizagem dinâmico. Forme-se com os melhores!”

Direção



Doutor Arturo Peralta Martín-Palomino

- CEO e CTO, Prometeus Global Solutions
- CTO em Korporate Technologies
- CTO em AI Shephers GmbH
- Consultor e Assessor Empresarial Estratégico na Alliance Medical
- Diretor de Design e Desenvolvimento na DocPath
- Doutorado em Engenharia Informática pela Universidade de Castilla-La Mancha
- Doutorado em Economia, Empresas 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 pela Formação Hadoop
- Mestrado em Tecnologias Avançadas de Informação da Universidade de Castilla - la Mancha
- Membro de: Grupo de Investigação SMILE



D. Juan Felipe Nájera Puente

- ♦ Diretor de Estudos e Investigação no Conselho de Garantia da Qualidade do Ensino Superior
- ♦ Analista de dados e Científico de dados
- ♦ Programador de Produção na Confiteca C.A.
- ♦ Consultor de Processos na Esefex Consulting
- ♦ Analista de Planeamento Académico 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 de Formações Técnicas na Securitas Seguridad Espanha
- ♦ Especialista em Educação, Negócios e Marketing
- ♦ *Product Manager* de Segurança Eletrónica na Securitas Seguridad Espanha
- ♦ Analista de inteligência Empresarial na Ricopia Technologies
- ♦ Técnico de informática e responsável pelas aulas de informática da OTEC na Universidade de Alcalá de Henares
- ♦ Colaboradora na Associação ASALUMA
- ♦ Licenciado em Engenharia Electrónica de Comunicações na Escola Politécnica Superior na Universidade de Alcalá de Henares

05

Estrutura e conteúdo

Composto por 20 módulos, esta certificação distingue-se pela sua abordagem integral e especializada. A programação vai para além dos aspetos técnicos da IA na educação, aprofundando as considerações éticas, jurídicas e sociais associadas. Ao mesmo tempo, o programa de estudos fornecerá aos estudantes ferramentas tecnológicas de ponta, para que o seu trabalho como professores integre inovações como a Realidade Aumentada ou a Análise Preditiva. A certificação destacará também a atenção dada à personalização da aprendizagem e à melhoria contínua, aspectos fundamentais para a adaptabilidade no processo educativo.



“

Inclui casos clínicos visando aproximar ao máximo o desenvolvimento da especialização da realidade dos cuidados docente”

Módulo 1. Fundamentos da Inteligência Artificial

- 1.1. História da Inteligência Artificial
 - 1.1.1. Quando se começa a falar de inteligência artificial?
 - 1.1.2. Referências no cinema
 - 1.1.3. Importância da inteligência artificial
 - 1.1.4. Tecnologias que viabilizam e apoiam a 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 neurais
 - 1.3.1. Fundamentos teológicos
 - 1.3.2. Modelo computacional
 - 1.3.3. Redes neurais supervisionadas e não supervisionadas
 - 1.3.4. Perceptron simples
 - 1.3.5. Perceptron multicamadas
- 1.4. Algoritmos genéticos
 - 1.4.1. História
 - 1.4.2. Base biológica
 - 1.4.3. Codificação de problemas
 - 1.4.4. Criação da população inicial
 - 1.4.5. Algoritmo principal e operadores genéticos
 - 1.4.6. Avaliação dos indivíduos: Fitness
- 1.5. Tesouros, vocabulários, taxonomias
 - 1.5.1. Vocabulários
 - 1.5.2. Taxonomias
 - 1.5.3. Tesauro
 - 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/razoabilidade
 - 1.6.3. *Linked Data*

- 1.7. Sistemas periciais e DSS
 - 1.7.1. Sistemas periciais
 - 1.7.2. Sistema de apoio à decisão
- 1.8. *Chatbots* e assistentes virtuais
 - 1.8.1. Tipos de assistentes: Assistentes por voz e por 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 dos assistentes: Dialog Flow, Watson Assistant
- 1.9. Estratégia de implementação de IA
- 1.10. Futuro da inteligência artificial
 - 1.10.1. Compreendemos como detetar as 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. Reflexão

Módulo 2. Tipos e ciclo de vida do dado

- 2.1. A estatística
 - 2.1.1. Estatística Estatística descritiva, inferências estatísticas
 - 2.1.2. População, amostra indivíduo
 - 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. Qualitativos: Dados binominais, dados nominais, dados ordinais
 - 2.2.2. De acordo com a sua forma
 - 2.2.2.1. Numérico
 - 2.2.2.2. Texto
 - 2.2.2.3. Lógico
 - 2.2.3. De acordo com a sua 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 metas
 - 2.4.2. Determinação de recursos necessários
 - 2.4.3. Diagrama de Gantt
 - 2.4.4. Estrutura de dados
- 2.5. Recolha de dados
 - 2.5.1. Metodologia de recolha
 - 2.5.2. Ferramentas de recolha
 - 2.5.3. Canais de recolha
- 2.6. Limpeza de dados
 - 2.6.1. Fases de 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. Indicadores de relação
 - 2.7.3. Extração de dados
- 2.8. Armazém de dados (*Datawarehouse*)
 - 2.8.1. Elementos incluídos
 - 2.8.2. Design
 - 2.8.3. Aspetos a considerar
- 2.9. Disponibilidade dos dados
 - 2.9.1. Acesso
 - 2.9.2. Utilidade
 - 2.9.3. Segurança
- 2.10. Aspetos regulamentares
 - 2.10.1. Lei da Proteção de Dados
 - 2.10.2. Boas práticas
 - 2.10.3. Outros aspetos regulamentares

Módulo 3. O dado na Inteligência Artificial

- 3.1. Ciência de dados
 - 3.1.1. A ciência de dados
 - 3.1.2. Ferramentas avançadas para o cientista de dados
- 3.2. Dados, informação e conhecimento
 - 3.2.1. Dados, informação e conhecimento
 - 3.2.2. Tipos de dados
 - 3.2.3. Fontes de dados
- 3.3. Dos dados à informação
 - 3.3.1. Análise de Dados
 - 3.3.2. Tipos de análise
 - 3.3.3. Extração de informação de um *Dataset*
- 3.4. Extração de informação 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 do 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 boas práticas
 - 3.10.1. Boas práticas 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. A inferência estatística
 - 4.1.1. Estatística descritiva vs. Inferência estatística
 - 4.1.2. Procedimentos paramétricos
 - 4.1.3. Procedimentos não paramétricos
- 4.2. Análise exploratória
 - 4.2.1. Análise descritiva
 - 4.2.2. Visualização
 - 4.2.3. Preparação de dados
- 4.3. Preparação de 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 automática
- 4.5. O ruído dos dados
 - 4.5.1. Classes de ruído e atributos
 - 4.5.2. Filtragem de ruído
 - 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 dados discretos
 - 4.7.2. Processo de discretização
- 4.8. Os dados
 - 4.8.1. Seleção de dados
 - 4.8.2. Perspetivas e critérios de seleção
 - 4.8.3. Métodos de seleção
- 4.9. Seleção de instâncias
 - 4.9.1. Métodos para a seleção de instâncias
 - 4.9.2. Seleção de protótipos
 - 4.9.3. Métodos avançados para a seleção de instâncias
- 4.10. Pré-processamento de dados em ambientes *Big Data*

Módulo 5. Algoritmo e complexidade na Inteligência Artificial

- 5.1. Introdução às estratégias de desenho do algoritmos
 - 5.1.1. Recursividade
 - 5.1.2. Divide e conquista
 - 5.1.3. Outras estratégias
- 5.2. Eficiência e análise dos algoritmos
 - 5.2.1. Medidas de eficiência
 - 5.2.2. Medir o tamanho da entrada
 - 5.2.3. Medir o tempo de execução
 - 5.2.4. Caso pior, melhor e médio
 - 5.2.5. Notação assintótica
 - 5.2.6. Critérios de análise matemática de 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 da bolha
 - 5.3.3. Ordenação por seleção
 - 5.3.4. Ordenação por inserção
 - 5.3.5. Ordenação por mistura (*Merge_Sort*)
 - 5.3.6. Ordenação rápida (*Quicksort*)

- 5.4. Algoritmos com árvores
 - 5.4.1. Conceito de árvore
 - 5.4.2. Árvores binários
 - 5.4.3. Caminhos de árvore
 - 5.4.4. Representar expressões
 - 5.4.5. Árvores binários ordenadas
 - 5.4.6. Árvores binárias equilibradas
- 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 de largura
 - 5.6.3. Caminho de 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. Câmbio de moedas
 - 5.7.4. Problema do viajante
 - 5.7.5. Problema da mochila
- 5.8. Pesquisa de caminhos mínimos
 - 5.8.1. O problema do caminho mínimo
 - 5.8.2. Arcos negativos e ciclos
 - 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
 - 5.9.3. O algoritmo 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 dos agentes
 - 6.1.1. História do conceito
 - 6.1.2. Definição de agente
 - 6.1.3. Agentes na Inteligência Artificial
 - 6.1.4. Agentes em Engenharia de Software
- 6.2. Arquiteturas de agentes
 - 6.2.1. O processo de argumentação de um agente
 - 6.2.2. Agentes reativos
 - 6.2.3. Agentes dedutivos
 - 6.2.4. Agentes híbridos
 - 6.2.5. Comparativo
- 6.3. Informação e conhecimento
 - 6.3.1. Distinção entre dados, informação e conhecimento
 - 6.3.2. Avaliação qualidade dos dados
 - 6.3.3. Métodos de recolha de dados
 - 6.3.4. Métodos de aquisição de dados
 - 6.3.5. Métodos de aquisição de conhecimento
- 6.4. Representação do conhecimento
 - 6.4.1. A importância da representação do conhecimento
 - 6.4.2. Definição da representação do conhecimento através das 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 a criação de ontologias
 - 6.6.1. Triples RDF, *Turtle* e N
 - 6.6.2. RDF *Schema*
 - 6.6.3. OWL

- 6.6.4. SPARQL
- 6.6.5. Introdução às diferentes ferramentas de criação de ontologias
- 6.6.6. Instalação e utilização do *Protégé*
- 6.7. A web semântica
 - 6.7.1. O estado atual e futuro da web semântica
 - 6.7.2. Aplicações da web semântica
- 6.8. Outros modelos representação do conhecimento
 - 6.8.1. Vocabulários
 - 6.8.2. Visão global
 - 6.8.3. Taxonomias
 - 6.8.4. Tesaurus
 - 6.8.5. Folksonomias
 - 6.8.6. Comparativo
 - 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 na lógica de primeira ordem
- 6.10. Raciocinadores semânticos, sistemas baseados no conhecimento e Sistemas Periciais
 - 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 Periciais
 - 6.10.5. Elementos e Arquitetura dos Sistemas Periciais
 - 6.10.6. Criação de Sistemas Periciais

Módulo 7. Aprendizagem automática e mineração de dados

- 7.1. Introdução aos processos de descoberta de conhecimentos e aos conceitos básicos da aprendizagem automática
 - 7.1.1. Conceitos-chave dos processos de descoberta do conhecimento
 - 7.1.2. Perspetiva histórica dos processos de descoberta do conhecimento
 - 7.1.3. Etapas 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 aprendizagem automática
 - 7.1.6. Tipos de informação sobre aprendizagem automática
 - 7.1.7. Conceitos básicos de aprendizagem
 - 7.1.8. Conceitos básicos de aprendizagem não supervisionado
- 7.2. Exploração e pré-processamento de dados
 - 7.2.1. Tratamento de dados
 - 7.2.2. Tratamento de dados no fluxo de análise de dados
 - 7.2.3. Tipos de dados
 - 7.2.4. Transformação 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 à redução da dimensionalidade
- 7.3. Árvore de decisão
 - 7.3.1. Algoritmo ID
 - 7.3.2. Algoritmo C
 - 7.3.3. Excesso de treino e poda
 - 7.3.4. Análise dos resultados
- 7.4. Avaliação dos classificadores
 - 7.4.1. Matrizes de confusão
 - 7.4.2. Matrizes de avaliação numérica
 - 7.4.3. Estatística Kappa
 - 7.4.4. A curva ROC

- 7.5. Regras de classificação
 - 7.5.1. Medidas de avaliação das 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 neuronais simples
 - 7.6.3. Algoritmo de *Backpropagation*
 - 7.6.4. Introdução às redes neuronais 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 modelos 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 suporte vetorial (SVM)
 - 7.8.6. Medidas de adequação
- 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 linguagem natural (PLN)
 - 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. As redes neuronais, a base da *Deep Learning*

- 8.1. Aprendizagem profunda
 - 8.1.1. Tipos de aprendizagem profunda
 - 8.1.2. Aplicações da aprendizagem profunda
 - 8.1.3. Vantagens e desvantagens da aprendizagem profunda
- 8.2. Operações
 - 8.2.1. Adição
 - 8.2.2. Produto
 - 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. Ligação de Camadas e Operações
 - 8.4.1. Design de arquiteturas
 - 8.4.2. Conexão entre camadas
 - 8.4.3. Propagação para a frente
- 8.5. Construção da primeira rede neuronal
 - 8.5.1. Design da rede
 - 8.5.2. Estabelecer os pesos
 - 8.5.3. Treino da rede
- 8.6. Treinador e Otimizador
 - 8.6.1. Seleção do otimizador
 - 8.6.2. Estabelecimento de uma função de perda
 - 8.6.3. Estabelecimento de uma métrica
- 8.7. Aplicação dos Princípios das Redes Neuronais
 - 8.7.1. Funções de ativação
 - 8.7.2. Propagação para trás
 - 8.7.3. Ajuste dos parâmetros

- 8.8. Dos neurónios biológicos aos neurónios artificiais
 - 8.8.1. Funcionamento de um neurónio biológico
 - 8.8.2. Transferência de conhecimentos para os neurónios artificiais
 - 8.8.3. Estabelecer de relações entre os dois
- 8.9. Implementação do MLP (Perceptron Multicamadas) com o Keras
 - 8.9.1. Definição da estrutura da rede
 - 8.9.2. Compilação do modelo
 - 8.9.3. Treino do modelo
- 8.10. Hiperparâmetros de *Fine tuning* de Redes Neurais
 - 8.10.1. Seleção da função de ativação
 - 8.10.2. Estabelecer a *Learning rate*
 - 8.10.3. Ajuste dos pesos

Módulo 9. Treino de redes neuronais 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. Treino de transferência de aprendizagem
 - 9.2.2. Extração de características
 - 9.2.3. Aprendizagem profunda
- 9.3. Otimizadores
 - 9.3.1. Otimizadores estocásticos de gradiente descendente
 - 9.3.2. Otimizadores Adam e *RMSprop*
 - 9.3.3. Otimizadores de momento
- 9.4. Programação da taxa de aprendizagem
 - 9.4.1. Controlo de taxa sobre 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. Orientações práticas
 - 9.6.1. Design do modelo
 - 9.6.2. Seleção de métricas e parâmetros de avaliação
 - 9.6.3. Teste de hipóteses
- 9.7. *Transfer Learning*
 - 9.7.1. Treino de transferência de aprendizagem
 - 9.7.2. Extração de características
 - 9.7.3. Aprendizagem profunda
- 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. Treino de transferência de aprendizagem
 - 9.9.2. Extração de características
 - 9.9.3. Aprendizagem profunda
- 9.10. Regularização
 - 9.10.1. L e L
 - 9.10.2. Regularização por entropia máxima
 - 9.10.3. *Dropout*

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

- 10.1. *TensorFlow*
 - 10.1.1. Uso da biblioteca *TensorFlow*
 - 10.1.2. Treino de modelos com o *TensorFlow*
 - 10.1.3. Operações de gráfico no *TensorFlow*
- 10.2. *TensorFlow* e NumPy
 - 10.2.1. Ambiente computacional NumPy para *TensorFlow*
 - 10.2.2. Utilização das arrays NumPy com o *TensorFlow*
 - 10.2.3. Operações NumPy para o *TensorFlow* gráficos do *TensorFlow*
- 10.3. Personalização de modelos e algoritmos de treino
 - 10.3.1. Construir modelos personalizados com o *TensorFlow*
 - 10.3.2. Gestão dos parâmetros de treino
 - 10.3.3. Utilização de técnicas de otimização para o treino

- 10.4. Funções e gráficos do *TensorFlow*
 - 10.4.1. Funções com o *TensorFlow*
 - 10.4.2. Utilização de gráficos para treino de modelos
 - 10.4.3. Otimização de gráficos com operações do *TensorFlow*
- 10.5. Carga de conjuntos de dados com o *TensorFlow*
 - 10.5.1. Carga de conjuntos de dados com o *TensorFlow*
 - 10.5.2. Pré-processamento de dados com o *TensorFlow*
 - 10.5.3. Utilizar de ferramentas do *TensorFlow* para a manipulação de dados
- 10.6. A API *tfdata*
 - 10.6.1. Utilização da API *tfdata* para o processamento de dados
 - 10.6.2. Construção de fluxo de dados com *tfdata*
 - 10.6.3. Utilização da API *tfdata* para o treino de modelos
- 10.7. O formato *TFRecord*
 - 10.7.1. Utilização da API *TFRecord* para a serialização de dados
 - 10.7.2. Carregar arquivos *TFRecord* com *TensorFlow*
 - 10.7.3. Utilização de arquivos *TFRecord* para o treino 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 o Keras
 - 10.8.3. Utilização da API de pré-processamento do Keras para o treino de modelos
- 10.9. O projeto *TensorFlow Datasets*
 - 10.9.1. Utilização de *TensorFlow Datasets* para o carregamento de dados
 - 10.9.2. Pré-processamento de dados com o *TensorFlow Datasets*
 - 10.9.3. Utilização de *TensorFlow Datasets* para o treino 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. Treino de um modelo com o *TensorFlow*
 - 10.10.4. Utilizar a aplicação para previsão de resultados

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

- 11.1. A Arquitetura *Visual Cortex*
 - 11.1.1. Funções do córtex visual
 - 11.1.2. Teoria 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
 - 11.3.1. *Pooling* e *Striding*
 - 11.3.2. *Flattening*
 - 11.3.3. Tipos de *Pooling*
- 11.4. Arquitetura 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. Utilização 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 a aprendizagem por transferência
 - 11.7.1. A 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 seguimento de objetos

11.9.1. Métodos de detecção de objetos

11.9.2. Algoritmos de seguimento de objetos

11.9.3. Técnicas de seguimento e localização

11.10. Segmentação semântica

11.10.1. Aprendizagem profunda para a segmentação semântica

11.10.2. Detecção de bordas

11.10.3. Métodos de segmentação baseado sem regras

Módulo 12. Processamento de linguagem natural (PLN) com Redes Neurais Recorrentes (RNN) e Atenção

12.1. Geração de texto utilizando RNN

12.1.1. Treino 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 de conjuntos de dados de treino

12.2.1. Preparação dos dados para o treino de uma RNN

12.2.2. Armazenamento do conjunto de dados de treino

12.2.3. Limpeza e transformação dos dados

12.2.4. Análise de Sentimento

12.3. Classificação da 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 codificadora-descodificadora para a tradução automática neural

12.4.1. Treino de uma RNN para a tradução automática

12.4.2. Utilização de uma rede *encoder-decoder* para a tradução automática

12.4.3. Melhoria da precisão da tradução automática com RNNs

12.5. Mecanismos de atenção

12.5.1. Implementação de mecanismos de atenção em RNN

12.5.2. Utilização de mecanismos de atenção para melhorar a precisão dos modelos

12.5.3. Vantagens dos mecanismos de atenção nas redes neurais

12.6. Modelos *Transformers*

12.6.1. Uso de modelos *Transformers* no processamento de linguagem natural

12.6.2. Aplicação de modelos *Transformers* na visão

12.6.3. Vantagens dos modelos *Transformers*

12.7. *Transformers* para a visão

12.7.1. Utilização de modelos *Transformers* para a visão

12.7.2. Pré-processamento de dados de imagem

12.7.3. Treino de modelos *Transformers* para visão

12.8. Biblioteca de *Transformers* de *Hugging Face*

12.8.1. Utilização da biblioteca *Transformers* de *Hugging Face*

12.8.2. Aplicação da biblioteca de *Transformers* de *Hugging Face*

12.8.3. Vantagens da biblioteca *Transformers* de *Hugging Face*

12.9. Outras Bibliotecas de *Transformers*. Comparativo

12.9.1. Comparação entre as diferentes bibliotecas de *Transformers*

12.9.2. Uso das outras bibliotecas de *Transformers*

12.9.3. Vantagens das outras bibliotecas de *Transformers*

12.10. Desenvolvimento de uma aplicação de PLN com RNN e Atenção. Aplicação prática

12.10.1. Desenvolvimento de uma aplicação de processamento de linguagem natural com RNN e atenção

12.10.2. Utilização de RNN, mecanismos de atenção e modelos *Transformers* na aplicação

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. Aprendizagem profunda
 - 13.1.3. Representações compactas
- 13.2. Realização da PCA com um codificador automático linear incompleto
 - 13.2.1. Processo de treino
 - 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. Utilização da regularização
- 13.4. Autoencodificadores convolucionais
 - 13.4.1. Design do modelo convolucionais
 - 13.4.2. Treino do modelo convolucionais
 - 13.4.3. Avaliação dos resultados
- 13.5. Redução do ruído dos codificadores automáticos
 - 13.5.1. Aplicação de filtros
 - 13.5.2. Design de modelos de codificação
 - 13.5.3. Utilização de técnicas de regularização
- 13.6. Codificadores automáticos dispersos
 - 13.6.1. Aumento da eficiência da codificação
 - 13.6.2. Minimizar o número de parâmetros
 - 13.6.3. Utilização de técnicas de regularização
- 13.7. Codificadores automáticos variacionais
 - 13.7.1. Utilização da 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. Treino de redes neurais profundas

- 13.9. Redes generativas antagónicas e modelos de difusão
 - 13.9.1. Geração de conteúdos a partir de imagens
 - 13.9.2. Modelação de distribuições de dados
 - 13.9.3. Utilização de redes contraditórias
- 13.10. Implementação dos Modelos
 - 13.10.1. Aplicação Prática
 - 13.10.2. Implementação dos modelos
 - 13.10.3. Utilização de dados reais
 - 13.10.4. Avaliação dos resultados

Módulo 14. Computação bioinspirada

- 14.1. Introdução à computação bioinspirada
 - 14.1.1. Introdução à computação bioinspirada
- 14.2. Algoritmos de inspiração social
 - 14.2.1. Computação bioinspirada baseada em colónias de formigas
 - 14.2.2. Variantes dos algoritmos de colónias 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
 - 14.5.1. Estratégias evolutivas
 - 14.5.2. Programação evolutiva
 - 14.5.3. Algoritmos baseados em evolução diferencial
- 14.6. Modelos de computação evolutiva (II)
 - 14.6.1. Modelos de evolução baseados na estimativa das distribuições (EDA)
 - 14.6.2. Programação genética
- 14.7. Programação evolutiva aplicada a problemas de aprendizagem
 - 14.7.1. A aprendizagem baseada em regras
 - 14.7.2. Métodos evolutivos em problemas de seleção de exemplos

- 14.8. Problemas multiobjetivo
 - 14.8.1. Conceito de dominância
 - 14.8.2. Aplicação de algoritmos evolutivos a problemas multiobjetivos
- 14.9. Redes neuronais (I)
 - 14.9.1. Introdução às redes neuronais
 - 14.9.2. Exemplo prático com redes neuronais
- 14.10. Redes neuronais (II)
 - 14.10.1. Casos de utilização de redes neuronais na investigação médica
 - 14.10.2. Casos de utilização de redes neuronais na economia
 - 14.10.3. Casos de utilização de redes neuronais na 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 utilização
 - 15.1.3. Potenciais riscos relacionados com a utilização 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 utilização
- 15.3. Riscos relacionados com a utilização de IA no serviço de saúde
 - 15.3.1. Potenciais riscos relacionados com a utilização de IA
 - 15.3.2. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.4. *Retail*
 - 15.4.1. Implicações da IA no *Retail* Oportunidades e desafios
 - 15.4.2. Casos de utilização
 - 15.4.3. Potenciais riscos relacionados com a utilização de IA
 - 15.4.4. Potenciais desenvolvimentos/utilizações futuras da IA

- 15.5. Indústrias
 - 15.5.1. Implicações da IA na Indústria. Oportunidades e desafios
 - 15.5.2. Casos de utilização
- 15.6. Potenciais riscos relacionados com a utilização de IA na Indústria
 - 15.6.1. Casos de utilização
 - 15.6.2. Potenciais riscos relacionados com a utilização 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 utilização
 - 15.7.3. Potenciais riscos relacionados com a utilização 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 utilização
 - 15.8.3. Potenciais riscos relacionados com a utilização de IA
 - 15.8.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.9. Silvicultura e agricultura
 - 15.9.1. Implicações da IA na Indústria 4.0 Oportunidades e desafios
 - 15.9.2. Casos de utilização
 - 15.9.3. Potenciais riscos relacionados com a utilização de IA
 - 15.9.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.10 recursos humanos
 - 15.10.1. Implicações da IA nos Recursos Humanos Oportunidades e desafios
 - 15.10.2. Casos de utilização
 - 15.10.3. Potenciais riscos relacionados com a utilização de IA
 - 15.10.4. Potenciais desenvolvimentos/utilizações futuras da IA

Módulo 16. Análise de dados e aplicação de técnicas de IA para a personalização do ensino

- 16.1. Identificação, extração e preparação de dados educativos
 - 16.1.1. Aplicação do H2O.ai nos métodos de recolha e seleção de dados relevantes em contextos educativos
 - 16.1.2. Técnicas de limpeza e normalização de dados para análise pedagógica
 - 16.1.3. Importância da integridade e da qualidade dos dados na investigação no domínio da educação
- 16.2. Análise e avaliação de dados educativos com IA para melhoria contínua na sala de aula
 - 16.2.1. Implementação do TensorFlow na interpretação de tendências e padrões educativos utilizando técnicas de aprendizagem automática
 - 16.2.2. Implementação do TensorFlow na interpretação de tendências e padrões educativos utilizando técnicas de aprendizagem automática
 - 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 académico a partir de dados educativos
 - 16.3.1. Estabelecimento de indicadores-chave para avaliar o desempenho dos alunos
 - 16.3.2. Avaliação comparativa de indicadores para identificar áreas de melhoria
 - 16.3.3. Correlação entre indicadores académicos e fatores externos utilizando IA
- 16.4. Ferramentas de IA para monitorização da educação e tomada de decisões
 - 16.4.1. Sistemas de apoio à decisão baseados em tome.ai para administradores de ensino
 - 16.4.2. Utilização do Trello para planeamento e atribuição de recursos educativos
 - 16.4.3. Otimização dos processos educativos através da análise preditiva com Orange Data Mining
- 16.5. Tecnologias e algoritmos de IA para análises preditivas dos dados de desempenho académico
 - 16.5.1. Fundamentos da modelos preditivos na educação
 - 16.5.2. Utilização de algoritmos de classificação e regressão para prever tendências educativas
 - 16.5.3. Estudos de casos de previsões bem sucedidas em contextos educativos
- 16.6. Aplicação da análise de dados com IA para a prevenção e solução de problemas educativos
 - 16.6.1. Identificação precoce dos riscos académicos através da análise preditiva
 - 16.6.2. Estratégias de intervenção baseadas em dados para enfrentar os desafios educativos
 - 16.6.3. Avaliação do impacto das soluções baseadas em IA da DataRobot na educação

- 16.7. Diagnóstico personalizado das dificuldades de aprendizagem a partir da análise de dados da IA
 - 16.7.1. Técnicas de IA para identificar estilos e dificuldades de aprendizagem com o IBM Watson Education
 - 16.7.2. Integração da análises de dados nos planos de apoio educativo individualizados
 - 16.7.3. Estudos de casos de diagnósticos melhorados pela utilização da IA
- 16.8. Análise de dados e aplicação de IA para identificar necessidades educativas específicas
 - 16.8.1. Enfoque da IA para a deteção de necessidades educativas especiais com Gooroo
 - 16.8.2. Personalização das estratégias de ensino com base na análise de dados
 - 16.8.3. Avaliação do impacto da IA na inclusão educativa
- 16.9. Personalização da aprendizagem com IA a partir da análise de dados de desempenho académico
 - 16.9.1. Criação de percursos de aprendizagem adaptativos utilizando o Smart Sparrow
 - 16.9.2. Implementação de sistemas de recomendação para recursos educativos
 - 16.9.3. Medição do progresso individual e ajustamentos em tempo real através do Squirrel AI Learning
- 16.10. Segurança e privacidade no tratamento de dados educativos
 - 16.10.1. Princípios éticos e jurídicos na gestão de dados no domínio da educação
 - 16.10.2. Técnicas de proteção de dados e privacidade para sistemas educativos com o Google Cloud Security
 - 16.10.3. Estudos de casos de violações de segurança e o seu impacto na educação

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

- 17.1. Planear e Desenho de projetos de IA na educação com a Algor Education
 - 17.1.1. Primeiros passos para planear o projeto
 - 17.1.2. Bases de conhecimento
 - 17.1.3. Desenho de projetos de IA na educação
- 17.2. Ferramentas para o desenvolvimento de projetos educativos com IA
 - 17.2.1. Ferramentas para o desenvolvimento Projeto Educativo: TensorFlow Playground
 - 17.2.2. Ferramentas para projetos educativos em História
 - 17.2.3. Ferramentas para Projetos Educativos em Matemática; Wolfram Alpha
 - 17.2.4. Ferramentas para projetos educativos em Inglês: Grammarly

- 17.3. Estratégias de implementação de projetos de IA em sala de aula
 - 17.3.1. Quando implementar um projeto de IA
 - 17.3.2. Quando implementar um projeto de IA
 - 17.3.3. Estratégias a levar a cabo
- 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: Deep L
 - 17.4.4. Outros temas: Watson Studio
- 17.5. Projeto 1: Desenvolvimento de projetos educativos utilizando a aprendizagem automática com a Khan Academy
 - 17.5.1. Primeiros passos
 - 17.5.2. Recolha de requisitos
 - 17.5.3. Ferramentas a utilizar
 - 17.5.4. Definição do projeto
- 17.6. Projeto 2: Integração da IA no desenvolvimento de jogos educativos
 - 17.6.1. Primeiros passos
 - 17.6.2. Recolha de requisitos
 - 17.6.3. Ferramentas a utilizar
 - 17.6.4. Definição do projeto
- 17.7. Projeto 3: Desenvolvimento de *chatbots* educativos para assistência aos estudantes
 - 17.7.1. Primeiros passos
 - 17.7.2. Recolha de requisitos
 - 17.7.3. Ferramentas a utilizar
 - 17.7.4. Definição do projeto
- 17.8. Projeto 4: Integração de agentes inteligentes em plataformas educativas com Knewton
 - 17.8.1. Primeiros passos
 - 17.8.2. Recolha de requisitos
 - 17.8.3. Ferramentas a utilizar
 - 17.8.4. Definição do projeto

- 17.9. Avaliação e medição do impacto dos projetos de IA na educação com a Qualtrics
 - 17.9.1. Benefícios de trabalho 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. Posta em marcha
 - 17.10.3. O que nos reserva o futuro
 - 17.10.4. Transformando a Escola 360

Módulo 18. Prática pedagógica com Inteligência Artificial generativa

- 18.1. Tecnologias de IA generativa para utilização 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 para vir
 - 18.1.4. O Futuro da sala de aula
- 18.2. Aplicação de ferramentas de IA generativa no planeamento educativo
 - 18.2.1. Ferramentas de planeamento: Altitude Learning
 - 18.2.2. Ferramentas e a sua aplicação
 - 18.2.3. Educação e IA
 - 18.2.4. Evolução
- 18.3. Criação de materiais didáticos com IA generativa utilizando Story Ai, Pix2Plx e NeouralTalk2
 - 18.3.1. IA e os seus usos na sala de aula
 - 18.3.2. Ferramentas para criar materiais didáticos
 - 18.3.3. Como trabalhar com as ferramentas
 - 18.3.4. Comandos
- 18.4. Desarrollo de pruebas de evaluación mediante IA generativa con Quizgecko
 - 18.4.1. A IA e as suas utilizações no desenvolvimento de testes de avaliação
 - 18.4.2. Ferramentas para o desenvolvimento testes de avaliação
 - 18.4.3. Como trabalhar com as ferramentas
 - 18.4.4. Comandos

- 18.5. Melhoria da retroalimentação e da comunicação com a IA generativa
 - 18.5.1. IA na comunicação
 - 18.5.2. Aplicação de ferramentas no desenvolvimento da comunicação na sala de aula
 - 18.5.3. Vantagens e desvantagens
- 18.6. Correção de atividades e testes de avaliação utilizando IA generativa com a IA do Gradescope
 - 18.6.1. A IA e as suas utilizações na correção de atividades e testes de avaliação
 - 18.6.2. Ferramentas para a correção de atividades e testes de avaliação
 - 18.6.3. Como trabalhar com as ferramentas
 - 18.6.4. Comandos
- 18.7. Geração de inquéritos de avaliação da qualidade do ensino utilizando IA generativa
 - 18.7.1. A IA e as suas utilizações na Geração de inquéritos de avaliação da qualidade do ensino utilizando IA
 - 18.7.2. Ferramentas para a Geração de inquéritos de avaliação da qualidade do ensino utilizando 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 de IA em estratégias pedagógicas
 - 18.8.2. Utilizações corretas
 - 18.8.3. Vantagens e desvantagens
 - 18.8.4. Ferramentas de IA generativa em estratégias pedagógicas: Gans
- 18.9. Utilização da IA generativa para o design universal da aprendizagem
 - 18.9.1. IA generativa, porquê agora
 - 18.9.2. IA na aprendizagem
 - 18.9.3. Vantagens e desvantagens
 - 18.9.4. Aplicação de a IA na aprendizagem
- 18.10. Avaliação da eficácia da IA generativa na educação
 - 18.10.1. Dados sobre a eficácia
 - 18.10.2. Projetos
 - 18.10.3. Objetivos do design
 - 18.10.4. Avaliação da eficácia da IA na educação

Módulo 19. Inovações e tendências emergentes na IA para a Educação

- 19.1. Ferramentas e tecnologias emergentes da IA para a educação
 - 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 as suas utilizações
 - 19.2.4. Vantagens e desvantagens
- 19.3. IA de conversação para apoio educativo e aprendizagem interativa com a IA da Wysdom e SnatchBot
 - 19.3.1. IA conversacional, porquê agora
 - 19.3.2. IA na aprendizagem
 - 19.3.3. Vantagens e desvantagens
 - 19.3.4. Aplicação de a IA na aprendizagem
- 19.4. Aplicação da IA para a melhoria da retenção de conhecimentos
 - 19.4.1. A IA como ferramenta de apoio
 - 19.4.2. Pautas a seguir
 - 19.4.3. Desempenho da IA na retenção de conhecimentos
 - 19.4.4. A IA e ferramentas de apoio
- 19.5. Tecnologias de reconhecimento facial e emocional para o acompanhamento da participação e o bem-estar dos alunos aula
 - 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 a IA na educação para transformar a administração da educação e validar certificações
 - 19.6.1. O que é Blockchain
 - 19.6.2. Blockchain e as suas aplicações
 - 19.6.3. Blockchain como elemento transformador
 - 19.6.4. Administração educativa e Blockchain

- 19.7. Ferramentas emergentes de IA para melhorar a experiência de aprendizagem com o Squirrel AI Learning
 - 19.7.1. Projetos atuais
 - 19.7.2. Posta em marcha
 - 19.7.3. O que nos reserva o futuro
 - 19.7.4. Transformando a Escola 360
- 19.8. Estratégias para o desenvolvimento de projetos-piloto 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 de inovação
 - 19.9.2. Aplicação de IA e os 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. Até 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 educativo
 - 20.1.1. Princípios e práticas para o tratamento ético de dados sensíveis na educação
 - 20.1.2. Desafios na proteção da privacidade e confidencialidade dos dados dos estudantes
 - 20.1.3. Estratégias para garantir a transparência e o consentimento informado da recompilação de dados
- 20.2. Impacto social e cultural da IA na educação
 - 20.2.1. Análise do efeito da IA na dinâmica social e cultural em contextos educativos.
 - 20.2.2. Exploração da forma como a IA para Acessibilidade da Microsoft pode perpetuar ou atenuar os preconceitos e as desigualdades sociais
 - 20.2.3. Avaliação da responsabilidade social dos criadores e educadores na implementação da IA

- 20.3. Legislação e política de dados sobre a IA em contextos educativos
 - 20.3.1. Revisão das leis e regulamentos atuais em matéria de dados e privacidade aplicáveis à IA na educação
 - 20.3.2. Impacto das políticas de dados nas práticas educativas e na inovação tecnológica
 - 20.3.3. Desenvolvimento de políticas institucionais para a utilização ética da IA na educação com o 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 quadros éticos para orientar o desenvolvimento e a utilização da IA na educação
- 20.5. Desafios e oportunidades da IA na educação
 - 20.5.1. Identificação dos principais desafios éticos e jurídicos na utilização da IA na educação
 - 20.5.2. Exploração das oportunidades para melhorar o ensino e a aprendizagem através do Squirrel AI Learning
 - 20.5.3. Equilíbrio entre a inovação tecnológica e considerações éticas na educação
- 20.6. Aplicação ética de soluções de IA no ambiente educativo
 - 20.6.1. Princípios para o desenho e implementação éticas de soluções de IA na educação
 - 20.6.2. Estudos de casos sobre aplicações éticas da IA em diferentes contextos educativos
 - 20.6.3. Estratégias para envolver todas as partes interessadas na tomada de decisões éticas sobre a IA
- 20.7. IA, diversidade cultural e igualdade de género
 - 20.7.1. Análise do impacto da IA na promoção da diversidade cultural e da equidade de género na educação
 - 20.7.2. Estratégias para desenvolver sistemas de IA inclusivos e sensíveis à diversidade com o Teachable Machine da Google
 - 20.7.3. Avaliação da forma como a IA pode influenciar a representação e o tratamento de diferentes grupos culturais e de género
- 20.8. Considerações éticas para Utilização de ferramentas a IA na Educação
 - 20.8.1. Orientações éticas para o desenvolvimento e utilização de ferramentas de IA na sala de aula
 - 20.8.2. Debate sobre o equilíbrio entre a automatização e a intervenção humana na educação
 - 20.8.3. Análise de casos em que a utilização da IA na educação levantou questões éticas significativas
- 20.9. Impacto da IA na Acessibilidade educativa
 - 20.9.1. Exploração da forma como a IA pode melhorar ou limitar a acessibilidade na educação
 - 20.9.2. Análise de soluções da IA designadas 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. Estudos de casos globais em IA e educação
 - 20.10.1. Análise de estudos de casos internacionais sobre a utilização da IA na educação
 - 20.10.2. Comparação de abordagens éticas e jurídicas em diferentes contextos culturais da educação
 - 20.10.3. Lições aprendidas e melhores práticas de casos globais em IA e educação




Ensino 100% online, sem horários fixos e com um programa de estudos disponível desde o primeiro dia.Increva-se já!"

06

Metodologia

Esta certificação oferece um método diferente de aprendizagem. A nossa metodologia foi desenvolvida através de um modo de aprendizagem cíclica: **o Relearning**.

Este método de ensino é utilizado, por exemplo, nas faculdades de medicina mais prestigiadas do mundo e tem sido considerado um dos mais eficazes por publicações líderes, tais como o ***New England Journal of Medicine***.





“

Descubra o Relearning, um sistema que renuncia à aprendizagem linear convencional para o guiar por meio de métodos de ensino cíclicos: uma forma de aprendizagem que provou ser extremamente eficaz, especialmente em disciplinas que requerem memorização”

Estudo de Caso para contextualizar todo o conteúdo

O nosso Curso oferece um método revolucionário de desenvolvimento de competências e conhecimentos. O nosso objetivo é reforçar as competências num contexto de mudança, competitivo e altamente exigente.

“

Com a TECH poderá experimentar uma forma de aprendizagem que abala as bases das universidades tradicionais em todo o mundo”



Terá acesso a um sistema de aprendizagem baseado na repetição, com ensino natural e progressivo ao longo de todo o plano de estudos.



Um método de aprendizagem inovador e diferente

Este Curso da TECH é um programa de ensino intensivo, criado de raiz, que propõe os desafios e decisões mais exigentes neste campo, tanto a nível nacional como internacional. Graças a esta metodologia, o crescimento pessoal e profissional é impulsionado, dando um passo decisivo para o sucesso. O método do caso, técnica que constitui a base deste conteúdo, assegura que a realidade económica, social e profissional mais atual seja seguida.

“*O nosso Curso de Especialização prepara-o para enfrentar novos desafios em ambientes incertos e alcançar o sucesso na sua carreira*”

O aluno aprenderá, através de atividades de colaboração e casos reais, a resolução de situações complexas em ambientes empresariais reais.

O método do caso tem sido o sistema de aprendizagem mais amplamente utilizado nas melhores escolas de Informática do mundo desde que estas existem. Desenvolvido em 1912 para que os estudantes de Direito não aprendessem apenas o direito com base no conteúdo teórico, o método do caso consistia em apresentar-lhes situações verdadeiramente complexas, a fim de tomarem decisões informadas e valorizarem juízos sobre a forma de as resolver. Em 1924 foi estabelecido como um método de ensino padrão em Harvard.

Numa dada situação, o que deve fazer um profissional? Esta é a questão que enfrentamos no método do caso, um método de aprendizagem orientado para a ação. Ao longo do Curso, os estudantes serão confrontados com múltiplos casos da vida real. Terão de integrar todo o seu conhecimento, investigar, argumentar e defender as suas ideias e decisões.

Relearning Methodology

A TECH combina eficazmente a metodologia do Estudo de Caso com um sistema de aprendizagem 100% online baseado na repetição, que combina elementos didáticos diferentes em cada lição.

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

Em 2019 alcançámos os melhores resultados de aprendizagem de todas as universidades online de língua espanhola do mundo.

Na TECH aprenderá com uma metodologia de vanguarda concebida para formar os gestores do futuro. Este método, pioneiro na pedagogia mundial, chama-se Relearning.

A nossa universidade é a única licenciada para utilizar este método de sucesso. Em 2019, conseguimos melhorar os níveis globais de satisfação dos nossos estudantes (qualidade de ensino, qualidade dos materiais, estrutura dos cursos, objetivos...) no que diz respeito aos indicadores da melhor universidade online em espanhol.



No nosso Curso, a aprendizagem não é um processo linear, mas acontece numa espiral (aprender, desaprender, esquecer e reaprender). Por isso, combinamos cada um destes elementos de forma concêntrica. Com esta metodologia formamos mais de 650.000 alunos com um sucesso sem precedentes em áreas tão diversas como Bioquímica, Genética, Cirurgia, Direito Internacional, Competências de Gestão, Ciências Desportivas, Filosofia, Direito, Engenharias, Jornalismo, História ou Mercados e Instrumentos Financeiros. Tudo isto num ambiente altamente exigente, com um corpo estudantil universitário com um elevado perfil socioeconómico e uma idade média de 43,5 anos.

O Relearning permitir-lhe-á aprender com menos esforço e mais desempenho, envolvendo-o mais na sua capacitação, desenvolvendo um espírito crítico, defendendo argumentos e opiniões contrastantes: uma equação direta ao sucesso.

A partir da última evidência científica no campo da neurociência, não só sabemos como organizar informação, ideias, imagens e memórias, mas sabemos que o lugar e o contexto em que aprendemos algo é fundamental para a nossa capacidade de o recordar e armazenar no hipocampo, para o reter na nossa memória a longo prazo.

Desta forma, e no que se chama Neurocognitive context-dependent e-learning, os diferentes elementos da nossa capacitação estão ligados ao contexto em que o participante desenvolve a sua prática profissional.

Este Curso de Especialização oferece o melhor material didático, cuidadosamente preparado para os profissionais:



Material de estudo

Todos os conteúdos didáticos são criados especificamente para o Curso, pelos especialistas que o irão lecionar, de modo a que o desenvolvimento didático seja realmente específico e concreto.

Estes conteúdos são depois colocados em formato audiovisual, para criar o método de trabalho online da TECH. Tudo isto, com as mais recentes técnicas, que oferecem componentes de alta-qualidade em cada um dos materiais colocados à disposição do aluno.



Masterclasses

Existe evidência científica acerca da utilidade da observação por especialistas terceiros.

O que se designa de Learning from an Expert fortalece o conhecimento e a recordação, e constrói a confiança em futuras decisões difíceis.




Estágios de aptidões e competências


Exercerão atividades para desenvolver competências e aptidões específicas em cada área temática. Práticas e dinâmicas para adquirir e desenvolver as competências e capacidades que um especialista deve desenvolver no quadro da globalização em que vivemos.



Leituras complementares

Artigos recentes, documentos de consenso e guias internacionais, entre outros. Na biblioteca virtual da TECH, o aluno terá acesso a tudo o que precisa para completar a sua especialização.



**Case studies**

Completarão uma seleção dos melhores estudos de caso escolhidos especificamente para esta certificação. Casos apresentados, analisados e instruídos pelos melhores especialistas do panorama internacional.

**Resumos interativos**

A equipa da TECH apresenta os conteúdos, de forma atrativa e dinâmica, em formato multimédia, que incluem áudios, vídeos, imagens, diagramas e mapas conceituais, a fim de reforçar o conhecimento.

Este sistema educativo único para a apresentação de conteúdos multimédia foi premiado pela Microsoft como um "Caso de Sucesso Europeu".

**Testing & Retesting**

Os conhecimentos do aluno são periodicamente avaliados e reavaliados ao longo do Curso, por meio de atividades e exercícios de avaliação e autoavaliação, para que o aluno possa verificar o cumprimento dos seus objetivos.



07

Certificação

O Mestrado Próprio em Inteligência Artificial no Educação garante, além da formação mais rigorosa e atualizada, o acesso a um certificado de Curso emitido pela TECH Global University.



“

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

Este programa permitirá a obtenção do certificado próprio de **Mestrado Próprio em Inteligência Artificial no Educação** reconhecido pela TECH Global University, a maior universidade digital do mundo

A **TECH Global University**, é uma Universidade Europeia Oficial reconhecida publicamente pelo Governo de Andorra ([bollettino ufficiale](#)). Andorra faz parte do Espaço Europeu de Educação Superior (EEES) desde 2003. O EEES é uma iniciativa promovida pela União Europeia com o objetivo de organizar o modelo de formação internacional e harmonizar os sistemas de ensino superior dos países membros desse espaço. O projeto promove valores comuns, a implementação de ferramentas conjuntas e o fortalecimento dos seus mecanismos de garantia de qualidade para fomentar a colaboração e a mobilidade entre alunos, investigadores e académicos.




Esse título próprio da **TECH Global University**, é um programa europeu de formação contínua e atualização profissional que garante a aquisição de competências na sua área de conhecimento, conferindo um alto valor curricular ao aluno que conclui o programa.

Título: **Mestrado Próprio em Inteligência Artificial no Educação**

Modalidade: **online**

Duração: **12 meses**

Acreditação: **90 ECTS**



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



Mestrado Próprio Inteligência Artificial na Educação

- » Modalidade: online
- » Duração: 12 meses
- » Certificação: TECH Global University
- » Acreditação: 90 ECTS
- » Horário: Ao seu próprio ritmo
- » Exames: online

Mestrado Próprio

Inteligência Artificial na Educação

