

Mestrado Próprio

Inteligência Artificial na Programação



Mestrado Próprio Inteligência Artificial na Programação

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

Acesso ao site: www.techtitude.com/pt/informatica/mestrado-proprio/mestrado-proprio-inteligencia-artificial-programacao

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) surgiu como um pilar fundamental no mundo da programação, devido à sua capacidade de automatizar tarefas complexas, tomar decisões baseadas em dados e aprender com padrões. De facto, a IA oferece ferramentas e técnicas que permitem a criação de sistemas mais inteligentes e eficientes. Desde os algoritmos de aprendizagem automática, que melhoram a precisão dos programas, até ao desenvolvimento de sistemas autónomos, capazes de tomar decisões em tempo real, a IA transformou radicalmente a forma como o código é concebido e executado. Neste contexto, a TECH concebeu um Mestrado Próprio que proporcionará ao aluno a oportunidade de se aprofundar nos mais recentes avanços nesta área, através da revolucionária metodologia Relearning.



“

Este Mestrado Próprio em Inteligência Artificial na Programação irá fornecer-lhe uma perspectiva holística sobre como a IA impacta e melhora todas as fases do desenvolvimento de software"

A importância da Inteligência Artificial na Programação assenta na sua capacidade de potenciar e automatizar processos, otimizando o desenvolvimento de software e melhorando a eficiência na resolução de problemas complexos. A sua capacidade de analisar grandes volumes de dados e encontrar soluções ideais levou a avanços significativos em domínios como a otimização de algoritmos, a criação de interfaces mais intuitivas e a resolução de problemas complexos em diferentes áreas.

É por isso que a TECH desenvolveu este Mestrado Próprio, que surge como uma solução estratégica para aumentar as oportunidades profissionais e o crescimento dos informáticos nas suas carreiras. Será abordada a melhoria da produtividade no desenvolvimento de software através da IA, explorando as técnicas e ferramentas que automatizam processos, otimizam o código e aceleram a criação de aplicações inteligentes.

Para além disso, o Mestrado Próprio centrar-se-á no papel crucial da IA no âmbito do QA Testing, implementando algoritmos e métodos de IA para melhorar a qualidade, a precisão e a cobertura dos testes, detetando e corrigindo erros de forma mais eficiente. Será também aprofundada a integração da aprendizagem automática e das capacidades de processamento da linguagem natural no desenvolvimento da Web, criando sites inteligentes que se adaptam e oferecem experiências personalizadas aos utilizadores.

Também se aprofundará as técnicas de IA para melhorar a usabilidade, a interação e a funcionalidade das aplicações móveis, para criar aplicações inteligentes e preditivas que se adaptem ao comportamento do utilizador. Proceder-se-á também a uma análise aprofundada da arquitetura do software com IA, incluindo os vários modelos que facilitarão a integração de algoritmos de IA e a sua implantação em ambientes de produção.

Com o objetivo de qualificar especialistas em IA altamente competentes, a TECH concebeu um Mestrado Próprio abrangente baseado na metodologia exclusiva Relearning. Esta abordagem permitirá aos alunos consolidar a sua compreensão através da repetição de conceitos fundamentais.

Este **Mestrado Próprio em Inteligência Artificial na Programação** 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 Programação
- ♦ Os conteúdos gráficos, esquemáticos e eminentemente práticos com os quais foi concebido fornecem informação científica e prática sobre as disciplinas que são essenciais para a prática profissional
- ♦ Exercícios práticos onde o processo de autoavaliação pode ser levado a cabo a fim de melhorar a aprendizagem
- ♦ A sua ênfase especial em metodologias inovadoras
- ♦ Lições teóricas, perguntas ao especialista, fóruns de discussão sobre questões controversas e atividades de reflexão individual
- ♦ A disponibilidade de acesso ao conteúdo a partir de qualquer dispositivo fixo ou portátil com ligação à Internet



Irá liderar projetos inovadores adaptados às exigências de um mercado tecnológico em constante evolução.

Do que está à espera para se inscrever?"

“

Irá explorar os aspetos fundamentais da arquitetura de software, incluindo o desempenho, a escalabilidade e a manutenção, graças aos recursos multimédia mais inovadores”


O corpo docente do Mestrado Próprio inclui profissionais do setor que trazem a sua experiência profissional, para além de especialistas reconhecidos de sociedades de referência e universidades de prestígio.

O seu conteúdo multimédia, desenvolvido com a mais recente tecnologia educativa, permitirá ao profissional uma aprendizagem situada e contextual, ou seja, um ambiente simulado que proporcionará uma preparação imersiva programada para praticar em situações reais.

A conceção deste Mestrado Próprio baseia-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 percurso académico. Para tal, contará com a ajuda de um sistema inovador de vídeo interativo desenvolvido por especialistas reconhecidos.

Pretende especializar-se em Inteligência Artificial? Com este Mestrado Próprio, irá dominar a otimização do processo de aplicação e a integração da IA na computação em nuvem.

Irá aprofundar a integração de elementos de IA no Visual Studio Code e a otimização do código com o ChatGPT, tudo através de um percurso académico abrangente.



02 Objetivos

O principal objetivo deste Mestrado Próprio é proporcionar aos profissionais o acesso aos conhecimentos mais avançados na área, com uma abordagem que promove a sua qualificação integral. Desta forma, terão a oportunidade de participar num percurso académico exclusivo e completamente online. Os alunos serão dotados de competências úteis e inovadoras, desde o desenvolvimento de software baseado em IA, ao design e à execução de projetos web e aplicações móveis com inteligência e adaptabilidade. Com este Mestrado Próprio, o informático ultrapassará as fronteiras da programação convencional e tornar-se-á um elemento ativo na revolução tecnológica.



“

*Abordará o ciclo de vida do testing,
desde a criação de casos de test cases
até à deteção de bugs, graças à TECH"*



Objetivos gerais

- ♦ Desenvolver competências para criar e gerir ambientes de desenvolvimento eficientes, garantindo uma base sólida para a implementação de projetos com IA
- ♦ Adquirir competências no planeamento, execução e automatização de testes de qualidade, incorporando ferramentas de IA para deteção e correção de bugs
- ♦ Compreender e aplicar princípios de desempenho, escalabilidade e facilidade de manutenção no design de sistemas informáticos de grande escala
- ♦ Familiarizar-se com os padrões de conceção mais importantes e aplicá-los eficazmente na arquitetura de software





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 neurais 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* (Armazém de Dados), com ênfase nos elementos que o integram e na sua conceção
- ♦ 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

- ♦ Domine 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. Exploração 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 conceção 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. Redes neuronais, 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 neuronais e compreender a sua aplicação na construção de modelos
- ♦ Analisar as diferentes camadas utilizadas nas redes neuronais e aprender a selecioná-las adequadamente
- ♦ Compreender a ligação eficaz de camadas e operações para conceber arquiteturas de redes neuronais complexas e eficientes
- ♦ Utilizar treinadores e otimizadores para ajustar e melhorar o desempenho das redes neuronais
- ♦ Explorar a ligação entre neurónios biológicos e artificiais para uma compreensão mais profunda do design de modelos
- ♦ Ajustar hiperparâmetros para o *Fine Tuning* de redes neuronais, otimizando o seu desempenho em tarefas específicas

Módulo 9. Treino de redes neuronais profundas

- ♦ Resolver problemas relacionados com gradientes na formação de redes neuronais 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 neuronais 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 do *TensorFlow* e a sua integração com o NumPy para um tratamento e computação eficientes dos dados
- ♦ Personalizar modelos e algoritmos de treino utilizando as capacidades avançadas do TensorFlow
- ♦ Explorar a API tfdata para gerir e manipular eficientemente conjuntos de dados
- ♦ Implementar o formato TFRecord para armazenar e aceder a grandes conjuntos de dados *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 do 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
- ♦ Implantar 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 deteção 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 PLN

- ♦ 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 neurais no domínio 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 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 A
- ♦ 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. Melhoria da produtividade no desenvolvimento de software com IA

- ♦ Aprofundar a implementação de extensões de IA obrigatórias no Visual Studio Code para melhorar a produtividade e facilitar o desenvolvimento de *software*
- ♦ Adquirir uma sólida compreensão dos conceitos básicos de IA e da sua aplicação no desenvolvimento de *software*, incluindo algoritmos de aprendizagem automática, processamento de linguagem natural, redes neuronais, etc.
- ♦ Dominar a configuração de ambientes de desenvolvimento otimizados, garantindo que os alunos possam criar ambientes propícios a projetos de IA
- ♦ Aplicar técnicas específicas utilizando o ChatGPT para a identificação e correção automática de possíveis melhorias no código, incentivando práticas de programação mais eficientes
- ♦ Promover a colaboração entre diferentes programadores (desde programadores a engenheiros de dados e designers da experiência do utilizador) para desenvolver soluções de *software* de IA eficazes e éticas

Módulo 17. Arquitetura do software para QA Testing

- ♦ Desenvolver habilidades para conceber planos de teste consistentes, abrangendo diferentes tipos de *testing* e garantindo a qualidade do software
- ♦ Reconhecer e analisar diferentes tipos de estruturas de *software*, tais como monolíticas, de microsserviços ou orientadas para os serviços
- ♦ Obter uma visão holística princípios e técnicas para conceber sistemas informáticos que sejam escaláveis e capazes de lidar com grandes volumes de dados

- ♦ Aplicar conhecimentos avançados na implementação de estruturas de dados alimentadas por IA para otimizar o desempenho e a eficiência do *software*
- ♦ Desenvolver práticas de desenvolvimento seguras, procurando evitar vulnerabilidades para garantir a segurança do *software* a nível arquitetónico

Módulo 18. Projetos Web com IA

- ♦ Desenvolver competências abrangentes para a implementação de projetos Web, desde o design do *frontend* até à otimização do *backend*, com a inclusão de elementos de IA
- ♦ Otimizar o processo de implantação de sites, incorporando técnicas e ferramentas para melhorar a velocidade e a eficiência
- ♦ Integrar a IA na computação em nuvem, permitindo aos alunos criar projetos Web altamente escaláveis e eficientes
- ♦ Adquirir a capacidade de identificar problemas específicos e oportunidades em projetos web em que a IA pode ser aplicada de forma eficaz, como o processamento de texto, a personalização, a recomendação de conteúdos, etc.
- ♦ Incentivar os estudantes a manterem-se a par das últimas tendências e desenvolvimentos em IA para a sua devida aplicação em projetos web

Módulo 19. Aplicações móveis com IA

- ♦ Aplicar conceitos avançados de *clean architecture*, *datasources* y *repositories* para garantir uma estrutura robusta e modular em aplicações móveis com IA
- ♦ Desenvolver competências para conceber ecrãs interativos, ícones e recursos gráficos utilizando a IA para melhorar a experiência do utilizador nas aplicações móveis
- ♦ Aprofundar a configuração da estrutura da aplicação móvel e utilizar o *Github Copilot* para acelerar o processo de desenvolvimento

- ♦ Otimizar as aplicações móveis de IA para um desempenho eficiente, tendo em conta a gestão de recursos e a utilização de dados
- ♦ Realizar testes de qualidade de aplicações móveis com IA, permitindo aos alunos identificar problemas e depurar erros

Módulo 20. IA para QA Testing

- ♦ Dominar princípios e técnicas para conceber sistemas informáticos que sejam escaláveis e capazes de lidar com grandes volumes de dados
- ♦ Aplicar conhecimentos avançados na implementação de estruturas de dados alimentadas por IA para otimizar o desempenho e a eficiência do *software*
- ♦ Compreender e aplicar práticas de desenvolvimento seguras, procurando evitar vulnerabilidades como a injeção, para garantir a segurança do *software* a nível arquitetónico
- ♦ Elaborar testes automatizados, especialmente em ambientes Web e móveis, integrando ferramentas de IA para melhorar a eficiência do processo
- ♦ Utilizar ferramentas avançadas de QA alimentadas por IA para uma deteção mais eficiente de *bugs* e uma melhoria contínua do *software*



*Dominará as tecnologias do futuro
com esta certificação exclusiva
100% online. Só com a TECH!"*

03

Competências

Este Mestrado Próprio proporcionará aos alunos uma vantagem significativa na indústria do desenvolvimento informático, dotando-os de competências específicas e atualizadas no domínio da Inteligência Artificial (IA). Os profissionais serão capazes não só de conceber e desenvolver software avançado, mas também de implementar eficazmente soluções de IA em diversas aplicações, desde projetos Web e móveis até à arquitetura de software em grande escala. Para além disso, ao abordar a produtividade do desenvolvimento e as melhores práticas de *QA Testing*, assegurará que os informáticos estejam preparados para enfrentar os desafios do mundo real e se destaquem num domínio em constante evolução.



“

Graças a este Mestrado Próprio, será capaz de implementar algoritmos de IA em projetos Web e aplicações móveis”



Competências gerais

- ♦ Aplicar extensões de IA no Visual Studio Code e técnicas de concepção *no-code* para aumentar a eficiência no desenvolvimento de software
- ♦ Utilizar o ChatGPT para otimizar e melhorar a qualidade do código, aplicando práticas de programação avançadas
- ♦ Implementar projetos Web, desde a criação de *workspaces* até à implantação, integrando a IA tanto no *frontend* como no *backend*
- ♦ Desenvolver aplicações móveis alimentadas por IA, desde a configuração do ambiente até à criação de funcionalidades avançadas e à gestão de recursos gráficos
- ♦ Aplicar conceitos avançados de armazenamento e estruturas de dados alimentadas por IA para melhorar a eficiência e a escalabilidade dos sistemas
- ♦ Incluir práticas de desenvolvimento seguro, evitando vulnerabilidades como a injeção, para garantir a integridade e a segurança do software desenvolvido

“

Será capaz de conceber experiências de utilizador personalizadas e intuitivas através da Inteligência Artificial. Inscreva-se já!”





Competências específicas

- ♦ Aplicar técnicas e estratégias de IA para melhorar a eficiência no setor do *retail*
- ♦ 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 sua utilização em modelos de *Deep Computer Vision* com o Keras
- ♦ Utilizar funções e gráficos *TensorFlow* para otimizar o desempenho dos modelos personalizados
- ♦ Melhorar o desenvolvimento e a aplicação de *chatbots* e agentes 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 os conceitos aprendidos na prática
- ♦ 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
- ♦ 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 precisão da informação utilizada nas análises posteriores
- ♦ Dominar a configuração de ambientes de desenvolvimento otimizados, garantindo que os alunos possam criar ambientes propícios a projetos de IA
- ♦ Aplicar técnicas específicas, utilizando o ChatGPT para a identificação e correção automática de possíveis melhorias no código, incentivando práticas de programação mais eficientes
- ♦ Criar testes automatizados, especialmente em ambientes Web e móveis, integrando ferramentas de IA para melhorar a eficiência do processo
- ♦ Utilizar ferramentas avançadas de QA alimentadas por IA para uma deteção mais eficiente de bugs e uma melhoria contínua do software
- ♦ Integrar a IA na computação em nuvem, permitindo aos alunos criar projetos Web altamente escaláveis e eficientes
- ♦ Configurar a estrutura para aplicações móveis e utilizar o Github Copilot para simplificar o processo de desenvolvimento

04

Direção do curso

No seu compromisso com o ensino de elite, a TECH selecionou cuidadosamente os professores responsáveis pelo desenvolvimento do plano de estudos desta certificação. Assim, este Mestrado Próprio conta com um corpo docente com uma experiência notável na aplicação da Inteligência Artificial em tarefas de Programação. Desta forma, os alunos deste Mestrado Próprio terão acesso a uma experiência educativa de primeira classe, com uma combinação única de conhecimentos apresentados em vários meios audiovisuais, para uma integração mais eficaz e dinâmica dos conhecimentos.



“

Atualizar-se sobre as últimas
tendências em Inteligência Artificial
aplicada à Programação com os
melhores especialistas da área”

Direção



Doutor Arturo Peralta Martín-Palomino

- CEO e CTO na 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
- Doutoramento em Engenharia Informática pela Universidade de Castilla-La Mancha
- Doutoramento em Economia, Empresas e Finanças pela Universidade Camilo José Cela
- Doutoramento 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



Sr. Ricardo Castellanos Herreros

- ♦ Especialista em Engenharia de Sistemas Informáticos
- ♦ *Chief Technology Officer* na OWQLO
- ♦ Consultor Técnico *Freelance*
- ♦ Programador de aplicações móveis para eDreams, Fnac, Air Europa, Bankia, Cetelem, Banco Santander, Santillana, Groupón e Grupo Planeta
- ♦ Programador Web para o Openbank e o Banco Santander
- ♦ Curso de *Machine Learning Engineer* na Udacity
- ♦ Engenheiro Técnica de Informática Sistemas pela Universidade de Castilla la Mancha

05

Estrutura e conteúdo

Este Mestrado Próprio em Inteligência Artificial na Programação destaca-se pela sua abordagem integral, abrangendo não só a implementação de algoritmos inteligentes, mas também a melhoria da produtividade no desenvolvimento de software e a aplicação da IA em áreas-chave como *QA Testing*, projetos Web, aplicações móveis e arquitetura de software. A combinação de competências técnicas, ferramentas avançadas e a aplicação prática da IA em várias fases do desenvolvimento posiciona-o como líder, proporcionando aos profissionais uma compreensão completa e detalhada da aplicação da IA na Programação.



“

Irá explorar a aplicação prática da IA em projeto Web, incluindo o desenvolvimento de front-end e back-end”

Módulo 1. Fundamentos da Inteligência Artificial

- 1.1. História da Inteligência Artificial
 - 1.1.1. Quando é que começámos a falar de inteligência artificial?
 - 1.1.2. Referências no cinema
 - 1.1.3. Importância da inteligência artificial
 - 1.1.4. Tecnologias que permitem 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 neuronais
 - 1.3.1. Fundamentos teológicos
 - 1.3.2. Modelo computacional
 - 1.3.3. Redes neuronais 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. 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/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 de voz e texto
 - 1.8.2. Partes fundamentais para o desenvolvimento de um agente: *Intenções*, entidades e fluxo de diálogo
 - 1.8.3. Integração: Web, *Slack*, Whatsapp, Facebook
 - 1.8.4. Ferramentas para o desenvolvimento dos agentes: *Dialog Flow*, *Watson Assistant*
- 1.9. Estratégia e implantação 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, mostra indivíduo
 - 2.1.3. Variáveis: Definição de medição
- 2.2. Tipos de dados estatísticos
 - 2.2.1. De acordo com o tipo
 - 2.2.1.1. Quantitativos: dados contínuos e dados discretos
 - 2.2.1.2. Qualitativo: dados binomiais, dados nominais, dados ordinais
 - 2.2.2. De acordo com 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. Mineração 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 sem supervisão
 - 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. Exploração 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 design de 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 (*Quick_sort*)

- 5.4. Algoritmos com árvores
 - 5.4.1. Conceito de árvore
 - 5.4.2. Árvores binárias
 - 5.4.3. Caminhos de árvore
 - 5.4.4. Representar expressões
 - 5.4.5. Árvores binárias 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. Busca em amplitude
 - 5.6.3. Busca 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. 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 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 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. Comparativa
- 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 informação
 - 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 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 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 de 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 neurais simples
 - 7.6.3. Algoritmo de *Backpropagation*
 - 7.6.4. Introdução às redes neurais recorrentes

- 7.7. Métodos bayesianos
 - 7.7.1. Conceitos básicos de probabilidade
 - 7.7.2. Teorema de Bayes
 - 7.7.3. Naive Bayes
 - 7.7.4. Introdução às redes bayesianas
- 7.8. Modelos de regressão e 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. 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. Deslocalização

- 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 Neuronais
 - 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 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. 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. Controle 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. Criação 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. Carregamento e pré-processamento 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. Carregamento de 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 *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 implantação de camadas de agrupamento com o Keras
 - 11.3.1. *Pooling* e *Striding*
 - 11.3.2. *Flattening*
 - 11.3.3. Tipos de *Pooling*
- 11.4. 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. Criação de texto utilizando RNN
 - 12.1.1. Treino de uma RNN para criação de texto
 - 12.1.2. Criação de linguagem natural com RNN
 - 12.1.3. Aplicações de criação 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 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. Implantação 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*. Comparativa
 - 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 PNL 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. Implantação 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. Criação de imagens
 - 13.8.3. Treino de redes neurais profundas
- 13.9. Redes generativas antagônicas e modelos de difusão
 - 13.9.1. Criação de conteúdos a partir de imagens
 - 13.9.2. Modelação de distribuições de dados
 - 13.9.3. Utilização de redes contraditórias
- 13.10. Implantação dos Modelos
 - 13.10.1. Aplicação Prática
 - 13.10.2. Implantação 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 colônias de formigas
 - 14.2.2. Variantes dos algoritmos de 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
 - 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 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 utilização de redes neurais na investigação médica
 - 14.10.2. Casos de utilização de redes neurais na economia
 - 14.10.3. Casos de utilização de redes neurais 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. Indústria
 - 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 silvicultura e na agricultura. 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. Melhoria da produtividade no desenvolvimento de software com IA

- 16.1.4. Gestão eficaz das dependências e do controlo de versões nos ambientes de desenvolvimento
- 16.2. Extensões essenciais de IA para o Visual Studio Code
 - 16.2.1. Exploração e seleção de extensões de IA para o Visual Studio Code
 - 16.2.2. Integrando ferramentas de análise estática e dinâmica no IDE
 - 16.2.3. Automatização de tarefas repetitivas com extensões específicas
 - 16.2.4. Personalização do ambiente de desenvolvimento para melhorar a eficiência
- 16.3. Design *No-code* de Interfaces de Utilizador com Elementos de IA
 - 16.3.1. Princípios do design *No-code* e sua aplicação a interfaces de utilizador
 - 16.3.2. Incorporação de elementos de IA no design de interfaces visuais
 - 16.3.3. Ferramentas e plataformas para a criação *No-code* de interfaces inteligentes
 - 16.3.4. Avaliação e melhoria contínua de interfaces *No-code* com IA
- 16.4. Otimização de código utilizando o ChatGPT
 - 16.4.1. Identificar código duplicado
 - 16.4.2. Refatorar
 - 16.4.3. Criar códigos legíveis
 - 16.4.4. Compreender o que o código faz
 - 16.4.5. Melhorar a designação de variáveis e funções
 - 16.4.6. Criação de documentação automática
- 16.5. Gestão de repositórios com IA
 - 16.5.1. Automatização dos processos de controlo de versões com técnicas de IA
 - 16.5.2. Deteção e resolução automática de conflitos em ambientes de colaboração
 - 16.5.3. Análise preditiva de alterações e tendências em repositórios de código
 - 16.5.4. Melhoria da organização e categorização de repositórios através de IA
- 16.6. Integração da IA na gestão de bases de dados
 - 16.6.1. Otimização das consultas e do desempenho utilizando técnicas de IA
 - 16.6.2. Análise preditiva de padrões de acesso a bases de dados
 - 16.6.3. Implementação de sistemas de recomendação para otimizar a estrutura da base de dados
 - 16.6.4. Monitorização proativa e deteção de potenciais problemas na base de dados
- 16.7. Pesquisa de falhas e criação de testes unitários com IA
 - 16.7.1. Geração automática de casos de teste utilizando técnicas de IA
 - 16.7.2. Deteção precoce de vulnerabilidades e erros através de análise estática com IA
 - 16.7.3. Melhoria da cobertura dos testes através da identificação de áreas críticas por IA

- 16.8. *Pair Programming* com GitHub Copilot
 - 16.8.1. Integração e utilização eficiente do GitHub Copilot em sessões de *Pair Programming*
 - 16.8.2. Melhoria na comunicação e colaboração entre programadores com o GitHub Copilot
 - 16.8.3. Estratégias para tirar o máximo partido das sugestões de código geradas pelo GitHub Copilot
 - 16.8.4. Estudos de caso e boas práticas em programação em *Pair Programming* assistida por IA
 - 16.9. Tradução automática entre linguagens de programação
 - 16.9.1. Ferramentas e serviços de tradução automática específicos de linguagens de programação
 - 16.9.2. Adaptação dos algoritmos de tradução automática aos contextos de desenvolvimento
 - 16.9.3. Melhoria da interoperabilidade entre diferentes línguas através da tradução automática
 - 16.9.4. Avaliação e atenuação dos potenciais desafios e limitações da tradução automática
 - 16.10. Ferramentas de IA recomendadas para melhorar a produtividade
 - 16.10.1. Análise comparativa das ferramentas de IA para o desenvolvimento de software
 - 16.10.2. Integração de ferramentas de IA em fluxos de trabalho
 - 16.10.3. Automatização de tarefas de rotina com ferramentas de IA
 - 16.10.4. Avaliação e seleção de ferramentas com base no contexto e nos requisitos do projeto
- Módulo 17. Arquitetura do software com IA**
- 17.1. Otimização e gestão do desempenho em ferramentas com IA
 - 17.1.1. Análise e perfil do desempenho em ferramentas com IA
 - 17.1.2. Estratégias de otimização para algoritmos e modelos de IA
 - 17.1.3. Implementação de técnicas de *caching* e de paralelização para melhorar o desempenho
 - 17.1.4. Ferramentas e metodologias para monitorização contínua do desempenho em tempo real
 - 17.2. Escalabilidade em aplicações de IA
 - 17.2.1. Design de arquiteturas escaláveis para aplicações de IA
 - 17.2.2. Implementação de técnicas de partição e distribuição de carga
 - 17.2.3. Gestão do fluxo de trabalho e da carga de trabalho em sistemas escaláveis
 - 17.2.4. Estratégias de expansão horizontal e vertical em ambientes com procura variável
 - 17.3. Manutenibilidade das aplicações com IA
 - 17.3.1. Princípios de design para facilitar a manutenibilidade em projetos de IA
 - 17.3.2. Estratégias de documentação específicas para modelos e algoritmos de IA
 - 17.3.3. Implementação de testes unitários e de integração para facilitar a manutenção
 - 17.3.4. Métodos de refatoração e melhoria contínua em sistemas com componentes de IA
 - 17.4. Design de sistemas de grande escala
 - 17.4.1. Princípios de arquitetura para a conceção de sistemas em grande escala
 - 17.4.2. Decomposição de sistemas complexos em microserviços
 - 17.4.3. Implementação de padrões de design específicos para sistemas distribuídos
 - 17.4.4. Estratégias para gerir a complexidade em arquiteturas de grande escala com componentes de IA
 - 17.5. Armazenamento de dados de grande escala para ferramentas de IA
 - 17.5.1. Seleção de tecnologias de armazenamento de dados escaláveis
 - 17.5.2. Conceção de esquemas de bases de dados para o tratamento eficiente de grandes volumes de dados
 - 17.5.3. Estratégias de partição e replicação em ambientes de armazenamento de dados em massa
 - 17.5.4. Implementação de sistemas de gestão de dados para garantir a integridade e disponibilidade em projetos com IA
 - 17.6. Estruturas de dados com IA
 - 17.6.1. Adaptação de estruturas de dados clássicas para utilização em algoritmos de IA
 - 17.6.2. Conceção e otimização de estruturas de dados específicas para modelos de aprendizagem automática
 - 17.6.3. Integração de estruturas de dados eficientes em sistemas com processamento intensivo de dados
 - 17.6.4. Estratégias para a manipulação e o armazenamento de dados em tempo real em estruturas de dados com IA
 - 17.7. Algoritmos de programação para produtos com IA
 - 17.7.1. Desenvolvimento e implementação de algoritmos específicos para aplicações com IA
 - 17.7.2. Estratégias de seleção de algoritmos de acordo com o tipo de problema e os requisitos do produto

- 17.7.3. Adaptação de algoritmos clássicos para integração em sistemas de inteligência artificial
- 17.7.4. Avaliação e comparação do desempenho entre diferentes algoritmos em contextos de desenvolvimento de IA
- 17.8. Padrões de design para o desenvolvimento de IA
 - 17.8.1. Identificação e aplicação de padrões de design comuns em projetos com componentes de IA
 - 17.8.2. Desenvolvimento de padrões específicos para a integração de modelos e algoritmos em sistemas existentes
 - 17.8.3. Estratégias de implementação de padrões para melhorar a reutilização e a manutenção em projetos de IA
 - 17.8.4. Estudos de casos e melhores práticas na aplicação de padrões de design em arquiteturas de IA
- 17.9. Implementação de *Clean Architecture*
 - 17.9.1. Princípios e conceitos fundamentais da *Clean Architecture*
 - 17.9.2. Adaptação da *Clean Architecture* a projetos com componentes de IA
 - 17.9.3. Implementação de camadas e dependências em sistemas com arquitetura limpa
 - 17.9.4. Benefícios e desafios da implementação de uma *Clean Architecture* no desenvolvimento de software com IA
- 17.10. Desenvolvimento de software seguro em aplicações web com IA
 - 17.10.1. Princípios de segurança no desenvolvimento de software com componentes de IA
 - 17.10.2. Identificação e atenuação de potenciais vulnerabilidades em modelos e algoritmos de IA
 - 17.10.3. Implementação de práticas de desenvolvimento seguro em aplicações web com funcionalidades de Inteligência Artificial
 - 17.10.4. Estratégias de proteção de dados sensíveis e de prevenção de ataques em projetos com IA

Módulo 18. Projetos Web com IA

- 18.1. Preparar o Ambiente de Trabalho para o Desenvolvimento Web com IA
 - 18.1.1. Configuração de ambientes de desenvolvimento Web para projetos com inteligência artificial
 - 18.1.2. Seleção e preparação de ferramentas essenciais para o desenvolvimento web com IA
 - 18.1.3. Integração de bibliotecas e *frameworks* específicos para projetos web com inteligência artificial
 - 18.1.4. Implementação de boas práticas na configuração de ambientes de desenvolvimento colaborativo
- 18.2. Criação de *Workspace* para Projetos de IA
 - 18.2.1. Design e organização eficaz de *workspaces* para projetos web com componentes de inteligência artificial
 - 18.2.2. Utilização de ferramentas de gestão de projetos e de controlo de versões no *workspace*
 - 18.2.3. Estratégias para a colaboração e a comunicação eficientes na equipa de desenvolvimento
 - 18.2.4. Adaptação do *workspace* às necessidades específicas dos projetos web com IA
- 18.3. Padrões de Design em Produtos com IA
 - 18.3.1. Identificação e aplicação de padrões de design comuns em interfaces de utilizador com elementos de inteligência artificial
 - 18.3.2. Desenvolvimento de padrões específicos para melhorar a experiência do utilizador em projetos web com IA
 - 18.3.3. Integração de padrões de design na arquitetura geral de projetos web com Inteligência Artificial
 - 18.3.4. Avaliação e seleção de padrões de design apropriados de acordo com o contexto do projeto
- 18.4. Desenvolvimento Frontend com IA
 - 18.4.1. Integração de modelos de IA na camada de apresentação de projetos web
 - 18.4.2. Desenvolvimento de interfaces de utilizador adaptáveis com elementos de inteligência artificial
 - 18.4.3. Implementação de funcionalidades de processamento de linguagem natural (NLP) no Frontend
 - 18.4.4. Estratégias para otimização do desempenho no desenvolvimento Frontend com IA
- 18.5. Criação da Base de Dados
 - 18.5.1. Seleção de tecnologias de bases de dados para projetos web com inteligência artificial
 - 18.5.2. Conceção de esquemas de bases de dados para armazenar e gerir dados relacionados com IA
 - 18.5.3. Implementação de sistemas de armazenamento eficientes para grandes volumes de dados gerados a partir de modelos com IA
 - 18.5.4. Estratégias para a segurança e proteção de dados sensíveis em bases de dados de projetos web com IA

- 18.6. Desenvolvimento Backend com IA
 - 18.6.1. Integração de serviços e modelos de IA na lógica comercial do Backend
 - 18.6.2. Desenvolvimento de API e pontos de extremidade específicos para a comunicação entre os componentes do Frontend e da IA
 - 18.6.3. Implementação da lógica de processamento de dados e de tomada de decisões no Backend com Inteligência Artificial
 - 18.6.4. Estratégias para a escalabilidade e o desempenho no desenvolvimento Backend de projetos web com IA
- 18.7. Otimizar o Processo de Implantação na Sua Web
 - 18.7.1. Automatizar o processo de criação e implantação de projetos Web com IA
 - 18.7.2. Implementar pipelines CI/CD adaptados a aplicações Web com componentes de inteligência artificial
 - 18.7.3. Estratégias para uma gestão eficiente de versões e atualizações em implantações contínuas
 - 18.7.4. Monitorização e análise pós-implantação para melhoria contínua do processo
- 18.8. IA na Computação em Nuvem
 - 18.8.1. Integração de serviços de inteligência artificial em plataformas de computação em nuvem
 - 18.8.2. Desenvolvimento de soluções escaláveis e distribuídas usando serviços de nuvem habilitados para IA
 - 18.8.3. Estratégias para uma gestão eficiente dos recursos e dos custos em ambientes de computação em nuvem com aplicações web com IA
 - 18.8.4. Avaliação e comparação de fornecedores de serviços em nuvem para projetos web com Inteligência Artificial
- 18.9. Criação de um projeto de IA para Ambientes LAMP
 - 18.9.1. Adaptação de projetos da Web com base no conjunto LAMP para incluir componentes de Inteligência Artificial
 - 18.9.2. Integração de bibliotecas e *frameworks* específicos de IA em ambientes LAMP
 - 18.9.3. Desenvolvimento de funcionalidades de IA que complementem a arquitetura LAMP tradicional
 - 18.9.4. Estratégias de otimização e manutenção em projetos web habilitados para IA em ambientes LAMP
- 18.10. Criação de um projeto de IA para Ambientes MEVN
 - 18.10.1. Integração de tecnologias e ferramentas do conjunto MEVN com componentes de Inteligência Artificial
 - 18.10.2. Desenvolvimento de aplicações web modernas e escaláveis em ambientes MEVN com capacidades de IA

- 18.10.3. Implementação de funcionalidades de tratamento de dados e de aprendizagem automática em projetos MEVN
- 18.10.4. Estratégias para melhorar o desempenho e a segurança de aplicações web com capacidades de IA em ambientes MEVN

Módulo 19. Aplicações móveis com IA

- 19.1. Preparação do Ambiente de Trabalho para o Desenvolvimento Móvel com IA
 - 19.1.1. Configuração de ambientes de desenvolvimento móvel para projetos com Inteligência Artificial
 - 19.1.2. Seleção e preparação de ferramentas específicas para o desenvolvimento de aplicações móveis com IA
 - 19.1.3. Integração de bibliotecas e *frameworks* de IA em ambientes de desenvolvimento móvel
 - 19.1.4. Configuração de emuladores e dispositivos reais para testar aplicações móveis com componentes de inteligência artificial
- 19.2. Criação de um *Workspace* com Github copilot
 - 19.2.1. Integração do GitHub Copilot em ambientes de desenvolvimento móvel
 - 19.2.2. Utilização eficaz do GitHub Copilot para a geração de código em projetos com IA
 - 19.2.3. Estratégias para a colaboração do programador ao utilizar o GitHub Copilot no *workspace*
 - 19.2.4. Boas práticas e limitações no uso do GitHub Copilot no desenvolvimento de aplicações móveis com IA
- 19.3. Configuração do Firebase
 - 19.3.1. Configuração inicial de um projeto Firebase para o desenvolvimento móvel
 - 19.3.2. Integração do Firebase em aplicações móveis com funcionalidades de IA
 - 19.3.3. Utilização dos serviços Firebase, como a base de dados, a autenticação e as notificações em projetos com IA
 - 19.3.4. Estratégias para a gestão de dados e eventos em tempo real em aplicações móveis com o Firebase
- 19.4. Conceitos de Clean Architecture, DataSources, Repositories
 - 19.4.1. Princípios fundamentais de Clean Architecture no desenvolvimento móvel com IA
 - 19.4.2. Implementação das camadas DataSources e Repositories em arquiteturas limpas
 - 19.4.3. Design e estruturação de componentes em projetos móveis com foco em arquitetura limpa
 - 19.4.4. Benefícios e desafios da implementação da *Clean Architecture* aplicações móveis com IA

- 19.5. Criação do Ecrã de Autenticação
 - 19.5.1. Design e desenvolvimento de interfaces de utilizador para ecrãs de autenticação em aplicações móveis com IA
 - 19.5.2. Integração de serviços de autenticação com Firebase no ecrã de início de sessão
 - 19.5.3. Utilização de técnicas de segurança e de proteção de dados no ecrã de autenticação
 - 19.5.4. Personalização e adaptação da experiência do utilizador no ecrã de autenticação
- 19.6. Criação do *Dashboard* e Navegação
 - 19.6.1. Design e desenvolvimento de *Dashboards* com elementos de Inteligência Artificial
 - 19.6.2. Implementação de sistemas de navegação eficientes em aplicações móveis com IA
 - 19.6.3. Integração de funcionalidades de IA no *Dashboard* para melhorar a experiência do utilizador
- 19.7. Criação do Ecrã com Listagem
 - 19.7.1. Desenvolvimento de interfaces de utilizador para ecrãs com listagem em aplicações móveis com IA
 - 19.7.2. Integração de algoritmos de recomendação e filtragem no ecrã de listagem
 - 19.7.3. Utilização de padrões de design para uma apresentação eficaz dos dados da listagem
 - 19.7.4. Estratégias para o carregamento eficaz de dados em tempo real no ecrã de listagem
- 19.8. Criação do Ecrã de Detalhes
 - 19.8.1. Design e desenvolvimento de interfaces de utilizador detalhadas para a apresentação de informações específicas
 - 19.8.2. Integração de funcionalidades de IA para enriquecer o ecrã de detalhes
 - 19.8.3. Implementação de interações e animações no ecrã de detalhes
 - 19.8.4. Estratégias para a otimização do desempenho na visualização e carregamento de detalhes de aplicações móveis com IA
- 19.9. Criação do Ecrã de *Settings*
 - 19.9.1. Desenvolvimento de interfaces de utilizador para configuração e ajustes em aplicações móveis com IA
 - 19.9.2. Integração de definições personalizadas relacionadas com componentes de inteligência artificial
 - 19.9.3. Implementação de opções e preferências de personalização no ecrã de configuração
 - 19.9.4. Estratégias de usabilidade e clareza na apresentação das opções no ecrã de *settings*
- 19.10. Criar Ícones, *Splash* e Recursos Gráficos para a Sua App com IA
 - 19.10.1. Design e criação de ícones atrativos para representar a aplicação móvel com IA
 - 19.10.2. Desenvolvimento de ecrãs iniciais (*splash*) com visuais impactantes

- 19.10.3. Seleção e adaptação de recursos gráficos que melhorem a estética da aplicação móvel
- 19.10.4. Estratégias de coerência e de branding visual nos elementos gráficos da aplicação com IA

Módulo 20. IA para QA Testing

- 20.1. Ciclo de vida do *Testing*
 - 20.1.1. Descrição e compreensão do ciclo de vida do *testing* de desenvolvimento de software
 - 20.1.2. Fases do ciclo de vida do *testing* e a sua importância para a garantia da qualidade
 - 20.1.3. Integração da inteligência artificial nas diferentes fases do ciclo de vida do *testing*
 - 20.1.4. Estratégias de melhoria contínua do ciclo de vida do *testing* através da utilização da IA
- 20.2. Test Cases e Detecção de Bugs
 - 20.2.1. Conceção e redação eficazes de casos de teste no contexto do QA *Testing*
 - 20.2.2. Identificação de bugs e erros durante a execução de casos de teste
 - 20.2.3. Aplicação de técnicas de deteção precoce de erros através de análise estática
 - 20.2.4. Utilização de ferramentas de inteligência artificial para a identificação automática de erros em casos de teste
- 20.3. Tipos de *Testing*
 - 20.3.1. Exploração de diferentes tipos de *testing* no domínio da QA
 - 20.3.2. Testes unitários, de integração, funcionais e de aceitação: características e aplicações
 - 20.3.3. Estratégias para a seleção e combinação adequada de tipos de *testing* em projetos com IA
 - 20.3.4. Adaptação de tipos de *testing* convencionais a projetos com componentes de inteligência artificial
- 20.4. Criar um Plano de Testes
 - 20.4.1. Design e estruturação de um plano de testes abrangente
 - 20.4.2. Identificação de requisitos e cenários de teste em projetos com IA
 - 20.4.3. Estratégias para o planeamento de testes manuais e automatizados
 - 20.4.4. Avaliação e ajuste contínuo do plano de testes de acordo com o desenvolvimento do projeto
- 20.5. Detecção e *Bugs* com IA
 - 20.5.1. Implementação de técnicas de deteção automática de bugs utilizando algoritmos de aprendizagem automática

- 20.5.2. Utilização de ferramentas de inteligência artificial para a análise dinâmica de códigos para procurar eventuais erros
- 20.5.3. Estratégias para a geração automática de relatórios pormenorizados sobre os bugs detetados pela IA
- 20.5.4. Colaboração eficaz entre as equipas de desenvolvimento e de garantia da qualidade na gestão dos erros identificados pela IA
- 20.6. Criação de Testes Automatizados com IA
 - 20.6.1. Desenvolvimento de scripts de testes automatizados para projetos com componentes de inteligência artificial
 - 20.6.2. Integração de ferramentas de automatização de testes baseadas em IA
 - 20.6.3. Utilização de algoritmos de *machine learning* para a geração dinâmica de casos de teste automatizados
 - 20.6.4. Estratégias para a execução eficiente e a manutenção de casos de teste automatizados em projetos com IA
- 20.7. API Testing
 - 20.7.1. Conceitos fundamentais de API testing e sua importância em QA
 - 20.7.2. Desenvolvimento de testes para a verificação de APIs em ambientes com componentes de Inteligência Artificial
 - 20.7.3. Estratégias para validação de dados e resultados em API testing com IA
 - 20.7.4. Utilização de ferramentas específicas para o testing de API em projetos com inteligência artificial
- 20.8. Ferramentas de IA para Web Testing
 - 20.8.1. Exploração de ferramentas de inteligência artificial para automatização de testes em ambientes Web
 - 20.8.2. Integração de tecnologias de reconhecimento de itens e de análise visual em Web testing
 - 20.8.3. Estratégias para a deteção automática de alterações e problemas de desempenho em aplicações Web através da IA
 - 20.8.4. Avaliação de ferramentas específicas para melhorar a eficiência no web testing com IA
- 20.9. Mobile Testing Através de IA
 - 20.9.1. Desenvolvimento de estratégias de testing para aplicações móveis com componentes de inteligência artificial
 - 20.9.2. Integração de ferramentas de testing específicas para plataformas móveis baseadas em IA
 - 20.9.3. Utilização de algoritmos de aprendizagem automática para detetar problemas de desempenho das aplicações móveis
 - 20.9.4. Estratégias para a validação de interfaces e funções específicas de aplicações móveis através da IA
- 20.10. Ferramentas de QA com IA
 - 20.10.1. Exploração de ferramentas e plataformas de GQ que incorporem funcionalidades de Inteligência Artificial
 - 20.10.2. Avaliação de ferramentas para a gestão e execução eficientes de testes em projetos de IA
 - 20.10.3. Utilização de algoritmos de *machine learning* para a geração e otimização de casos de teste
 - 20.10.4. Estratégias para a seleção e adoção eficaz de ferramentas de QA com capacidades de IA



Posicione-se no mercado de trabalho com um Mestrado Próprio 100% online que se adapta às suas necessidades e permite uma aprendizagem imersiva e sólida"

06 Metodologia

Este programa de capacitação oferece uma forma diferente de aprendizagem. A nossa metodologia é desenvolvida através de um modo de aprendizagem cíclico: **o Relearning**. Este sistema de ensino é utilizado, por exemplo, nas escolas médicas mais prestigiadas do mundo e tem sido considerado um dos mais eficazes pelas principais publicações, tais como a **New England Journal of Medicine**.



“

Descubra o Relearning, um sistema que abandona a aprendizagem linear convencional para o levar através de sistemas 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 programa 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 pode experimentar uma forma de aprendizagem que abala as fundações das universidades tradicionais de todo o mundo”



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



Um método de aprendizagem inovador e diferente

Este programa 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, a técnica que constitui a base deste conteúdo, assegura que a realidade económica, social e profissional mais atual é seguida.



O nosso programa prepara-o para enfrentar novos desafios em ambientes incertos e alcançar o sucesso na sua carreira”

O estudante 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 principais escolas de informática do mundo desde que existem. Desenvolvido em 1912 para que os estudantes de direito não só aprendessem 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 programa, 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.

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

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

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

A nossa universidade é a única universidade de língua espanhola 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 do mundo.



No nosso programa, a aprendizagem não é um processo linear, mas acontece numa espiral (aprender, desaprender, esquecer e reaprender). Portanto, cada um destes elementos é combinado de forma concêntrica. Esta metodologia formou mais de 650.000 licenciados com sucesso sem precedentes em áreas tão diversas como a bioquímica, genética, cirurgia, direito internacional, capacidades de gestão, ciência do desporto, filosofia, direito, engenharia, jornalismo, história, 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 das últimas provas científicas 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 do nosso programa estão ligados ao contexto em que o participante desenvolve a sua prática profissional.

Este programa oferece o melhor material educativo, cuidadosamente preparado para profissionais:



Material de estudo

Todos os conteúdos didáticos são criados pelos especialistas que irão ensinar o curso, especificamente para o curso, para que o desenvolvimento didático seja realmente específico e concreto.

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



Masterclasses

Existem provas científicas sobre a utilidade da observação por terceiros especializada.

O denominado Learning from an Expert constrói conhecimento e memória, e gera confiança em futuras decisões difíceis.




Práticas de aptidões e competências


Realizarão 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 necessita de desenvolver no quadro da globalização 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 necessita para completar a sua capacitação.





Case studies

Completarão uma seleção dos melhores estudos de casos escolhidos especificamente para esta situação. Casos apresentados, analisados e instruídos pelos melhores especialistas na cena internacional.



Resumos interativos

A equipa da TECH apresenta os conteúdos de uma forma atrativa e dinâmica em comprimidos 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 uma "História de Sucesso Europeu".



Testing & Retesting

Os conhecimentos do aluno são periodicamente avaliados e reavaliados ao longo de todo o programa, através de atividades e exercícios de avaliação e auto-avaliação, para que o aluno possa verificar como está a atingir os seus objetivos.



07

Certificação

Este programa permitir-lhe-á obter o diploma Mestrado Próprio em Inteligência Artificial na Programação emitido pela TECH Global University, a maior universidade digital do mundo.



“

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 do **Mestrado Próprio em Inteligência Artificial na Programação** 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 de seus mecanismos de garantia de qualidade para fomentar a colaboração e a mobilidade entre alunos, pesquisadores e acadêmicos.




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

Certificação: Mestrado Próprio em Inteligência Artificial na Programação

Modalidade: online

Duração: 12 meses

Créditos: 90 ECTS



futuro
saúde confiança pessoas
informação orientadores
educação certificação ensino
garantia aprendizagem
instituições tecnologia
comunidade compromisso
atenção personalizada
conhecimento inovação
presente qualidade
desenvolvimento situação



Mestrado Próprio Inteligência Artificial na Programação

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

Mestrado Próprio

Inteligência Artificial na Programação