

Mestrado Próprio

Inteligência Artificial na Prática Clínica



Mestrado Próprio Inteligência Artificial na Prática Clínica

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

Acesso ao site: [www.techitute.com/pt/ medicina/mestrado-proprio/mestrado-proprio-inteligencia-artificial-pratica-clinica](http://www.techitute.com/pt/medicina/mestrado-proprio/mestrado-proprio-inteligencia-artificial-pratica-clinica)

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 aplicação da Inteligência Artificial (IA) na Prática Clínica permite a integração de algoritmos avançados e a análise de dados, acelerando e melhorando o diagnóstico médico e identificando padrões subtis que podem passar despercebidos ao olho humano. Para além disso, a IA facilita a previsão de doenças, contribuindo para uma deteção mais precoce e para a implementação de tratamentos preventivos personalizados. Esta tecnologia também melhora a gestão dos dados médicos, permitindo uma assistência mais eficiente e precisa aos pacientes, apoiando simultaneamente a tomada de decisões clínicas informadas através da análise de evidências científicas volumosas. Por estas razões, a TECH desenvolveu um Mestrado Próprio que irá envolver os médicos na tecnologia mais avançada, aproveitando a metodologia revolucionária do *Relearning*.



“

A IA na Prática Clínica promete melhorar a qualidade dos cuidados médicos, reduzir os erros e abrir novos caminhos para a medicina personalizada e a investigação biomédica"

A Inteligência Artificial pode ser aplicada à Prática Médica, ao analisar grandes conjuntos de dados médicos para identificar padrões e tendências e facilitar diagnósticos mais precisos e atempados. Para além disso, na assistência aos pacientes, a IA é capaz de antecipar potenciais complicações, personalizar tratamentos e otimizar a atribuição de recursos, melhorando a eficiência e a qualidade dos cuidados médicos. A automatização de tarefas de rotina também liberta tempo para os profissionais se concentrarem em aspetos mais complexos e humanos dos cuidados, promovendo avanços significativos na medicina.

Por este motivo, a TECH desenvolveu este Mestrado Próprio em Inteligência Artificial na Prática Clínica, com uma abordagem abrangente e especializada. Os módulos específicos englobam, desde o domínio de ferramentas práticas de IA, até à compreensão crítica da sua aplicação ética e legal na medicina. A prioridade dada a aplicações médicas específicas, como o diagnóstico assistido por IA e a gestão da dor, dotará os profissionais de competências e conhecimentos avançados em áreas-chave dos cuidados de saúde.

Será também promovida a colaboração multidisciplinar, preparando os alunos para trabalhar em diferentes equipas em contextos clínicos. E ainda, graças ao seu foco ético, jurídico e de governação, assegurará uma compreensão responsável e uma aplicação prática no desenvolvimento e implementação de soluções de IA nos cuidados de saúde. A combinação de aprendizagem teórica e prática, juntamente com a aplicação do *Big Data* na saúde, permitirá aos clínicos enfrentar os desafios atuais e futuros no campo de uma forma abrangente e competente.

Desta forma, a TECH concebeu um Mestrado Próprio completo, com base na inovadora metodologia *Relearning*, para qualificar especialistas em IA altamente competentes. Esta forma de aprendizagem centra-se na repetição de conceitos-chave para garantir uma compreensão consolidada. Para ter acesso aos conteúdos em qualquer momento, basta um dispositivo eletrónico com ligação à Internet, libertando os participantes de horários fixos ou da obrigação de participar presencialmente.

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

- ♦ O desenvolvimento de casos práticos apresentados por especialistas em Inteligência Artificial na Prática Clínica
- ♦ Os conteúdos gráficos, esquemáticos e eminentemente práticos fornecem informações científicas e práticas 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



A estrutura modular do Mestrado Próprio permitir-lhe-á beneficiar de um progresso coerente desde os fundamentos até às aplicações mais avançadas"

“

Irá aprofundar-se na ciência dos dados de saúde apoiada na IA, explorando a bioestatística e a análise de grandes volumes de dados ao longo de 2 250 horas de conteúdos 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.

Graças a este Mestrado Próprio 100% online, irá analisar a forma como a IA interpreta os dados genéticos para conceber estratégias terapêuticas específicas.

Aplicará a mineração de dados e a aprendizagem automática no contexto da saúde. De que está à espera para se inscrever?



02

Objetivos

O Mestrado Próprio em Inteligência Artificial na Prática Clínica tem como objetivo preparar os profissionais de saúde para transformar os cuidados médicos através da aplicação estratégica da IA. Este Mestrado Próprio inovador dotará os alunos de competências consistentes relativamente à análise de dados médicos, ao diagnóstico assistido por IA, à personalização do tratamento e à gestão eficiente da assistência ao paciente. Após a conclusão da certificação, os especialistas estarão preparados para liderar a mudança, melhorando a precisão do diagnóstico, otimizando os protocolos de tratamento e promovendo cuidados médicos mais acessíveis e eficazes.



“

A TECH irá dotá-lo para transformar a prática clínica, melhorar o diagnóstico e conceber tratamentos precisos e personalizados”



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 no desenvolvimento de sistemas inteligentes
- ♦ Analisar as estratégias de Inteligência Artificial atuais em vários domínios, identificando oportunidades e desafios
- ♦ Avaliar de forma crítica os benefícios e as limitações da IA nos cuidados de saúde, identificando possíveis erros e fornecendo uma avaliação informada da sua aplicação clínica
- ♦ Reconhecer a importância da colaboração entre disciplinas para desenvolver soluções de IA eficazes
- ♦ Adotar uma perspectiva abrangente das tendências emergentes e das inovações tecnológicas no domínio da IA aplicada à saúde
- ♦ Adquirir conhecimentos sólidos sobre a aquisição, a filtragem e o pré-processamento de dados médicos
- ♦ Compreender os princípios éticos e a regulamentação legislativa aplicáveis à implementação da IA na medicina, promovendo práticas éticas, equidade e transparência





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
- ♦ Afinar hiperparâmetros para o *Fine Tuning* de redes neuronais, melhorando 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
- ♦ Explore o projeto *TensorFlow Datasets* para acessar 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
- ♦ 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 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 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. Diagnóstico na prática clínica através da IA

- ♦ Analisar de forma crítica os benefícios e as limitações da IA na saúde
- ♦ Identificar possíveis erros, fornecendo uma avaliação informada da sua aplicação em contextos clínicos
- ♦ Reconhecer a importância da colaboração entre disciplinas para desenvolver soluções de IA eficazes
- ♦ Desenvolver competências para aplicar ferramentas de IA no contexto clínico, centrando-se em aspetos como o diagnóstico assistido, a análise de imagens médicas e a interpretação de resultados
- ♦ Identificar possíveis erros para a aplicação da IA na saúde, fornecendo uma visão informada da sua utilização em contextos clínicos

Módulo 17. Tratamento e controlo do paciente com IA

- ♦ Interpretar os resultados para a criação ética de *datasets* e a aplicação estratégica em emergências de saúde
- ♦ Adquirir competências avançadas na apresentação, visualização e gestão de dados de IA na saúde
- ♦ Adotar uma perspetiva abrangente das tendências emergentes e das inovações tecnológicas no domínio da IA aplicada à saúde
- ♦ Desenvolver algoritmos de IA para aplicações específicas, como a monitorização da saúde, facilitando a implementação eficaz de soluções na prática médica
- ♦ Conceber e implementar tratamentos médicos individualizados através da análise dos dados clínicos e genómicos dos pacientes com IA

Módulo 18. Personalização da saúde através da IA

- ♦ Aprofundar as tendências emergentes da IA aplicada à saúde personalizada e o seu impacto futuro
- ♦ Definir as aplicações da IA para personalizar tratamentos médicos, abrangendo desde a análise genómica até à gestão da dor
- ♦ Diferenciar algoritmos específicos de IA para o desenvolvimento de aplicações relacionadas com a conceção de medicamentos ou a robótica cirúrgica
- ♦ Delinear as tendências emergentes no domínio da IA aplicada aos cuidados de saúde personalizados e o seu impacto futuro
- ♦ Promover a inovação através da criação de estratégias destinadas a melhorar os cuidados médicos

Módulo 19. Análise de *Big Data* no setor da saúde com IA

- ♦ Adquirir conhecimentos sólidos sobre a recolha, a filtragem e o pré-processamento de dados médicos
- ♦ Desenvolver uma abordagem clínica baseada na qualidade e integridade dos dados no contexto dos regulamentos relativos à privacidade
- ♦ Aplicar os conhecimentos adquiridos em casos de utilização e aplicações práticas, permitindo compreender e resolver desafios específicos do setor, desde a análise de texto à visualização de dados e à segurança da informação médica
- ♦ Definir técnicas de *Big Data* específicas para setor da saúde, incluindo a aplicação de algoritmos de aprendizagem automática para análise
- ♦ Empregar procedimentos de *Big Data* para rastrear e monitorizar a propagação de doenças infecciosas em tempo real para uma resposta eficaz a epidemias

Módulo 20. Ética e regulamentação na IA médica

- ♦ Compreender os princípios éticos fundamentais e a regulamentação aplicável à implementação da IA na medicina
- ♦ Dominar os princípios da governação de dados
- ♦ Compreender os quadros regulamentares internacionais e locais
- ♦ Assegurar a conformidade regulamentar na utilização de dados e ferramentas de IA no setor da saúde
- ♦ Desenvolver competências para conceber sistemas de IA centrados no ser humano, promovendo a equidade e a transparência na aprendizagem automática



Torne-se um líder na integração de tecnologias inovadoras nos cuidados de saúde, melhorando o diagnóstico, o tratamento e a experiência do paciente"

03

Competências

O Mestrado Próprio em Inteligência Artificial na Prática Clínica ajudará os profissionais a dominar as competências essenciais para se prepararem para a convergência da medicina e da tecnologia. Desde a análise avançada de dados médicos até à implementação estratégica de algoritmos para diagnósticos precisos, este Mestrado Próprio reforçará as competências dos alunos na personalização de tratamentos e na otimização dos cuidados médicos, permitindo-lhes inovar e liderar a mudança na medicina com visão e excelência.



“

*Aperfeiçoe as suas competências com TECH!
Irá desenvolver as suas capacidades de análise
de dados médicos, de diagnóstico assistido por
IA e de personalização de tratamentos”*



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 de Inteligência Artificial
- ♦ Implementar uma rede codificadora-descodificadora para tradução automática neuronal
- ♦ Aplicar os princípios fundamentais das redes neurais na resolução de problemas específicos
- ♦ Implementar ferramentas de IA em contextos clínicos, com incidência no diagnóstico assistido, na análise de imagens médicas e nos resultados da modelização da IA
- ♦ Aplicar algoritmos de IA para personalizar tratamentos médicos, abrangendo desde a análise genómica até à gestão da dor
- ♦ Adquirir competências avançadas na apresentação, visualização e gestão de dados de IA na saúde
- ♦ Desenvolver algoritmos de IA para aplicações específicas em medicina, como a conceção de medicamentos, a monitorização da saúde e a robótica cirúrgica
- ♦ Utilizar técnicas de *Big Data* específicas para a saúde, incluindo o processamento de texto, a avaliação da qualidade e a aplicação de algoritmos de aprendizagem automática





Competências específicas

- ♦ Aplicar técnicas e estratégias de IA para melhorar a eficiência no setor do retail
- ♦ 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 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 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 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 precisão da informação utilizada nas análises posteriores
- ♦ Aplicar ferramentas de IA no contexto clínico, com destaque no diagnóstico assistido, na análise de imagens médicas e na interpretação de resultados de modelos de IA
- ♦ Aplicar e avaliar algoritmos de IA em contextos médicos reais
- ♦ Utilizar IA para personalizar tratamentos médicos, desde a análise genómica até à gestão da dor
- ♦ Utilizar algoritmos de IA para aplicações específicas, como a conceção de medicamentos, a monitorização da saúde e a robótica cirúrgica
- ♦ Dominar técnicas de Big Data específicas para setor da saúde, incluindo processamento de texto, avaliação da qualidade e aplicação de algoritmos de aprendizagem automática para personalização e análise
- ♦ Conceber sistemas de IA centrados no ser humano, promovendo a equidade e a transparência na aprendizagem automática e garantindo a segurança e a qualidade dos modelos através de políticas e avaliações abrangentes

04

Direção do curso

Mestrado Próprio em Inteligência Artificial na Prática Clínica reúne especialistas de renome na área da medicina e da tecnologia, oferecendo uma perspectiva excepcionalmente abrangente e atualizada. Estes profissionais possuem não só um conhecimento exaustivo em IA aplicada à prática clínica, mas também uma vasta experiência prática no desenvolvimento e implementação de soluções inovadoras em contextos médicos. A sua dedicação à excelência educativa garantirá que os alunos adquiram não só conhecimentos teóricos, mas também uma compreensão prática aprofundada.



“

Aprenda com os melhores! O corpo docente irá prepará-lo para enfrentar os desafios atuais e futuros dos cuidados de saúde"

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



Dr. Fernando Martín-Palomino Sahagún

- ♦ Engenheiro de Telecomunicações
- ♦ *Chief Technology Officer* e R+D+i Diretor na AURA Diagnostics (medTech)
- ♦ Desenvolvimento de Negócios na SARLIN
- ♦ Diretor de Operações na Alliance Diagnósticos
- ♦ Diretor de Inovação na Alliance Medical
- ♦ *Chief Information Officer* na Alliance Medical
- ♦ *Field engineer & Project Management* em Radiologia Digital na Kodak
- ♦ MBA pela Universidade Politécnica de Madrid
- ♦ *Executive Master* em Marketing e Vendas pela ESADE
- ♦ Engenheiro Superior de Telecomunicações da Universidade Alfonso X El Sabio

Professores

Doutor Ramón Alberto Carrasco González

- ♦ Especialista em Informática e Inteligência Artificial
- ♦ Investigador
- ♦ Responsável de Business Intelligence (Marketing) na Caja General de Ahorros de Granada e no Banco Mare Nostrum
- ♦ Responsável de Sistemas de Informação (Data Warehousing e Business Intelligence) na Caja General de Ahorros de Granada e no Banco Mare Nostrum
- ♦ Doutoramento em Inteligência Artificial pela Universidade de Granada
- ♦ Engenheiro Superior em Informática pela Universidade de Granada

Dr. Daniel Vasile Popescu Radu

- ♦ Especialista em Farmacologia, Nutrição e Dieta
- ♦ Produtor Freelancer de Conteúdos Didáticos e Científicos
- ♦ Nutricionista e Dietista Comunitário
- ♦ Farmacêutico Comunitário
- ♦ Investigador
- ♦ Mestrado em Nutrição e Saúde pela Universidade Oberta da Catalunha (UOC)
- ♦ Mestrado em Psicofarmacologia pela Universidade de Valência
- ♦ Farmacêutico pela Universidade Complutense de Madrid
- ♦ Nutricionista-Dietista pela Universidade Europeia Miguel de Cervantes

05

Estrutura e conteúdo

Este Mestrado Próprio foi cuidadosamente concebido para aliar a excelência clínica à inovação tecnológica. A sua estrutura baseia-se em módulos especializados, que vão desde os fundamentos da IA até às aplicações específicas em ambientes médicos. Assim, os conteúdos oferecerão um equilíbrio perfeito entre a teoria avançada e a aplicação prática, permitindo que os profissionais abordem tudo, desde a análise de dados até à personalização de tratamentos. Desta forma, os alunos estarão preparados para fazer a diferença na medicina, com uma visão progressista e sólidas aptidões técnicas.





“

Atualize a sua prática clínica diária para estar ao corrente da revolução tecnológica na saúde, contribuindo para o avanço da Prática Clínica"

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 Neurais
 - 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 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 neuronais
- 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 neuronais 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 neuronais profundas
- 13.9. Redes generativas antagónicas 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 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 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. Diagnóstico na prática clínica através da IA

- 16.1. Tecnologias e ferramentas para o diagnóstico assistido por IA
 - 16.1.1. Desenvolvimento de software para o diagnóstico assistido por IA em várias especialidades médicas
 - 16.1.2. Utilização de algoritmos avançados para a análise rápida e precisa de sinais e sintomas clínicos
 - 16.1.3. Integração da IA em dispositivos de diagnóstico para melhorar a eficiência
 - 16.1.4. Ferramentas de IA para ajudar na interpretação dos resultados dos testes laboratoriais
- 16.2. Integração de dados clínicos multimodais para o diagnóstico
 - 16.2.1. Sistemas de IA para combinar dados de imagiologia, laboratoriais e de registros clínicos
 - 16.2.2. Ferramentas para correlacionar dados multimodais em diagnósticos mais precisos
 - 16.2.3. Utilização da IA para analisar padrões complexos de diferentes tipos de dados clínicos
 - 16.2.4. Integração de dados genômicos e moleculares no diagnóstico assistido por IA
- 16.3. Criação e análise de *datasets* de saúde com IA
 - 16.3.1. Desenvolvimento de bases de dados clínicas para treino de modelos de IA
 - 16.3.2. Utilização da IA para a análise e extração de *insights* de grandes *datasets* de saúde
 - 16.3.3. Ferramentas de IA para limpeza e preparação de dados clínicos
 - 16.3.4. Sistemas de IA para identificar tendências e padrões nos dados de saúde
- 16.4. Visualização e gestão de dados de saúde com IA
 - 16.4.1. Ferramentas de IA para a visualização interativa e compreensível dos dados de saúde
 - 16.4.2. Sistemas de IA para a gestão eficiente de grandes volumes de dados clínicos
 - 16.4.3. Utilização de *dashboards* baseados em IA para monitorizar indicadores de saúde
 - 16.4.4. Tecnologias de IA para a gestão e segurança de dados de saúde
- 16.5. Reconhecimento de padrões e *machine learning* em diagnósticos clínicos
 - 16.5.1. Aplicação de técnicas de *machine learning* para o reconhecimento de padrões em dados clínicos
 - 16.5.2. Utilização da IA na identificação precoce de doenças através da análise de padrões
 - 16.5.3. Desenvolvimento de modelos preditivos para diagnósticos mais precisos
 - 16.5.4. Implementação de algoritmos de aprendizagem automática na interpretação de dados de saúde
- 16.6. Interpretação de imagens médicas através de IA
 - 16.6.1. Sistemas de IA para detecção e classificação de anomalias em imagens médicas
 - 16.6.2. Utilização de aprendizagem profunda na interpretação de radiografias, ressonâncias magnéticas e tomografias computadorizadas
 - 16.6.3. Ferramentas de IA para melhorar a exatidão e a rapidez do diagnóstico por imagens
 - 16.6.4. Implementação da IA para a assistência na tomada de decisões clínicas com base em imagens
- 16.7. Processamento de linguagem natural em registros médicos para o diagnóstico clínico
 - 16.7.1. Utilização de PNL para a extração de informação relevante de registros médicos
 - 16.7.2. Sistemas de IA para análise de notas médicas e relatórios de pacientes
 - 16.7.3. Ferramentas de IA para resumir e classificar informações de registros médicos
 - 16.7.4. Aplicação da PNL na identificação de sintomas e diagnósticos a partir de textos clínicos
- 16.8. Validação e avaliação de modelos de diagnóstico assistidos por IA
 - 16.8.1. Métodos de validação e teste de modelos de IA em contextos clínicos reais
 - 16.8.2. Avaliação do desempenho e da exatidão das ferramentas de diagnóstico assistido por IA
 - 16.8.3. Utilização da IA para garantir a fiabilidade e a ética no diagnóstico clínico
 - 16.8.4. Implementação de protocolos de avaliação contínua para sistemas de IA na saúde
- 16.9. IA no diagnóstico de doenças raras
 - 16.9.1. Desenvolvimento de sistemas de IA especializados para a identificação de doenças raras
 - 16.9.2. Utilização da IA para a análise de padrões atípicos e sintomatologia complexa
 - 16.9.3. Ferramentas de IA para o diagnóstico precoce e exato de doenças raras
 - 16.9.4. Implementação de bases de dados globais com recurso à IA para melhorar o diagnóstico de doenças raras
- 16.10. Casos de sucesso e desafios na implementação de diagnósticos com IA
 - 16.10.1. Análise de estudos de casos em que a IA melhorou significativamente o diagnóstico clínico
 - 16.10.2. Avaliação dos desafios na adoção da IA em contextos clínicos
 - 16.10.3. Discussão dos obstáculos éticos e práticos à implementação da IA no diagnóstico
 - 16.10.4. Análise de estratégias para ultrapassar os obstáculos à integração da IA no diagnóstico médico

Módulo 17. Tratamento e controlo do paciente com IA

- 17.1. Sistemas de tratamento assistido por IA
 - 17.1.1. Desenvolvimento de sistemas de IA para ajudar na tomada de decisões terapêuticas
 - 17.1.2. Utilização da IA para a personalização dos tratamentos com base em perfis individuais
 - 17.1.3. Implementação de ferramentas de IA na administração de dosagens e horários de medicação
 - 17.1.4. Integração da IA na monitorização e no ajuste de tratamentos em tempo real
- 17.2. Definição de indicadores para o controlo do estado de saúde do paciente
 - 17.2.1. Estabelecimento de parâmetros-chave através da IA para o acompanhamento da saúde do paciente
 - 17.2.2. Utilização da IA para identificar indicadores preditivos de saúde e de doença
 - 17.2.3. Desenvolvimento de sistemas de alerta precoce com base em indicadores de saúde
 - 17.2.4. Implementação de IA para de avaliação contínua do estado de saúde do paciente
- 17.3. Ferramentas de monitorização e controlo dos indicadores de saúde
 - 17.3.1. Desenvolvimento de aplicações móveis e wearables com IA para monitorização da saúde
 - 17.3.2. Implementação de sistemas de IA para análise em tempo real de dados de saúde
 - 17.3.3. Utilização de *dashboards* baseados em IA para visualização e indicadores de saúde
 - 17.3.4. Integração de dispositivos IoT na monitorização contínua de indicadores de saúde com IA
- 17.4. IA no Planeamento e Execução de Procedimentos Médicos
 - 17.4.1. Utilização de sistemas de IA para otimizar o planeamento de cirurgias e procedimentos médicos
 - 17.4.2. Implementação da IA na simulação e prática de procedimentos cirúrgicos
 - 17.4.3. Utilização da IA para melhorar a exatidão e a eficiência na execução de procedimentos médicos
 - 17.4.4. Aplicação da IA na coordenação e gestão de recursos cirúrgicos
- 17.5. Algoritmos de aprendizagem automática para o estabelecimento de tratamentos terapêuticos
 - 17.5.1. Utilização da *machine learning* para desenvolver protocolos de tratamento personalizados
 - 17.5.2. Implementação de algoritmos preditivos para a seleção de terapias eficazes
 - 17.5.3. Desenvolvimento de sistemas de IA para a adaptação de tratamentos em tempo real
 - 17.5.4. Aplicação da IA na análise da eficácia de diferentes opções terapêuticas
- 17.6. Adaptabilidade e atualização contínua dos protocolos terapêuticos através da IA
 - 17.6.1. Implementação de sistemas de IA para revisão e atualização dinâmica de tratamentos
 - 17.6.2. Utilização da IA na adaptação dos protocolos terapêuticos a novas descobertas e dados
 - 17.6.3. Desenvolvimento de ferramentas de IA para a personalização contínua dos tratamentos
 - 17.6.4. Integração da IA na resposta adaptativa à evolução das condições do paciente
- 17.7. Otimizar os serviços de saúde com tecnologia de IA
 - 17.7.1. Utilização da IA para melhorar a eficiência e a qualidade dos serviços de saúde
 - 17.7.2. Implementação de sistemas de IA para a gestão dos recursos de saúde
 - 17.7.3. Desenvolvimento de ferramentas de IA para a otimização dos fluxos de trabalho em hospitais
 - 17.7.4. Aplicação da IA na redução do tempo de espera e na melhoria dos cuidados prestados ao paciente
- 17.8. Aplicação de IA na resposta a emergências de saúde
 - 17.8.1. Implementação de sistemas de IA para a gestão rápida e eficiente de situações críticas de saúde
 - 17.8.2. Utilização da IA na otimização da atribuição de recursos em emergências
 - 17.8.3. Desenvolvimento de ferramentas de IA para a previsão e resposta a surtos de doenças
 - 17.8.4. Integração da IA nos sistemas de alerta e comunicação durante as emergências sanitárias
- 17.9. Colaboração interdisciplinar em tratamentos assistidos por IA
 - 17.9.1. Incentivo à colaboração entre diferentes especialidades médicas utilizando sistemas de IA
 - 17.9.2. Utilização da IA para integrar conhecimentos e competências de diferentes disciplinas no tratamento
 - 17.9.3. Desenvolvimento de plataformas de IA para facilitar a comunicação e a coordenação interdisciplinares
 - 17.9.4. Implementação da IA na criação de equipas de tratamento multidisciplinares
- 17.10. Experiências bem-sucedidas de IA no tratamento de doenças
 - 17.10.1. Análise de casos de sucesso na utilização da IA para tratamentos eficazes de doenças
 - 17.10.2. Avaliação do impacto da IA na melhoria dos resultados dos tratamentos

- 17.10.3. Documentação de experiências inovadoras na utilização da IA em diferentes áreas médicas
- 17.10.4. Discussão sobre os avanços e desafios na implementação da IA em tratamentos médicos

Módulo 18. Personalização da saúde através da IA

- 18.1. Aplicações de IA em genómica para medicina personalizada
 - 18.1.1. Desenvolvimento de algoritmos de IA para a análise de sequências genéticas e sua relação com doenças
 - 18.1.2. Utilização da IA na identificação de marcadores genéticos para tratamentos personalizados
 - 18.1.3. Implementação da IA para uma interpretação rápida e precisa dos dados genómicos
 - 18.1.4. Ferramentas de IA para correlacionar genótipos com respostas a medicamentos
- 18.2. IA na farmacogenómica e na conceção de medicamentos
 - 18.2.1. Desenvolvimento de modelos de IA para prever a eficácia e a segurança dos medicamentos
 - 18.2.2. Utilização da IA na identificação de alvos e na conceção de medicamentos
 - 18.2.3. Aplicação da IA na análise das interações gene-fármaco para a personalização de tratamentos
 - 18.2.4. Implementação de algoritmos de IA para acelerar a descoberta de medicamentos
- 18.3. Monitorização personalizada com dispositivos inteligentes e IA
 - 18.3.1. Desenvolvimento de wearables com IA para monitorização contínua de indicadores de saúde
 - 18.3.2. Utilização da IA na interpretação dos dados recolhidos pelos dispositivos inteligentes
 - 18.3.3. Implementação de sistemas de alerta precoce com base em IA de saúde
 - 18.3.4. Ferramentas de IA para personalização do estilo de vida e recomendações de saúde
- 18.4. Sistemas de apoio a decisões clínicas com IA
 - 18.4.1. Implementação de IA para assistir os médicos na tomada de decisões clínicas
 - 18.4.2. Desenvolvimento de sistemas de IA que forneçam recomendações baseadas em dados clínicos
 - 18.4.3. Utilização da IA na avaliação do risco/benefício de diferentes opções terapêuticas
 - 18.4.4. Ferramentas de IA para a integração e a análise de dados de saúde em tempo real
- 18.5. Tendências na personalização da saúde com IA
 - 18.5.1. Análise das últimas tendências em IA para a personalização do cuidado da saúde
 - 18.5.2. Utilização da IA no desenvolvimento de abordagens preventivas e preditivas na saúde
 - 18.5.3. Aplicação da IA na adaptação dos planos de saúde às necessidades individuais
 - 18.5.4. Exploração de novas tecnologias de IA no domínio da saúde personalizada
- 18.6. Avanços na robótica cirúrgica assistida por IA
 - 18.6.1. Desenvolvimento de robôs cirúrgicos com IA para procedimentos precisos e minimamente invasivos
 - 18.6.2. Utilização da IA para melhorar a precisão e a segurança na cirurgia assistida por robôs 18.6.3.
 - 18.6.3. Implementação de sistemas de IA para o planeamento cirúrgico e a simulação de operações
 - 18.6.4. Avanços na integração do *feedback* tátil e visual na robótica cirúrgica com IA
- 18.7. Desenvolvimento de modelos preditivos para a prática clínica personalizada
 - 18.7.1. Utilização da IA para modelos preditivos de doenças com base em dados individuais
 - 18.7.2. Aplicação da IA na previsão de respostas a tratamentos
 - 18.7.3. Desenvolvimento de ferramentas de IA para a antecipação de riscos para a saúde
 - 18.7.4. Aplicação da modelização preditiva no planeamento de intervenções preventivas
- 18.8. IA na gestão e tratamento personalizados da dor
 - 18.8.1. Desenvolvimento de sistemas de IA para a avaliação e gestão personalizada da dor
 - 18.8.2. Utilização da IA na identificação de padrões de dor e respostas a tratamentos
 - 18.8.3. Implementação de ferramentas de IA na personalização de terapias para a dor
 - 18.8.4. Implementação de ferramentas de IA na personalização da terapia da dor
- 18.9. Autonomia do Paciente e Participação Ativa na Personalização
 - 18.9.1. Promoção da autonomia do paciente através de ferramentas de IA para a gestão da sua saúde
 - 18.9.2. Desenvolvimento de sistemas de IA que capacitem os pacientes para a tomada de decisões
 - 18.9.3. Utilização da IA para fornecer informação e educação personalizadas aos pacientes
 - 18.9.4. Ferramentas de IA que facilitem a participação ativa do paciente no seu tratamento
- 18.10. Integração da IA nos registos médicos eletrónicos
 - 18.10.1. Implementação de IA para a análise e gestão eficiente dos registos de saúde eletrónicos
 - 18.10.2. Desenvolvimento de ferramentas de IA para a extração de *insights* clínicos dos registos eletrónicos
 - 18.10.3. Utilização da IA para melhorar a exatidão e a acessibilidade dos dados nos registos médicos

- 18.10.4. Aplicação da IA para correlacionar dados de registos médicos com planos de tratamento

Módulo 19. Análise de *Big Data* no setor da saúde com IA

- 19.1. Fundamentos de *Big Data* na saúde
 - 19.1.1. A explosão do dado na área da saúde
 - 19.1.2. Conceito de *Big Data* e ferramentas principais
 - 19.1.3. Aplicações do *Big Data* na saúde
- 19.2. Processamento e análise de textos em dados de saúde
 - 19.2.1. Conceito de processamento de linguagem natural
 - 19.2.2. Técnicas de *embedding*
 - 19.2.3. Aplicação do processamento de linguagem natural na saúde
- 19.3. Métodos avançados de recuperação de dados de saúde
 - 19.3.1. Exploração de técnicas inovadoras para uma recuperação eficiente de dados na saúde
 - 19.3.2. Desenvolvimento de estratégias avançadas para a extração e organização da informação em contextos de saúde
 - 19.3.3. Implementação de métodos de extração de dados adaptáveis e personalizados para vários contextos clínicos
- 19.4. Avaliação da qualidade na análise de dados de saúde
 - 19.4.1. Desenvolvimento de indicadores para uma avaliação rigorosa da qualidade dos dados em contextos de saúde
 - 19.4.2. Implementação de ferramentas e protocolos para garantir a qualidade dos dados utilizados nas análises clínicas
 - 19.4.3. Avaliação contínua da precisão e da fiabilidade dos resultados em projetos de análise de dados de saúde
- 19.5. Mineração de dados e aprendizagem automática na saúde
 - 19.5.1. Principais metodologias para a mineração de dados
 - 19.5.2. Integração de dados de saúde
 - 19.5.3. Detecção de padrões e anomalias em dados de saúde
- 19.6. Áreas inovadoras de *Big Data* e IA na saúde
 - 19.6.1. Exploração de novas fronteiras na aplicação de *Big Data* e IA para transformar o setor da saúde
 - 19.6.2. Identificação de oportunidades inovadoras para a integração das tecnologias de *Big Data* e de IA nas práticas médicas

- 19.6.3. Desenvolvimento de abordagens inovadoras para maximizar o potencial de *Big Data* e IA nos cuidados de saúde
- 19.7. Recolha e pré-processamento de dados médicos
 - 19.7.1. Desenvolvimento de metodologias eficientes para a recolha de dados médicos em contextos clínicos e de investigação
 - 19.7.2. Aplicação de técnicas avançadas de pré-tratamento para otimizar a qualidade e a utilidade dos dados médicos
 - 19.7.3. Conceção de estratégias de recolha e pré-processamento que garantam a confidencialidade e a privacidade da informação médica
- 19.8. Visualização e comunicação de dados na saúde
 - 19.8.1. Conceção de ferramentas inovadoras de visualização na saúde
 - 19.8.2. Estratégias criativas de comunicação na área da saúde
 - 19.8.3. Integração de tecnologias interativas na saúde
- 19.9. Segurança e governação dos dados no setor da saúde
 - 19.9.1. Desenvolvimento de estratégias globais de segurança dos dados para proteger a confidencialidade e a privacidade no setor da saúde
 - 19.9.2. Implementação de quadros de administração eficazes para garantir uma gestão ética e responsável dos dados em ambientes médicos
 - 19.9.3. Conceção de políticas e procedimentos para garantir a integridade e a disponibilidade de dados médicos, abordando desafios específicos do setor da saúde
- 19.10. Aplicações práticas de *Big Data* na saúde
 - 19.10.1. Desenvolvimento de soluções especializadas para gerir e analisar grandes conjuntos de dados em contextos de saúde
 - 19.10.2. Utilização de ferramentas práticas baseadas em *Big Data* para apoiar a tomada de decisões clínicas
 - 19.10.3. Aplicação de abordagens inovadoras de *Big Data* para enfrentar desafios específicos no setor da saúde

Módulo 20. Ética e regulamentação na IA médica

- 20.1. Princípios éticos na utilização da IA em medicina
 - 20.1.1. Análise e adoção de princípios éticos no desenvolvimento e utilização de sistemas de IA médica
 - 20.1.2. Integração de valores éticos na tomada de decisões assistida por IA em contextos médicos

- 20.1.3. Estabelecimento de diretrizes éticas para garantir uma utilização responsável da inteligência artificial na medicina
- 20.2. Privacidade dos dados e consentimento em contextos médicos
 - 20.2.1. Desenvolvimento de políticas de privacidade para proteger dados sensíveis em aplicações de IA médica
 - 20.2.2. Assegurar o consentimento informado na recolha e utilização de dados pessoais no contexto médico
 - 20.2.3. Implementação de medidas de segurança para salvaguardar a privacidade dos pacientes em ambientes de IA médica
- 20.3. Ética na investigação e desenvolvimento de sistemas de IA médica
 - 20.3.1. Avaliação ética dos protocolos de investigação no desenvolvimento de sistemas de IA para a saúde
 - 20.3.2. Garantia de transparência e rigor ético nas fases de desenvolvimento e validação dos sistemas de IA médica
 - 20.3.3. Considerações éticas na publicação e partilha de resultados no domínio da IA médica
- 20.4. Impacto social e responsabilidade em IA para a saúde
 - 20.4.1. Análise do impacto social da IA na prestação de serviços de saúde
 - 20.4.2. Desenvolvimento de estratégias de atenuação dos riscos e de responsabilidade ética nas aplicações da IA na medicina
 - 20.4.3. Avaliação contínua do impacto social e adaptação dos sistemas de IA para contribuir positivamente para a saúde pública
- 20.5. Desenvolvimento sustentável de IA no setor saúde
 - 20.5.1. Integração de práticas sustentáveis no desenvolvimento e manutenção dos sistemas de IA na saúde
 - 20.5.2. Avaliação do impacto ambiental e económico das tecnologias de IA no setor da saúde
 - 20.5.3. Desenvolvimento de modelos de negócio sustentáveis para assegurar a continuidade e a melhoria das soluções de IA no setor da saúde
- 20.6. Governação dos dados e quadros regulamentares internacionais para a IA médica
 - 20.6.1. Desenvolvimento de quadros de governação para a gestão ética e eficiente dos dados em aplicações de IA médica
 - 20.6.2. Adaptação às normas e regulamentos internacionais para garantir a conformidade ética e jurídica
 - 20.6.3. Participação ativa em iniciativas internacionais para estabelecer normas éticas no desenvolvimento de sistemas de IA médica
- 20.7. Aspetos económicos da IA no âmbito da saúde
 - 20.7.1. Análise das implicações económicas e de custo-benefício na implementação de sistemas de IA na saúde
 - 20.7.2. Desenvolvimento de modelos de negócio e financiamento para facilitar a adoção de tecnologias de IA no setor da saúde
 - 20.7.3. Avaliação da eficiência económica e da equidade no acesso a serviços de saúde baseados na IA
- 20.8. Design de sistemas de IA médica centrado no ser humano
 - 20.8.1. Integração de princípios de design centrados no ser humano para melhorar a usabilidade e a aceitação dos sistemas de IA médica
 - 20.8.2. Participação dos profissionais de saúde e dos pacientes no processo de conceção para garantir a pertinência e a eficácia das soluções
 - 20.8.3. Avaliação contínua da experiência do utilizador e do feedback para otimizar a interação com os sistemas de IA em contextos médicos
- 20.9. Equidade e transparência na aprendizagem automática médica
 - 20.9.1. Desenvolvimento de modelos de aprendizagem automática médica que promovam a equidade e a transparência
 - 20.9.2. Implementação de práticas para atenuar os preconceitos e garantir a equidade na aplicação de algoritmos de IA no âmbito da saúde
 - 20.9.3. Avaliação contínua da equidade e da transparência no desenvolvimento e na implantação de soluções de aprendizagem automática na medicina
- 20.10. Segurança e política na implementação da IA na medicina
 - 20.10.1. Desenvolvimento de políticas de segurança para proteger a integridade e a confidencialidade dos dados em aplicações de IA médica
 - 20.10.2. Implementação de medidas de segurança na implantação de sistemas de IA para prevenir riscos e garantir a segurança do paciente
 - 20.10.3. Avaliação contínua das políticas de segurança para se adaptar aos avanços tecnológicos e aos novos desafios na aplicação da IA médica

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”

Na TECH utilizamos o Método de Caso

Numa dada situação, o que deve fazer um profissional? Ao longo do programa, os estudantes serão confrontados com múltiplos casos clínicos simulados com base em pacientes reais nos quais terão de investigar, estabelecer hipóteses e finalmente resolver a situação. Há abundantes provas científicas sobre a eficácia do método. Os especialistas aprendem melhor, mais depressa e de forma mais sustentável ao longo do tempo.

Com a TECH pode experimentar uma forma de aprendizagem que abala as fundações das universidades tradicionais de todo o mundo.



Segundo o Dr. Gérvas, o caso clínico é a apresentação anotada de um paciente, ou grupo de pacientes, que se torna um "caso", um exemplo ou modelo que ilustra alguma componente clínica peculiar, quer pelo seu poder de ensino, quer pela sua singularidade ou raridade. É essencial que o caso seja fundamentado na vida profissional actual, tentando recriar as condições reais da prática profissional do médico.

“

Sabia que este método foi desenvolvido em 1912 em Harvard para estudantes de direito? O método do caso consistia em apresentar situações reais complexas para que tomassem decisões e justificassem a forma de as resolver. Em 1924 foi estabelecido como um método de ensino padrão em Harvard”

A eficácia do método é justificada por quatro realizações fundamentais:

- 1 Os estudantes que seguem este método não só conseguem a assimilação de conceitos, mas também desenvolvem a sua capacidade mental através de exercícios para avaliar situações reais e aplicar os seus conhecimentos.
- 2 A aprendizagem é solidamente traduzida em competências práticas que permitem ao educador integrar melhor o conhecimento na prática diária.
- 3 A assimilação de ideias e conceitos é facilitada e mais eficiente, graças à utilização de situações que surgiram a partir de um ensino real.
- 4 O sentimento de eficiência do esforço investido torna-se um estímulo muito importante para os estudantes, o que se traduz num maior interesse pela aprendizagem e num aumento do tempo passado a trabalhar no curso.



Relearning Methodology

A TECH combina eficazmente a metodologia do Estudo de Caso com um sistema de aprendizagem 100% online baseado na repetição, que combina 8 elementos didáticos diferentes em cada lição.

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

O profissional aprenderá através de casos reais e da resolução de situações complexas em ambientes de aprendizagem simulados. Estas simulações são desenvolvidas utilizando software de última geração para facilitar a aprendizagem imersiva.



Na vanguarda da pedagogia mundial, o método Relearning conseguiu melhorar os níveis globais de satisfação dos profissionais que concluem os seus estudos, no que diz respeito aos indicadores de qualidade da melhor universidade online do mundo (Universidade de Columbia).

Utilizando esta metodologia, mais de 250.000 médicos foram formados com sucesso sem precedentes em todas as especialidades clínicas, independentemente da carga cirúrgica. 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.

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.

A pontuação global do nosso sistema de aprendizagem é de 8,01, de acordo com os mais elevados padrões internacionais.

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.



Técnicas cirúrgicas e procedimentos em vídeo

A TECH traz as técnicas mais inovadoras, com os últimos avanços educacionais, para a vanguarda da atualidade em enfermagem. Tudo isto, na primeira pessoa, com o máximo rigor, explicado e detalhado para a assimilação e compreensão do estudante.

E o melhor de tudo, pode observá-los quantas vezes quiser.



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".



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.





07

Certificação

Este programa permitir-lhe-á obter o diploma Mestrado Próprio em Inteligência Artificial na Prática Clínica 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 Prática Clínica** 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 Prática Clínica
Modalidade: online
Duração: 12 meses
Créditos: 90 ECTS



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



Mestrado Próprio Inteligência Artificial na Prática Clínica

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

Mestrado Próprio

Inteligência Artificial na Prática Clínica