

Mestrado Próprio

Inteligência Artificial na Investigação Clínica



Mestrado Próprio Inteligência Artificial na Investigação Clínica

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

Acesso ao site: www.techtute.com/pt/medicina/mestrado-proprio/mestrado-proprio-inteligencia-artificial-investigacao-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 Investigação Clínica revolucionou a forma como os dados médicos são analisados e compreendidos. Esta abordagem simplificou os processos de investigação ao permitir uma análise mais rápida e precisa de grandes conjuntos de dados, identificando padrões e correlações que poderiam passar despercebidos pelos métodos tradicionais. Assim, a IA facilita a previsão dos resultados de ensaios clínicos, ajuda a personalizar os tratamentos de acordo com perfis individuais e otimiza a identificação atempada de doenças. Por este motivo, a TECH desenvolveu um Mestrado Próprio que permitirá aos médicos imergirem na inovação neste domínio. Baseado na revolucionária metodologia Relearning, o sistema de aprendizagem consiste na repetição de conceitos-chave.





“

A capacidade da IA de integrar dados de várias fontes, bem como de prever resultados, contribui para uma medicina mais precisa e personalizada”

Através da aplicação da Inteligência Artificial (IA) na Investigação Clínica, é possível simplificar o processo de análise de grandes conjuntos de dados médicos, permitindo aos investigadores identificar padrões, correlações e tendências de forma mais eficiente. Para além disso, a IA contribui para a personalização da medicina, ao adaptar os tratamentos às características individuais de cada paciente. De facto, as novas tecnologias não só otimizam os processos, como também apresentam novas perspetivas para enfrentar os desafios médicos e melhorar a qualidade da assistência.

Por esta razão, a TECH criou este Mestrado Próprio em que a IA e a biomedicina se fundem, proporcionando aos profissionais um conhecimento profundo e prático das aplicações específicas desta tecnologia no domínio da Investigação Clínica. Por esta razão, a TECH criou este Mestrado Próprio em que a IA e a biomedicina se fundem, proporcionando aos profissionais um conhecimento profundo e prático das aplicações específicas desta tecnologia no domínio da Investigação Clínica. Adicionalmente, será abordada a questão da ética, da regulamentação e das considerações legais na utilização da IA no contexto clínico.

A certificação também integra tecnologias revolucionárias, como a sequenciação genómica e a análise de imagens biomédicas, abordando questões emergentes como a sustentabilidade na investigação biomédica e a gestão de grandes volumes de dados. Neste contexto, os alunos serão dotados das aptidões necessárias para liderar na interseção da IA e da Investigação Clínica.

A TECH concebeu um Mestrado Próprio abrangente, baseado na inovadora metodologia *Relearning*, com o objetivo de qualificar especialistas em IA altamente competentes. Esta modalidade de aprendizagem centra-se na reiteração de conceitos-chave para consolidar uma compreensão ideal. Para aceder aos conteúdos a qualquer momento, basta um dispositivo eletrónico ligado à Internet, eliminando a necessidade presencial ou o cumprimento de horários fixos.

Este **Mestrado Próprio em Inteligência Artificial na Investigação 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 Investigação Clínica
- ♦ 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



Este Mestrado Próprio em Inteligência Artificial na Investigação Clínica é altamente relevante no panorama atual da saúde e da tecnologia

“

Irá investigar as últimas tecnologias e as aplicações mais inovadoras da Inteligência Artificial na Investigação Clínica, através dos melhores recursos multimédia”

O corpo docente do curso é composto por profissionais do setor que trazem para esta capacitação a experiência do seu trabalho, bem como especialistas reconhecidos de empresas de referência e de 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 programa 100% online, analisará de forma exaustiva os princípios essenciais da aprendizagem automática e a sua aplicação na análise de dados clínicos e biomédicos.


*Irá aprofundar a aplicação das técnicas do Big Data e da aprendizagem automática na Investigação Clínica.
Inscreva-se já!*




02

Objetivos

Este Mestrado Próprio visa não só proporcionar uma compreensão aprofundada da Inteligência Artificial aplicada à Investigação Clínica, mas também preparar líderes capazes de enfrentar os desafios atuais e futuros da medicina. Ao frequentar esta certificação, os alunos irão imergir num ambiente académico onde a inovação e a ética se entrelaçam para transformar a assistência médica. Assim, abordarão as técnicas de análise de dados médicos, o desenvolvimento de modelos preditivos para ensaios clínicos e a implantação de soluções inovadoras para a personalização dos tratamentos, abordando os problemas clínicos com soluções baseadas em dados.






“

Aposte na TECH! Desenvolverás competências em IA e abordarás problemas clínicos com soluções baseadas em dados"



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 neuronais 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
- ♦ Obter uma perspetiva abrangente da transformação da Investigação Clínica através da IA, desde os seus fundamentos históricos até às aplicações atuais
- ♦ Aprenda métodos eficazes para integrar dados heterogêneos na Investigação Clínica, incluindo o processamento de linguagem natural e a visualização avançada de dados
- ♦ Adquirir conhecimentos sólidos sobre validação de modelos e simulações no domínio biomédico, explorando a utilização de datasets sintéticos e aplicações práticas de IA na investigação na saúde
- ♦ Compreender e aplicar tecnologias de sequenciação genómica, análise de dados com IA e utilização de IA em imagens biomédicas
- ♦ Adquirir conhecimentos especializados em áreas-chave como a personalização de terapias, a medicina de precisão, o diagnóstico assistido por IA e a gestão de ensaios clínicos
- ♦ Adquirir uma sólida compreensão dos conceitos de Big Data no contexto clínico e familiarizar-se com as ferramentas essenciais para a sua análise
- ♦ Aprofundar os dilemas éticos, analisar as considerações jurídicas, explorar o impacto socioeconómico e o futuro da IA na saúde e promover a inovação e o empreendedorismo no âmbito da IA clínica





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 *tf.data* 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. Métodos e Ferramentas de IA utilizadas na Investigação Clínica

- ♦ Obter uma visão abrangente de como a IA está a transformar a Investigação Clínica, desde os seus fundamentos históricos até às aplicações atuais
- ♦ Implementar métodos estatísticos avançados e algoritmos em estudos clínicos para otimizar a análise de dados
- ♦ Conceber experiências com abordagens inovadoras e efetuar uma análise exaustiva dos resultados na Investigação Clínica
- ♦ Aplicar o processamento de linguagem natural para melhorar a documentação científica e clínica no contexto da Investigação
- ♦ Integrar eficazmente dados heterogéneos utilizando técnicas avançadas para melhorar a investigação clínica interdisciplinar

Módulo 17. Investigação biomédica com IA

- ♦ Adquirir conhecimentos sólidos sobre a validação de modelos e simulações no domínio biomédico, garantindo a sua precisão e relevância clínica
- ♦ Integrar dados heterogéneos utilizando métodos avançados para enriquecer a análise multidisciplinar na Investigação Clínica
- ♦ Desenvolver algoritmos de aprendizagem profunda para melhorar a interpretação e análise de dados biomédicos em estudos clínicos
- ♦ Explorar a utilização de *datasets* sintéticos em estudos clínicos e compreender as aplicações práticas da IA na investigação em saúde
- ♦ Compreender o papel crucial da simulação computacional na descoberta de medicamentos, na análise das interações moleculares e na modelação de doenças complexas

Módulo 18. Aplicação Prática da IA na Investigação Clínica

- ♦ Adquirir conhecimentos especializados em áreas-chave como a personalização de terapias, a medicina de precisão, o diagnóstico assistido por IA, a gestão de ensaios clínicos e o desenvolvimento de vacinas
- ♦ Incorporar a robótica e a automatização nos laboratórios clínicos para melhorar os processos e a qualidade dos resultados
- ♦ Explorar o impacto da IA no microbioma, na microbiologia, nos *wearables* e na monitorização remota em estudos clínicos
- ♦ Enfrentar os desafios da atualidade no domínio biomédico, como a gestão eficiente dos ensaios clínicos, o desenvolvimento de tratamentos assistidos por IA e a aplicação da IA na imunologia e nos estudos da resposta imunitária
- ♦ Inovar no diagnóstico assistido por IA para melhorar a deteção precoce e a precisão do diagnóstico em contextos clínicos e de investigação biomédica

Módulo 19. Análise de *Big Data* e aprendizagem automática na Investigação Clínica

- ♦ Adquirir uma sólida compreensão dos conceitos fundamentais de *Big Data* no contexto clínico e familiarizar-se com as ferramentas essenciais utilizadas para a sua análise
- ♦ Explorar técnicas avançadas de mineração de dados, algoritmos de aprendizagem automática, análise preditiva e aplicações de IA em epidemiologia e saúde pública
- ♦ Analisar redes biológicas e padrões de doenças para identificar ligações e possíveis tratamentos
- ♦ Abordar a segurança dos dados e lidar com os desafios associados a grandes volumes de dados na investigação biomédica
- ♦ Investigar estudos de casos que demonstrem o potencial do *Big Data* na investigação biomédica.

Módulo 20. Aspectos éticos, jurídicos e futuro da IA na Investigação Clínica

- Compreender os dilemas éticos que surgem quando se aplica a IA na investigação clínica e analisar as considerações legais e regulamentares relevantes no domínio biomédico
- Abordar os desafios específicos da gestão do consentimento informado em estudos com IA
- Investigar a forma como a IA pode influenciar a equidade e o acesso aos cuidados de saúde
- Analisar as perspetivas futuras sobre a forma como a IA irá moldar a Investigação Clínica, explorando o seu papel na sustentabilidade da prática de investigação biomédica e identificando oportunidades para a inovação e o empreendedorismo
- Abordar de forma exaustiva os aspetos éticos, jurídicos e socioeconómicos da Investigação Clínica impulsionada pela IA




Atualize as suas competências para estar na vanguarda da revolução tecnológica na saúde, contribuindo para o avanço da Investigação Clínica"

03

Competências

Este Mestrado Próprio proporcionará ao aluno uma atualização exceccionalmente completa e especializada na aplicação da Inteligência Artificial no campo da Investigação Clínica. Desta forma, estará dotado de competências avançadas e práticas para enfrentar desafios biomédicos complexos, desde a análise de dados até à simulação de processos biológicos. Proporcionará também uma compreensão abrangente das tecnologias mais avançadas, como a sequenciação genómica e a análise de imagens biomédicas. Sem esquecer os aspetos éticos, jurídicos e regulamentares que são cruciais na implementação da IA em contextos clínicos.



“


Através deste Mestrado Próprio, irá melhorar a precisão do diagnóstico e a concepção de tratamentos personalizados, revolucionando os cuidados médicos com inovação e eficiência”



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 instáveis
- ♦ 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 a tradução automática neuronal
- ♦ Aplicar os princípios fundamentais das redes neuronais na resolução de problemas específicos
- ♦ Utilizar ferramentas, plataformas e técnicas de IA, desde a análise de dados até à aplicação de redes neuronais e modelação preditiva
- ♦ Aplicar modelos computacionais para simular processos biológicos e respostas a tratamentos, utilizando a IA para melhorar a compreensão de fenómenos biomédicos complexos
- ♦ Responder a desafios da atualidade no domínio biomédico, incluindo a gestão eficiente de ensaios clínicos e a aplicação da IA em imunologia





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 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
- ♦ 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
- ♦ Dominar as ferramentas, plataformas e técnicas de IA na Investigação Clínica, desde a análise de dados até à aplicação de redes neuronais e modelação preditiva
- ♦ Aplicar modelos computacionais para simular de processos biológicos, doenças e respostas a tratamentos, utilizando ferramentas de IA para melhorar a compreensão e representação de fenómenos biomédicos complexos
- ♦ Aplicar tecnologias de sequenciação genómica e de análise de dados com inteligência IA
- ♦ Utilizar a IA na análise de imagens biomédicas
- ♦ Adquirir competências na visualização avançada e na comunicação eficaz de dados complexos, com destaque para o desenvolvimento de ferramentas baseadas em IA



Irá liderar a inovação na convergência da Inteligência Artificial e da Investigação Clínica. Do que está à espera para se inscrever?"

04

Direção do curso

O corpo docente do Mestrado Próprio em Inteligência Artificial na Investigação Clínica representa a excelência académica e a experiência prática na convergência da medicina e da tecnologia. Estes profissionais extraordinários não só têm um conhecimento profundo da IA e da análise de dados, como também um percurso notável na aplicação destas ferramentas na investigação médica. O seu compromisso centrar-se-á na transmissão não só de conhecimentos teóricos, mas também na partilha das suas experiências da vida real, proporcionando aos alunos uma perspetiva inestimável para enfrentar os desafios atuais e futuros no domínio da saúde.



“

O corpo docente oferecerá uma orientação prática de valor inestimável, fundindo a IA e a Investigação Clínica para conseguir avanços significativos nos 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. 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

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


05

Estrutura e conteúdo

Este Mestrado Próprio foi meticulosamente concebido para fundir o rigor científico da Investigação Clínica com as inovações disruptivas da Inteligência Artificial.

A sua estrutura baseia-se em módulos especializados, desde a interpretação de dados médicos ao desenvolvimento de algoritmos preditivos e à implementação de soluções tecnológicas em contextos clínicos. Os conteúdos são uma amálgama de teoria e prática, abrangendo os fundamentos da IA e a sua aplicação específica no domínio médico. Assim, os alunos estarão aptos para liderar os avanços na personalização dos tratamentos e na otimização dos cuidados de saúde.





“

Beneficie de um plano de estudos realizado por especialistas e com conteúdos da mais alta qualidade. Atualize a sua prática clínica com a TECH!”

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 agentes virtuais
 - 1.8.1. Tipos de agentes: Agentes por voz e por texto
 - 1.8.2. Partes fundamentais para o desenvolvimento de um agente: *Intents*, 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, escalas de medida
- 2.2. Tipos de dados estatísticos
 - 2.2.1. De acordo com o tipo
 - 2.2.1.1. Quantitativos: Dados contínuos e dados discretos
 - 2.2.1.2. Qualitativos: Dados 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 neuronais
 - 7.6.1. Conceitos básicos
 - 7.6.2. Redes neuronais simples
 - 7.6.3. Algoritmo de *Backpropagation*
 - 7.6.4. Introdução às redes neuronais recorrentes

- 7.7. Métodos bayesianos
 - 7.7.1. Conceitos básicos de probabilidade
 - 7.7.2. Teorema de Bayes
 - 7.7.3. Naive Bayes
 - 7.7.4. Introdução às redes bayesianas
- 7.8. Modelos de regressão e modelos de resposta contínua
 - 7.8.1. Regressão linear simples
 - 7.8.2. Regressão linear múltipla
 - 7.8.3. Regressão logística
 - 7.8.4. Árvores de regressão
 - 7.8.5. Introdução às máquinas de suporte vetorial (SVM)
 - 7.8.6. Medidas de adequação
- 7.9. *Clustering*
 - 7.9.1. Conceitos básicos
 - 7.9.2. *Clustering* hierárquico
 - 7.9.3. Métodos probabilísticos
 - 7.9.4. Algoritmo EM
 - 7.9.5. Método *B-Cubed*
 - 7.9.6. Métodos implícitos
- 7.10. Mineração de texto e processamento linguagem natural (PLN)
 - 7.10.1. Conceitos básicos
 - 7.10.2. Criação do corpus
 - 7.10.3. Análise descritiva
 - 7.10.4. Introdução à análise de sentimentos

Módulo 8. Redes neurais, 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 um modelo *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 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 neuronais (I)
 - 14.9.1. Introdução às redes neuronais
 - 14.9.2. Exemplo prático com redes neuronais
- 14.10. Redes neuronais (II)
 - 14.10.1. Casos de utilização de redes neuronais na investigação médica
 - 14.10.2. Casos de utilização de redes neuronais na economia
 - 14.10.3. Casos de utilização de redes neuronais na visão artificial

Módulo 15. Inteligência Artificial: Estratégias e aplicações

- 15.1. Serviços financeiros
 - 15.1.1. As implicações da Inteligência Artificial (IA) nos serviços financeiros Oportunidades e desafios
 - 15.1.2. Casos de utilização
 - 15.1.3. Potenciais riscos relacionados com a utilização de IA
 - 15.1.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.2. Implicações da inteligência artificial no serviço de saúde
 - 15.2.1. Implicações da IA no setor da saúde Oportunidades e desafios
 - 15.2.2. Casos de utilização
- 15.3. Riscos relacionados com a utilização de IA no serviço de saúde
 - 15.3.1. Potenciais riscos relacionados com a utilização de IA
 - 15.3.2. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.4. *Retail*
 - 15.4.1. Implicações da IA no *Retail* Oportunidades e desafios
 - 15.4.2. Casos de utilização
 - 15.4.3. Potenciais riscos relacionados com a utilização de IA
 - 15.4.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.5. 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. Métodos e Ferramentas de IA utilizadas na Investigação Clínica

- 16.1. Tecnologias e Ferramentas de IA na investigação clínica
 - 16.1.1. Utilização da aprendizagem automática para identificar padrões em dados clínicos
 - 16.1.2. Desenvolvimento de algoritmos preditivos para ensaios clínicos
 - 16.1.3. Implementação de sistemas de IA para melhorar o recrutamento de pacientes
 - 16.1.4. Ferramentas de IA para a análise de dados de investigação em tempo real
- 16.2. Métodos estatísticos e algoritmos em estudos clínicos
 - 16.2.1. Aplicação de técnicas estatísticas avançadas para a análise de dados clínicos
 - 16.2.2. Utilização de algoritmos para a validação e verificação dos resultados dos ensaios
 - 16.2.3. Aplicação de modelos de regressão e de classificação em estudos clínicos
 - 16.2.4. Análise de grandes conjuntos de dados através de métodos estatísticos computacionais
- 16.3. Conceção de experiências e análise de resultados
 - 16.3.1. Estratégias para a conceção eficiente de ensaios clínicos utilizando IA
 - 16.3.2. Técnicas de IA para análise e interpretação de dados experimentais
 - 16.3.3. Otimização de protocolos de investigação através de simulações de IA
 - 16.3.4. Avaliação da eficácia e segurança dos tratamentos utilizando modelos de IA
- 16.4. Interpretação de imagens médicas com recurso à IA na investigação
 - 16.4.1. Desenvolvimento de sistemas de IA para deteção automática de patologias em imagens
 - 16.4.2. Utilização da aprendizagem profunda para a classificação e segmentação de imagens médicas
 - 16.4.3. Ferramentas de IA para melhorar a precisão em diagnóstico por imagem
 - 16.4.4. Análise de imagens radiológicas e de ressonância magnética através da IA
- 16.5. Análise de dados clínicos e biomédicos
 - 16.5.1. IA no tratamento e análise de dados genómicos e proteómicos
 - 16.5.2. Ferramentas para análise integrada de dados clínicos e biomédicos
 - 16.5.3. Utilização da IA para identificar biomarcadores na investigação clínica
 - 16.5.4. Análise preditiva de resultados clínicos com base em dados biomédico
- 16.6. Visualização avançada de dados na Investigação Clínica
 - 16.6.1. Desenvolvimento de ferramentas de visualização interativa para dados clínicos
 - 16.6.2. Utilização de IA na criação de representações gráficas de dados complexos
 - 16.6.3. Técnicas de visualização para facilitar a interpretação dos resultados da investigação
 - 16.6.4. Ferramentas de realidade aumentada e virtual para a visualização de dados biomédicos
- 16.7. Processamento de linguagem natural em documentação científica e clínica
 - 16.7.1. Aplicação de PNL para análise de literatura científica e registos clínicos
 - 16.7.2. Ferramentas de IA para a extração de informação relevante de textos médicos
 - 16.7.3. Sistemas de IA para resumir e categorizar publicações científicas
 - 16.7.4. Utilização de PNL na identificação de tendências e padrões em documentação clínica

- 16.8. Processamento de dados heterogêneos na Investigação Clínica
 - 16.8.1. Técnicas de IA para integração e análise de dados provenientes de diversas fontes clínicas
 - 16.8.2. Ferramentas para a gestão de dados clínicos não estruturados
 - 16.8.3. Sistemas de IA para a correlação de dados clínicos e demográficos
 - 16.8.4. Análise de dados multidimensionais para obter *insights* clínicos
- 16.9. Aplicações de redes neuronais em investigações biomédicas
 - 16.9.1. Utilização de redes neuronais para modelização de doenças e previsão de tratamento
 - 16.9.2. Implementação de redes neuronais na classificação de doenças genéticas
 - 16.9.3. Desenvolvimento de sistemas de diagnóstico baseados em redes neuronais
 - 16.9.4. Aplicação das redes neuronais na personalização de tratamentos médicos
- 16.10. Modelação preditiva e o seu impacto na Investigação Clínica
 - 16.10.1. Desenvolvimento de modelos preditivos para a antecipação de resultados clínicos
 - 16.10.2. Utilização da IA na previsão de efeitos secundários e reações adversas
 - 16.10.3. Implementação de modelos preditivos na otimização de ensaios clínicos
 - 16.10.4. Análise de riscos em tratamentos médicos utilizando a modelação preditiva

Módulo 17. Investigação biomédica com IA

- 17.1. Projeto e execução de estudos observacionais de IA
 - 17.1.1. Implementação da IA para seleção e segmentação das populações dos estudos
 - 17.1.2. Utilização de algoritmos para a monitorização em tempo real dos dados de estudos observacionais
 - 17.1.3. Ferramentas de IA para a identificação de padrões e correlações em estudos observacionais
 - 17.1.4. Automatização do processo de recolha e análise de dados em estudos observacionais
- 17.2. Validação e calibração de modelos em investigação clínica
 - 17.2.1. Técnicas de IA para garantir a precisão e a fiabilidade dos modelos clínicos
 - 17.2.2. Utilização da IA na calibração de modelos preditivos em investigação clínica
 - 17.2.3. Métodos de validação cruzada aplicados a modelos clínicos que utilizam IA
 - 17.2.4. Ferramentas de IA para a avaliação da generalização dos modelos clínicos
- 17.3. Métodos de integração de dados heterogêneos na investigação clínica
 - 17.3.1. Técnicas de IA para a combinação de dados clínicos, genómicos e ambientais
 - 17.3.2. Utilização de algoritmos para tratar e analisar dados clínicos não estruturados

- 17.3.3. Ferramentas de IA para normalização e padronização de dados clínicos
- 17.3.4. Sistemas de IA para a correlação de diferentes tipos de dados em investigação
- 17.4. Integração multidisciplinar de dados biomédicos
 - 17.4.1. Sistemas de IA para a combinação de dados de diferentes disciplinas biomédicas
 - 17.4.2. Algoritmos para análise integrada de dados clínicos e laboratoriais
 - 17.4.3. Ferramentas de IA para a visualização de dados biomédicos complexos
 - 17.4.4. Utilização da IA na criação de modelos de saúde holísticos a partir de dados multidisciplinares
- 17.5. Algoritmos de aprendizagem profunda na análise de dados biomédicos
 - 17.5.1. Implementação de redes neuronais na análise de dados genéticos e proteómicos
 - 17.5.2. Utilização da aprendizagem profunda para a identificação de padrões em dados biomédicos
 - 17.5.3. Desenvolvimento de modelos preditivos em medicina de precisão utilizando a aprendizagem profunda
 - 17.5.4. Aplicação da IA na análise avançada de imagens biomédicas
- 17.6. Otimização dos processos de investigação através da automatização
 - 17.6.1. Automatização de rotinas laboratoriais utilizando sistemas de IA
 - 17.6.2. Utilização da IA para uma gestão eficiente dos recursos e do tempo de investigação
 - 17.6.3. Ferramentas de IA para a otimização dos fluxos de trabalho em investigação clínica
 - 17.6.4. Sistemas automatizados para acompanhar e comunicar os progressos da investigação
- 17.7. Simulação e modelação computacional em medicina com IA
 - 17.7.1. Desenvolvimento de modelos computacionais para simular cenários clínicos
 - 17.7.2. Utilização da IA para a simulação de interações moleculares e celulares
 - 17.7.3. Ferramentas de IA na criação de modelos preditivos de doenças
 - 17.7.4. Aplicação da IA na simulação dos efeitos de medicamentos e tratamentos
- 17.8. Utilização de realidade virtual e aumentada em estudos clínicos
 - 17.8.1. Implementação da realidade virtual para formação e simulação em medicina
 - 17.8.2. Utilização da realidade aumentada em procedimentos cirúrgicos e diagnósticos
 - 17.8.3. Ferramentas de realidade virtual para estudos comportamentais e psicológicos
 - 17.8.4. Aplicação de tecnologias imersivas na reabilitação e na terapia
- 17.9. Ferramentas de mineração de dados aplicadas à investigação biomédica
 - 17.9.1. Utilização de técnicas de mineração de dados para extrair conhecimentos de bases de dados biomédicas
 - 17.9.2. Aplicação de algoritmos de IA para descobrir padrões em dados clínicos

- 17.9.3. Ferramentas de IA para identificação de tendências em grandes conjuntos de dados
- 17.9.4. Aplicação da mineração de dados na geração de hipóteses de investigação
- 17.10. Desenvolvimento e validação de biomarcadores com inteligência artificial
 - 17.10.1. Utilização da IA para a identificação e caracterização de novos biomarcadores
 - 17.10.2. Aplicação de modelos de IA para a validação em estudos clínicos
 - 17.10.3. Ferramentas de IA para correlacionar biomarcadores com resultados clínicos
 - 17.10.4. Aplicação da IA na análise de biomarcadores para a medicina personalizada

Módulo 18. Aplicação Prática da IA na Investigação Clínica

- 18.1. Tecnologias de sequenciação genómica e análise de dados com IA
 - 18.1.1. Utilização da IA para uma análise rápida e precisa das sequências genéticas
 - 18.1.2. Implementação de algoritmos de aprendizagem automática na interpretação de dados genómicos
 - 18.1.3. Ferramentas de IA para identificar variantes e mutações genéticas
 - 18.1.4. Aplicação da IA na correlação genómica com doenças e características
- 18.2. IA na análise de imagens biomédicas
 - 18.2.1. Desenvolvimento de sistemas de IA para a deteção de anomalias em imagens médicas
 - 18.2.2. Utilização de aprendizagem profunda na interpretação de radiografias, ressonâncias e tomografias computadorizadas
 - 18.2.3. Ferramentas de IA para melhorar a precisão do diagnóstico por imagens
 - 18.2.4. Implementação da IA na classificação e segmentação de imagens biomédicas
- 18.3. Robótica e automatização em laboratórios clínicos
 - 18.3.1. Utilização de robots para automatização de ensaios e processos em laboratórios
 - 18.3.2. Implementação de sistemas automatizados para a gestão de amostras biológicas
 - 18.3.3. Desenvolvimento de tecnologias robóticas para melhorar a eficiência e a precisão das análises clínicas
 - 18.3.4. Aplicação de IA na otimização dos fluxos de trabalho em laboratórios
- 18.4. IA na personalização de terapias e na medicina de precisão
 - 18.4.1. Desenvolvimento de modelos de IA para a personalização de tratamentos médicos
 - 18.4.2. Utilização de algoritmos preditivos na seleção de terapias com base no perfil genético
 - 18.4.3. Ferramentas de IA na adaptação de doses e combinações de medicamentos
 - 18.4.4. Aplicação da IA na identificação de tratamentos eficazes para grupos específicos
- 18.5. Inovações no diagnóstico assistido por IA
 - 18.5.1. Implementação de sistemas de IA para diagnósticos rápidos e precisos
 - 18.5.2. Utilização da IA na identificação precoce de doenças através de análise de dados
 - 18.5.3. Desenvolvimento de ferramentas de IA para a interpretação de exames clínicos
 - 18.5.4. Aplicação da IA na combinação de dados clínicos e biomédicos para diagnósticos abrangentes
- 18.6. Aplicações de IA em microbioma e estudos de microbiologia
 - 18.6.1. Utilização da IA na análise e mapeamento do microbioma humano
 - 18.6.2. Implementação de algoritmos para estudar a relação entre o microbioma e as doenças
 - 18.6.3. Ferramentas de IA na identificação de padrões em estudos microbiológicos
 - 18.6.4. Aplicação da IA na investigação de terapêuticas baseadas no microbioma
- 18.7. Wearables e monitorização remota em estudos clínicos
 - 18.7.1. Desenvolvimento de dispositivos wearables com IA para monitorização contínua de saúde
 - 18.7.2. Utilização da IA na interpretação dos dados recolhidos pelos wearables
 - 18.7.3. Implementação de sistemas de monitorização à distância em ensaios clínicos
 - 18.7.4. Aplicação da IA na previsão de eventos clínicos através de dados de wearables
- 18.8. IA na gestão de ensaios clínicos
 - 18.8.1. Utilização de sistemas de IA para a otimização da gestão de ensaios clínicos
 - 18.8.2. Implementação da IA na seleção e acompanhamento dos participantes
 - 18.8.3. Ferramentas de IA para a análise de dados e resultados de ensaios clínicos
 - 18.8.4. Aplicação da IA para melhorar a eficiência e reduzir os custos dos ensaios
- 18.9. Desenvolvimento de vacinas e tratamentos assistidos por IA
 - 18.9.1. Utilização da IA para acelerar o desenvolvimento de vacinas
 - 18.9.2. Implementação de modelos preditivos na identificação de potenciais tratamentos
 - 18.9.3. Ferramentas de IA para simular a resposta a vacinas e medicamentos
 - 18.9.4. Aplicação da IA na personalização de vacinas e terapias
- 18.10. Aplicações de IA em imunologia e estudos de resposta imune
 - 18.10.1. Desenvolvimento de modelos de IA para compreender os mecanismos imunológicos
 - 18.10.2. Utilização de IA na identificação de padrões em respostas imunes
 - 18.10.3. Implementação da IA na investigação de doenças autoimunes
 - 18.10.4. Aplicação da IA na conceção de imunoterapias personalizadas

Módulo 19. Análise de *Big Data* e aprendizagem automática na Investigação Clínica

- 19.1. *Big Data* na Investigação Clínica: Conceitos e Ferramentas
 - 19.1.1. A explosão do dado na área da Investigação clínica
 - 19.1.2. Conceito de *Big Data* e ferramentas principais
 - 19.1.3. Aplicações do *Big Data* na Investigação clínica
- 19.2. Mineração de dados em registos clínicos e biomédicos
 - 19.2.1. Principais metodologias para a mineração de dados
 - 19.2.2. Integração de dados de registos clínicos e biomédicos
 - 19.2.3. Detecção de padrões e anomalias em registos clínicos e biomédicos
- 19.3. Algoritmos de aprendizagem automática em investigação biomédica
 - 19.3.1. Técnicas de classificação na investigação biomédica
 - 19.3.2. Técnicas de regressão na investigação biomédica
 - 19.3.4. Técnicas não supervisionadas na investigação biomédica
- 19.4. Técnicas de análise preditiva na investigação clínica
 - 19.4.1. Técnicas de classificação na investigação clínica
 - 19.4.2. Técnicas de regressão na investigação clínica
 - 19.4.3. *Deep Learning* na investigação clínica
- 19.5. Modelos de IA em epidemiologia e saúde pública
 - 19.5.1. Técnicas de classificação para epidemiologia e saúde pública
 - 19.5.2. Técnicas de regressão para epidemiologia e saúde pública
 - 19.5.3. Técnicas não supervisionadas para epidemiologia e saúde pública
- 19.6. Análise de redes biológicas e padrões de doença
 - 19.6.1. Exploração das interações em redes biológicas para a identificação de padrões de doença
 - 19.6.2. Integração de dados ómicos na análise de redes para caraterizar as complexidades biológicas
 - 19.6.3. Aplicação de algoritmos de *machine learning* para a descoberta de padrões de doença
- 19.7. Desenvolvimento de ferramentas para o prognóstico clínico
 - 19.7.1. Criação de ferramentas inovadoras para o prognóstico clínico com base em dados multidimensionais
 - 19.7.2. Integração de variáveis clínicas e moleculares no desenvolvimento de ferramentas de prognóstico
 - 19.7.3. Avaliação da eficácia das ferramentas de prognóstico em diferentes contextos clínicos

- 19.8. Visualização e comunicação avançadas de dados complexos
 - 19.8.1. Utilização de técnicas avançadas de visualização para representar dados biomédicos complexos
 - 19.8.2. Desenvolvimento de estratégias de comunicação eficazes para apresentar resultados de análises complexas
 - 19.8.3. Implementação de ferramentas de interatividade em visualizações para melhorar a compreensão
- 19.9. Segurança dos dados e desafios na gestão de *Big Data*
 - 19.9.1. Abordagem dos desafios relativos à segurança dos dados no contexto do *Big Data* biomédico
 - 19.9.1. Estratégias de proteção da privacidade na gestão de grandes conjuntos de dados biomédicos
 - 19.9.3. Implementação de medidas de segurança para atenuar os riscos no tratamento de dados sensíveis
- 19.10. Aplicações práticas e estudos de casos em *Big Data* biomédico
 - 19.10.1. Exploração de casos de sucesso na implementação de *Big Data* biomédico na investigação clínica
 - 19.10.2. Desenvolvimento de estratégias práticas para a aplicação de *Big Data* na tomada de decisões clínicas
 - 19.10.3. Avaliação do impacto e das lições aprendidas através de estudos de casos no domínio biomédico

Módulo 20. Aspetos éticos, jurídicos e futuro da IA na Investigação Clínica

- 20.1. Ética na aplicação de IA na Investigação Clínica
 - 20.1.1. Análise ética da tomada de decisões assistida por IA em contextos de investigação clínica
 - 20.1.2. Ética na utilização de algoritmos de IA para a seleção de participantes em ensaios clínicos
 - 20.1.3. Considerações éticas na interpretação dos resultados gerados pelos sistemas de IA na investigação clínica
- 20.2. Considerações legais e regulamentares na IA biomédica
 - 20.2.1. Análise da regulamentação jurídica no desenvolvimento e aplicação de tecnologias de IA no domínio biomédico
 - 20.2.2. Avaliação da conformidade com a regulamentação específica para garantir a segurança e a eficácia das soluções baseadas na IA
 - 20.2.3. Abordagem dos desafios regulamentares emergentes associados à utilização da IA na investigação biomédica

- 20.3. Consentimento informado e aspetos éticos da utilização de dados clínicos
 - 20.3.1. Desenvolvimento de estratégias para garantir um consentimento informado eficaz em projetos que envolvam IA
 - 20.3.2. Ética na recolha e utilização de dados clínicos sensíveis no contexto de investigações impulsionadas por IA
 - 20.3.3. Abordagem de questões éticas relacionadas com a propriedade e o acesso a dados clínicos em projetos de investigação
- 20.4. IA e responsabilidade na Investigação Clínica
 - 20.4.1. Avaliação da responsabilidade ética e jurídica na implementação de sistemas de IA em protocolos de investigação clínica
 - 20.4.2. Desenvolvimento de estratégias para abordar as eventuais consequências adversas da implementação da IA na investigação biomédica
 - 20.4.3. Considerações éticas sobre a participação ativa da IA na tomada de decisões na investigação clínica
- 20.5. Impacto da IA na equidade e acesso aos cuidados de saúde
 - 20.5.1. Avaliação do impacto das soluções de IA na equidade da participação em ensaios clínicos
 - 20.5.2. Desenvolvimento de estratégias para melhorar o acesso às tecnologias de IA em diversos contextos clínicos
 - 20.5.3. Ética na distribuição dos benefícios e riscos associados à aplicação da IA nos cuidados de saúde
- 20.6. Privacidade e proteção de dados em projetos de investigação
 - 20.6.1. Garantia da privacidade dos participantes em projetos de investigação que envolvam a utilização de IA
 - 20.6.2. Desenvolvimento de políticas e práticas de proteção de dados na investigação biomédica
 - 20.6.3. Abordagem de desafios específicos de privacidade e segurança no tratamento de dados sensíveis no ambiente clínico
- 20.7. IA e sustentabilidade em investigações biomédicas
 - 20.7.1. Avaliação do impacto ambiental e dos recursos associados à implementação da IA na investigação biomédica
 - 20.7.2. Desenvolvimento de práticas sustentáveis na integração de tecnologias de IA em projetos de investigação clínica
 - 20.7.3. Ética na gestão de recursos e sustentabilidade na adoção da IA na investigação biomédica
- 20.8. Auditoria e explicabilidade dos modelos de IA no contexto clínico
 - 20.8.1. Desenvolvimento de protocolos de auditoria para avaliar a fiabilidade e precisão dos modelos de IA na investigação clínica
 - 20.8.2. Ética na explicabilidade dos algoritmos para garantir a compreensão das decisões tomadas pelos sistemas de IA em contextos clínicos
 - 20.8.3. Abordagem dos desafios éticos na interpretação dos resultados dos modelos de IA na investigação biomédica
- 20.9. Identificar oportunidades de inovação e empreendedorismo âmbito da IA clínica
 - 20.9.1. Ética na inovação responsável aquando do desenvolvimento de soluções de IA para aplicações clínicas
 - 20.9.2. Desenvolvimento de estratégias empresariais éticas no domínio da IA clínica
 - 20.9.3. Considerações éticas na comercialização e adoção de soluções de IA no sector clínico
- 20.10. Considerações éticas na colaboração internacional na investigação clínica
 - 20.10.1. Desenvolvimento de acordos éticos e jurídicos para a colaboração internacional em projetos de investigação impulsionados por IA
 - 20.10.2. Ética da participação de várias instituições e países na investigação clínica com tecnologias de IA
 - 20.10.3. Abordagem dos desafios éticos emergentes associados à colaboração global em investigação biomédica

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 Mestrado Próprio oferece o melhor material educativo, cuidadosamente preparado para profissionais:



Material de estudo

Todos os conteúdos didáticos são criados pelos especialistas que irão ministrar o Mestrado Próprio, em específico para o mesmo, para que o desenvolvimento didático seja realmente específico e concreto.

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



Técnicas cirúrgicas e procedimentos em vídeo

A TECH faz chegar ao aluno as técnicas mais inovadoras, com os últimos avanços educativos, que estão na vanguarda da atual situação nas técnicas médicas. Tudo isto, em primeira pessoa, com o máximo rigor, explicado e detalhado para a assimilação e compreensão do aluno. E o melhor de tudo é que pode assistir quantas vezes quiser.



Resumos interativos


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


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



Leituras complementares

Artigos recentes, documentos de consenso e guias internacionais, entre outros. Na biblioteca virtual da TECH, o estudante terá acesso a tudo o que precisa para completar o seu Mestrado Próprio.





07

Certificação

Este programa permitir-lhe-á obter o diploma Mestrado Próprio em Inteligência Artificial na Investigação 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 Inteligência Artificial na Investigação 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 Inteligência Artificial na Investigação Clínica

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 Investigação 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 Investigação Clínica