

Mestrado

Inteligência Artificial em
Diagnóstico por Imagem



Mestrado Inteligência Artificial em Diagnóstico por Imagem

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

Acesso ao site: www.techtute.com/pt/inteligencia-artificial/mestrado/mestrado-inteligencia-artificial-diagnostico-imagem

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. 48

07

Certificação

pág. 56

01

Apresentação

A Inteligência Artificial está a emergir como uma das tecnologias mais promissoras no domínio do Diagnóstico por Imagem. A capacidade dos algoritmos para analisar grandes volumes de dados de exames radiológicos e detetar padrões subtis permite aos especialistas diagnosticar precocemente uma vasta gama de doenças. Desta forma, os profissionais podem criar planos de tratamento individualizados para melhorar significativamente os resultados clínicos. No entanto, a adoção destas ferramentas coloca também inúmeros desafios técnicos e éticos aos profissionais. Por esta razão, a TECH apresenta um programa universitário inovador, 100% online, que fornecerá aos médicos as competências necessárias para tirar o máximo partido destes instrumentos em expansão.



“

Através deste programa 100% online, irá dominar as principais ferramentas da Inteligência Artificial e utilizá-las para otimizar a qualidade das suas análises clínicas”

Um relatório recente da Organização Mundial de Saúde prevê que o peso global das doenças crónicas irá aumentar nos próximos anos. Perante esta situação, a organização insta os médicos a utilizarem os instrumentos mais exactos e eficazes para um diagnóstico precoce. Neste contexto, a Inteligência Artificial é uma ferramenta útil para a identificação precoce de patologias como o cancro do pulmão, a insuficiência cardíaca e até a doença de Alzheimer. Daí a importância de os profissionais incorporarem técnicas avançadas como a aprendizagem profunda na sua prática clínica diária, *Deep Learning* ou Computação bio-inspirada com o objetivo de reduzir os erros de diagnóstico e personalizar o tratamento dos utilizadores.

Neste contexto, a TECH está a desenvolver um programa pioneiro em Inteligência Artificial no Diagnóstico por Imagem. Concebido por referências no domínio, o programa de estudos abordará os fundamentos das redes neuronais e dos algoritmos genéticos. Neste sentido, os materiais de formação fornecerão as chaves para a aplicação das técnicas mais sofisticadas de Data Mining. Desta forma, os especialistas adquirirão competências avançadas para melhorar a precisão na deteção de doenças e condições médicas, permitindo-lhes fazer diagnósticos mais exactos. Além disso, o programa abordará também em profundidade a utilização de modelos de computação bio-inspirados para que os médicos possam aplicá-los na resolução de problemas clínicos complexos e na otimização de tratamentos clínicos.

A TECH oferece um ambiente académico 100% online que se ajuste às necessidades dos médicos que procuram progredir nas suas carreiras. Utiliza também a sua metodologia disruptiva do *Relearning*, baseado na repetição de conceitos-chave para fixar o conhecimento com eficácia e rapidez. Além disso, os especialistas só precisam de um dispositivo com acesso à Internet (telemóvel, computador ou *tablet*) para acederem ao Campus Virtual e viverem uma experiência que lhes permitirá aumentar significativamente os seus horizontes profissionais.

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

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



Um plano de estudo dá-lhe a oportunidade de atualizar os seus conhecimentos num cenário real, com o máximo rigor científico de uma instituição na vanguarda tecnológica"

“

Utilizará as Redes Neurais Convolucionais para adaptar os tratamentos às necessidades específicas dos doentes e melhorar significativamente o seu prognóstico”

Adquirirá competências avançadas para avaliar a exatidão, a validade e a aplicabilidade clínica dos modelos de Inteligência Artificial no domínio da medicina.

Os resumos interactivos de cada módulo permitirão consolidar os conceitos de Processamento da Linguagem Natural de uma forma mais dinâmica.

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

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

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



02

Objetivos

Este programa proporcionará aos médicos uma compreensão abrangente da aplicação das tecnologias de Inteligência Artificial no Diagnóstico por Imagem. Os alunos também desenvolverão competências avançadas para empregar técnicas emergentes, como a extração de dados, a extração de dados e a extração de dados, *Big Data* ou *Deep Learning* no contexto clínico. Além disso, os profissionais de saúde utilizarão ferramentas como as Redes Neurais Convolucionais para interpretar imagens médicas de diferentes modalidades. Desta forma, os especialistas detectarão anomalias nos exames imagiológicos obtidos e poderão efetuar diagnósticos mais precisos para melhorar a recuperação do doente.



“

Utilizará a Inteligência Artificial para automatizar tarefas de rotina, como a detecção de anomalias em grandes volumes de imagens, permitindo-lhe concentrar-se nos casos clínicos mais complexos”



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*
- Explorar a computação bioinspirada e a sua relevância para o desenvolvimento de sistemas inteligentes
- Desenvolver competências para utilizar e aplicar ferramentas avançadas de Inteligência Artificial na interpretação e análise de imagens médicas, melhorando a precisão do diagnóstico
- Implementar soluções de Inteligência Artificial que permitam a automatização de processos e a personalização de diagnósticos
- Aplicar técnicas de extração de dados e de análise preditiva para tomar decisões clínicas baseadas em provas
- Adquirir competências de investigação que permitirão aos especialistas contribuir para o avanço da Inteligência Artificial na imagiologia médica





Objetivos específicos

Módulo 1. Fundamentos da Inteligência Artificial

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

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

Módulo 3. O dado na Inteligência Artificial

- Dominar os fundamentos da ciência dos dados, abrangendo ferramentas, tipos e fontes de análise de informações
- Explorar o processo de transformação de dados em informação utilizando técnicas de mineração e visualização de dados
- Estudar a estrutura e características dos *datasets*, compreendendo a sua importância na preparação e utilização de dados para modelos de Inteligência Artificial
- 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 concepção de algoritmos, proporcionando uma compreensão sólida das abordagens fundamentais para a resolução de problemas
- ♦ Analisar a eficiência e a complexidade dos algoritmos, aplicando técnicas de análise para avaliar o desempenho em termos de tempo e espaço
- ♦ Estudar e aplicar algoritmos de ordenação, compreendendo o seu desempenho e comparando a sua eficiência em diferentes contextos
- ♦ Explorar algoritmos baseados em árvores, compreendendo a sua estrutura e aplicações
- ♦ Investigar algoritmos com *Heaps*, analisando a sua implementação e utilidade na manipulação eficiente de dados
- ♦ Analisar algoritmos baseados em grafos, explorando a sua aplicação na representação e resolução de problemas que envolvam relações complexas
- ♦ Estudar algoritmos *Greedy*, compreendendo a sua lógica e aplicações na resolução de problemas de otimização
- ♦ Investigar e aplicar a técnica de *backtracking* na resolução sistemática de problemas, analisando a sua eficácia numa variedade de cenários

Módulo 6. Sistemas inteligentes

- ♦ Explorar a teoria dos agentes, compreendendo os conceitos fundamentais do seu funcionamento e a sua aplicação na Inteligência Artificial e na engenharia de Software
- ♦ Estudar a representação do conhecimento, incluindo a análise de ontologias e a sua aplicação na organização de informação estruturada
- ♦ Analisar o conceito de web semântica e o seu impacto na organização e recuperação de informação em ambientes digitais
- ♦ Avaliar e comparar diferentes representações do conhecimento, integrando-as para melhorar a eficiência e a precisão dos sistemas inteligentes

Módulo 7. Aprendizagem automática e mineração de dados

- ♦ Introduzir processos de descoberta de conhecimentos e os conceitos fundamentais da aprendizagem automática
- ♦ Estudar árvores de decisão como modelos de aprendizagem supervisionada, compreendendo a sua estrutura e aplicações
- ♦ Avaliar classificadores utilizando técnicas específicas para medir o seu desempenho e exatidão na classificação de dados
- ♦ Estudar as redes neuronais, compreendendo o seu funcionamento e arquitetura para resolver problemas complexos de aprendizagem automática
- ♦ Explorar os métodos bayesianos e a sua aplicação na aprendizagem automática, incluindo redes bayesianas e classificadores bayesianos
- ♦ Analisar modelos de regressão e de resposta contínua para prever valores numéricos a partir de dados
- ♦ Estudar técnicas de *clustering* para identificar padrões e estruturas em conjuntos de dados não rotulados
- ♦ Explorar a extração de texto e o processamento de linguagem natural (PLN), compreendendo como as técnicas de aprendizagem automática são aplicadas para analisar e compreender texto



Módulo 8. As redes 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 seleccioná-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 da conceção de modelos

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

Módulo 10. Personalização de modelos e formação 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

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
- ♦ 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
- ♦ 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. Inovações de Inteligência Artificial em Diagnóstico por Imagem

- ♦ Dominar ferramentas como o IBM Watson Imaging e o NVIDIA Clara para interpretar automaticamente testes clínicos
- ♦ Obter competências para efetuar experiências clínicas e análise de resultados com recurso à Inteligência Artificial, com o objetivo de melhorar a precisão do diagnóstico

Módulo 17. Aplicações Avançadas de Inteligência Artificial em Estudos e Análise de Imagens Médicas

- ♦ Realizar estudos observacionais em imagiologia utilizando Inteligência Artificial, validando e calibrando modelos de forma eficiente
- ♦ Integrar dados de imagiologia médica com outras fontes biomédicas, utilizando ferramentas como o Enlitic Curie para efetuar investigação multidisciplinar

Módulo 18. Personalização e automatização do diagnóstico médico através da inteligência artificial

- ♦ Adquirir competências para personalizar diagnósticos utilizando a Inteligência Artificial, correlacionando os resultados de imagiologia com dados genómicos e outros biomarcadores
- ♦ Dominar a automatização da aquisição e do tratamento de imagens médicas, aplicando tecnologias avançadas de Inteligência Artificial





Módulo 19. *Big Data* e Análise Preditiva em Imagiologia Médica

- ♦ Gerir grandes volumes de dados utilizando técnicas de extração de dados e algoritmos de aprendizagem automática
- ♦ Criar ferramentas de prognóstico clínico baseadas na análise de *Big Data* a fim de otimizar as decisões clínicas

Módulo 20. Aspectos éticos e jurídicos da inteligência artificial no diagnóstico por imagem

- ♦ Ter uma compreensão holística dos princípios normativos e deontológicos que regem a utilização da inteligência no domínio dos cuidados de saúde, incluindo aspectos como o consentimento informado
- ♦ Ser capaz de auditar os modelos de Inteligência Artificial utilizados na prática clínica, garantindo a sua transparência e responsabilidade na tomada de decisões médicas



Aprenderá lições valiosas através da resolução de casos clínicos reais em ambientes de aprendizagem simulados

03

Competências

Após a conclusão deste programa, os médicos estarão aptos a implementar tecnologias avançadas de Inteligência Artificial na sua prática clínica diária. Neste contexto, os estudantes desenvolverão competências técnicas para utilizar ferramentas como a Aprendizagem Profunda, *Deep Learning* ou a Computação Bio-inspirada. Desta forma, os especialistas obterão *insights* valiosos para interpretar vários testes de diagnóstico e detetar uma vasta gama de doenças numa fase precoce. Desta forma, os profissionais poderão conceber planos de intervenção altamente personalizados que melhorarão significativamente a qualidade de vida dos doentes.




“

Dominará o Data Mining para antecipar a evolução de uma doença ou a resposta de indivíduos a tratamentos, permitindo-lhe tomar decisões clínicas altamente informadas”



Competências gerais

- ♦ Aplicar eficazmente as técnicas fundamentais da Inteligência Artificial (*Big Data*, Deep Learning, Redes Neurais, etc.) para otimizar a análise de imagens de diagnóstico
- ♦ Interpretar criticamente os resultados gerados pelos sistemas de Inteligência Artificial, garantindo a validade e a relevância clínica das previsões ou classificações.
- ♦ Dominar linguagens de programação de IA, como Python, para garantir a qualidade dos dados obtidos
- ♦ Desenvolver competências avançadas para identificar oportunidades de melhoria no diagnóstico por imagem e conceber soluções tecnológicas inovadoras
- ♦ Personalizar modelos de Inteligência Artificial para o diagnóstico de patologias específicas, como os tumores, tendo em conta as variações individuais e as características da população
- ♦ Comunicar de forma clara e exacta os resultados das análises clínicas a uma variedade de audiências





Competências específicas

- ♦ Treinar redes neurais profundas para classificação, segmentação e detecção de padrões em imagens radiológicas e detecção de padrões em imagens radiológicas
- ♦ Aplicar métodos avançados de processamento de imagem, tais como filtragem, normalização e melhoria do contraste
- ♦ Administrar software médico que incorpora algoritmos de Inteligência Artificial para análise automatizada de testes clínicos, garantindo a usabilidade e a conformidade com a regulamentação sanitária
- ♦ Realizar estudos de validação clínica para garantir que as ferramentas de Inteligência Artificial são eficazes e têm uma aplicabilidade real em contextos clínicos



Irá liderar projectos de investigação que exploram novas aplicações da inteligência artificial no diagnóstico por imagem e impulsionar a inovação no domínio da medicina"

04

Direção do curso

A filosofia da TECH baseia-se em oferecer os programas mais completos e pragmáticos do panorama académico, razão pela qual realiza um processo metódico de formação do seu corpo docente. Para este programa, conta com a colaboração dos melhores especialistas no domínio da Inteligência Artificial aplicada ao Diagnóstico por Imagem. Estes profissionais têm uma longa carreira, na qual contribuíram para otimizar a qualidade de vida de muitos doentes. Assim, os alunos têm as garantias necessárias para aceder a uma experiência que lhes permitirá dar um salto de qualidade na sua prática clínica.



“

Terá o apoio de uma equipa pedagógica constituída por autênticas referências em Inteligência Artificial no Diagnóstico por Imagem”

Direção



Dr .Arturo Peralta Martín-Palomino

- CEO e CTO, Prometeus Global Solutions
- CTO em Korporate Technologies
- CTO em AI Shephers GmbH
- Consultor e Assessor Empresarial Estratégico na Alliance Medical
- Diretor de Design e Desenvolvimento na DocPath
- Doutorado em Engenharia Informática pela Universidade de Castilla-La Mancha
- Doutorado em Economia, Empresas e Finanças pela Universidade Camilo José Cela
- Doutorado em Psicologia pela Universidade de Castilla-La Mancha
- Mestrado em Executive MBA pela Universidade Isabel I
- Mestrado em Gestão Comercial e de Marketing pela Universidade Isabel I
- Mestrado Especialista em Big Data pela Formação Hadoop
- Mestrado em Tecnologias Avançadas de Informação da Universidade de Castilla - la Mancha
- Membro de: Grupo de Investigação SMILE



Professores

Sr. Daniel Vasile Popescu Radu

- ◆ Especialista independente em Farmacologia, Nutrição e Dietética
- ◆ Produtor freelancer de conteúdos didáticos e científicos
- ◆ Nutricionista e dietista comunitário
- ◆ Farmacêutico Comunitário
- ◆ Investigador
- ◆ Mestrado em Nutrição e Saúde na Universidade Aberta da Catalunha (UOC)
- ◆ Mestrado em Psicofarmacologia, Universidade de Valência
- ◆ Produtos farmacêuticos pela Universidade Complutense de Madri
- ◆ Mestrado em Neuropsicologia Clínica pela Universidade Europeia Miguel de Cervantes

“

Uma experiência de aprendizagem única, fundamental e decisiva para impulsionar o seu desenvolvimento profissional”

05

Estrutura e conteúdo

Os materiais didáticos que compõem este programa universitário foram concebidos por especialistas na utilização da Inteligência Artificial em contextos clínicos. Graças a isto, o itinerário académico aprofundará o manejo de várias ferramentas emergentes, como o *Deep Learning*, as redes neurais profundas ou o processamento de linguagem natural. Os alunos desenvolverão assim competências avançadas para integrar estes instrumentos na sua prática de rotina e para analisar exaustivamente os resultados dos exames imagiológicos. Além disso, isto permitirá aos médicos otimizar a precisão dos seus diagnósticos e personalizar os tratamentos para contribuir para o bem-estar geral dos pacientes.



“

Utilizará as técnicas mais sofisticadas de Big Data para detetar precocemente patologias graves, como o cancro, e conceber planos terapêuticos individualizados para otimizar a recuperação de utilizadores”

Módulo 1. Fundamentos da Inteligência Artificial

- 1.1. História da Inteligência Artificial
 - 1.1.1. Quando se começa a falar de inteligência artificial?
 - 1.1.2. Referências no cinema
 - 1.1.3. Importância da inteligência artificial
 - 1.1.4. Tecnologias que viabilizam e apoiam a inteligência artificial
- 1.2. Inteligência Artificial em jogos
 - 1.2.1. Teoria dos jogos
 - 1.2.2. *Minimax* e poda Alfa-Beta
 - 1.2.3. Simulação: Monte Carlo
- 1.3. Redes neurais
 - 1.3.1. Fundamentos teológicos
 - 1.3.2. Modelo computacional
 - 1.3.3. Redes neurais supervisionadas e não supervisionadas
 - 1.3.4. Perceptron simples
 - 1.3.5. Perceptron multicamadas
- 1.4. Algoritmos genéticos
 - 1.4.1. História
 - 1.4.2. Base biológica
 - 1.4.3. Codificação de problemas
 - 1.4.4. Criação da população inicial
 - 1.4.5. Algoritmo principal e operadores genéticos
 - 1.4.6. Avaliação dos indivíduos: Fitness
- 1.5. Tesouros, vocabulários, taxonomias
 - 1.5.1. Vocabulários
 - 1.5.2. Taxonomias
 - 1.5.3. Tesauro
 - 1.5.4. Ontologias
 - 1.5.5. Representação do conhecimento: web semântica
- 1.6. Web semântica
 - 1.6.1. Especificações: RDF, RDFS e OWL
 - 1.6.2. Inferência/razoabilidade
 - 1.6.3. *Linked Data*



- 1.7. Sistemas periciais e DSS
 - 1.7.1. Sistemas periciais
 - 1.7.2. Sistema de apoio à decisão
- 1.8. *Chatbots* e assistentes virtuais
 - 1.8.1. Tipos de assistentes: assistentes de voz e texto
 - 1.8.2. Partes fundamentais para o desenvolvimento de um assistente: *Intenções*, entidades e fluxo de diálogo
 - 1.8.3. Integração: Web, *Slack*, Whatsapp, Facebook
 - 1.8.4. Ferramentas para o desenvolvimento dos assistentes: *Dialog Flow*, *Watson Assistant*
- 1.9. Estratégia de implementação de IA
- 1.10. Futuro da inteligência artificial
 - 1.10.1. Compreendemos como detetar as emoções através de algoritmos
 - 1.10.2. Criação de uma personalidade: linguagem, expressões e conteúdo
 - 1.10.3. Tendências da Inteligência Artificial
 - 1.10.4. Reflexão

Módulo 2. Tipos e Ciclo de Vida do Dado

- 2.1. A Estatística
 - 2.1.1. Estatística: estatística descritiva, inferências estatísticas
 - 2.1.2. População, amostra indivíduo
 - 2.1.3. Variáveis: Definição 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. Extração de dados
- 2.8. Armazém de dados (*Datawarehouse*)
 - 2.8.1. Elementos incluídos
 - 2.8.2. Design
 - 2.8.3. Aspectos a considerar
- 2.9. Disponibilidade dos dados
 - 2.9.1. Acesso
 - 2.9.2. Utilidade
 - 2.9.3. Segurança
- 2.10. Aspectos regulamentares
 - 2.10.1. Lei da Proteção de Dados
 - 2.10.2. Boas práticas
 - 2.10.3. Outros aspetos regulamentares

Módulo 3. O dado na Inteligência Artificial

- 3.1. Ciência de dados
 - 3.1.1. A ciência de dados
 - 3.1.2. Ferramentas avançadas para o cientista de dados
- 3.2. Dados, informação e conhecimento
 - 3.2.1. Dados, informação e conhecimento
 - 3.2.2. Tipos de dados
 - 3.2.3. Fontes de dados
- 3.3. Dos dados à informação
 - 3.3.1. Análise de Dados
 - 3.3.2. Tipos de análise
 - 3.3.3. Extração de informação de um *Dataset*
- 3.4. Extração de informação através da visualização
 - 3.4.1. A visualização como ferramenta de análise
 - 3.4.2. Métodos de visualização
 - 3.4.3. Visualização de um conjunto de dados
- 3.5. Qualidade dos dados
 - 3.5.1. Dados de qualidade
 - 3.5.2. Limpeza de dados
 - 3.5.3. Pré-processamento básico de dados
- 3.6. *Dataset*
 - 3.6.1. Enriquecimento do *Dataset*
 - 3.6.2. A maldição da dimensionalidade
 - 3.6.3. Modificação do nosso conjunto de dados
- 3.7. Desequilíbrio
 - 3.7.1. Desequilíbrio de classes
 - 3.7.2. Técnicas de mitigação do desequilíbrio
 - 3.7.3. Equilíbrio de um *Dataset*
- 3.8. Modelos não supervisionados
 - 3.8.1. Modelo não supervisionado
 - 3.8.2. Métodos
 - 3.8.3. Classificação com modelos não supervisionados

- 3.9. Modelos supervisionados
 - 3.9.1. Modelo supervisionado
 - 3.9.2. Métodos
 - 3.9.3. Classificação com modelos supervisionados
- 3.10. Ferramentas e boas práticas
 - 3.10.1. Boas práticas para um cientista de dados
 - 3.10.2. O melhor modelo
 - 3.10.3. Ferramentas úteis

Módulo 4. 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 desenho do algoritmos
 - 5.1.1. Recursividade
 - 5.1.2. Divide e conquista
 - 5.1.3. Outras estratégias
- 5.2. Eficiência e análise dos algoritmos
 - 5.2.1. Medidas de eficiência
 - 5.2.2. Medir o tamanho da entrada
 - 5.2.3. Medir o tempo de execução
 - 5.2.4. Caso pior, melhor e médio
 - 5.2.5. Notação assintótica
 - 5.2.6. Critérios de Análise matemática de algoritmos não recursivos
 - 5.2.7. Análise matemática de algoritmos recursivos
 - 5.2.8. Análise empírica de algoritmos
- 5.3. Algoritmos de ordenação
 - 5.3.1. Conceito de ordenação
 - 5.3.2. Ordenação da bolha
 - 5.3.3. Ordenação por seleção
 - 5.3.4. Ordenação por inserção
 - 5.3.5. Ordenação por mistura (*Merge_Sort*)
 - 5.3.6. Ordenação rápida (*Quicksort*)
- 5.4. Algoritmos com árvores
 - 5.4.1. Conceito de árvore
 - 5.4.2. Árvores binários
 - 5.4.3. Caminhos de árvore
 - 5.4.4. Representar expressões
 - 5.4.5. Árvores 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. Caminho de largura
 - 5.6.3. Caminho de profundidade
 - 5.6.4. Ordenação topológica
- 5.7. Algoritmos *Greedy*
 - 5.7.1. A estratégia *Greedy*
 - 5.7.2. Elementos da estratégia *Greedy*
 - 5.7.3. Câmbio de moedas
 - 5.7.4. Problema do viajante
 - 5.7.5. Problema da mochila
- 5.8. Pesquisa de caminhos mínimos
 - 5.8.1. O problema do caminho mínimo
 - 5.8.2. Arcos negativos e ciclos
 - 5.8.3. Algoritmo de Dijkstra
- 5.9. Algoritmos *Greedy* sobre Grafos
 - 5.9.1. A árvore de extensão mínima
 - 5.9.2. O algoritmo de Prim
 - 5.9.3. O algoritmo Kruskal
 - 5.9.4. Análise de complexidade
- 5.10. *Backtracking*
 - 5.10.1. O *Backtracking*
 - 5.10.2. Técnicas alternativas

Módulo 6. Sistemas inteligentes

- 6.1. Teoria dos agentes
 - 6.1.1. História do conceito
 - 6.1.2. Definição de agente
 - 6.1.3. Agentes na Inteligência Artificial
 - 6.1.4. Agentes em Engenharia de Software
- 6.2. Arquiteturas de agentes
 - 6.2.1. O processo de argumentação de um agente
 - 6.2.2. Agentes reativos
 - 6.2.3. Agentes dedutivos
 - 6.2.4. Agentes híbridos
 - 6.2.5. Comparativo
- 6.3. Informação e conhecimento
 - 6.3.1. Distinção entre dados, informação e conhecimento
 - 6.3.2. Avaliação qualidade dos dados
 - 6.3.3. Métodos de recolha de dados
 - 6.3.4. Métodos de aquisição de dados
 - 6.3.5. Métodos de aquisição de conhecimento
- 6.4. Representação do conhecimento
 - 6.4.1. A importância da representação do conhecimento
 - 6.4.2. Definição da representação do conhecimento através das suas funções
 - 6.4.3. Características de uma representação do conhecimento
- 6.5. Ontologias
 - 6.5.1. Introdução aos metadados
 - 6.5.2. Conceito filosófico de ontologia
 - 6.5.3. Conceito informático de ontologia
 - 6.5.4. Ontologias de domínio e ontologias de nível superior
 - 6.5.5. Como construir uma ontologia?
- 6.6. Linguagens para ontologias e Software para a criação de ontologias
 - 6.6.1. Triples RDF, *Turtle* e N
 - 6.6.2. RDF *Schema*
 - 6.6.3. OWL
 - 6.6.4. SPARQL
 - 6.6.5. Introdução às diferentes ferramentas de criação de ontologias
 - 6.6.6. Instalação e utilização do *Protégé*
- 6.7. A web semântica
 - 6.7.1. O estado atual e futuro da web semântica
 - 6.7.2. Aplicações da web semântica
- 6.8. Outros modelos representação do conhecimento
 - 6.8.1. Vocabulários
 - 6.8.2. Visão global
 - 6.8.3. Taxonomias
 - 6.8.4. Tesauros
 - 6.8.5. Folksonomias
 - 6.8.6. Comparativo
 - 6.8.7. Mapas mentais
- 6.9. Avaliação e integração das representações do conhecimento
 - 6.9.1. Lógica de ordem zero
 - 6.9.2. Lógica de primeira ordem
 - 6.9.3. Lógica descritiva
 - 6.9.4. Relação entre diferentes tipos de lógica
 - 6.9.5. *Prolog*: programação baseada na lógica de primeira ordem
- 6.10. Raciocinadores semânticos, sistemas baseados no conhecimento e Sistemas Periciais
 - 6.10.1. Conceito de raciocinador
 - 6.10.2. Aplicações de um raciocinador
 - 6.10.3. Sistemas baseados no conhecimento
 - 6.10.4. MYCIN, história dos Sistemas Periciais
 - 6.10.5. Elementos e Arquitetura dos Sistemas Periciais
 - 6.10.6. Criação de Sistemas Periciais

Módulo 7. Aprendizagem automática e mineração de dados

- 7.1. Introdução aos processos de descoberta de conhecimentos e aos conceitos básicos da aprendizagem automática
 - 7.1.1. Conceitos-chave dos processos de descoberta do conhecimento
 - 7.1.2. Perspetiva histórica dos processos de descoberta do conhecimento
 - 7.1.3. Etapas dos processos de descoberta do conhecimento
 - 7.1.4. Técnicas utilizadas nos processos de descoberta do conhecimento
 - 7.1.5. Características dos bons modelos de aprendizagem automática
 - 7.1.6. Tipos de informação sobre aprendizagem automática
 - 7.1.7. Conceitos básicos de aprendizagem
 - 7.1.8. Conceitos básicos de aprendizagem não supervisionado
- 7.2. Exploração e pré-processamento de dados
 - 7.2.1. Tratamento de dados
 - 7.2.2. Tratamento de dados no fluxo de análise de dados
 - 7.2.3. Tipos de dados
 - 7.2.4. Transformação de dados
 - 7.2.5. Visualização e exploração de variáveis contínuas
 - 7.2.6. Visualização e exploração de variáveis categóricas
 - 7.2.7. Medidas de correlação
 - 7.2.8. Representações gráficas mais comuns
 - 7.2.9. Introdução à análise multivariada e à redução da dimensionalidade
- 7.3. Árvore de decisão
 - 7.3.1. Algoritmo ID
 - 7.3.2. Algoritmo C
 - 7.3.3. Excesso de treino e poda
 - 7.3.4. Análise dos resultados
- 7.4. Avaliação dos classificadores
 - 7.4.1. Matrizes de confusão
 - 7.4.2. Matrizes de avaliação numérica
 - 7.4.3. Estatística Kappa
 - 7.4.4. A curva ROC

- 7.5. Regras de classificação
 - 7.5.1. Medidas de avaliação das regras
 - 7.5.2. Introdução à representação gráfica
 - 7.5.3. Algoritmo de sobreposição sequencial
- 7.6. Redes neurais
 - 7.6.1. Conceitos básicos
 - 7.6.2. Redes neuronais simples
 - 7.6.3. Algoritmo de *Backpropagation*
 - 7.6.4. Introdução às redes neuronais recorrentes
- 7.7. Métodos bayesianos
 - 7.7.1. Conceitos básicos de probabilidade
 - 7.7.2. Teorema de Bayes
 - 7.7.3. Naive Bayes
 - 7.7.4. Introdução às redes bayesianas
- 7.8. Modelos de regressão e modelos de resposta contínua
 - 7.8.1. Regressão linear simples
 - 7.8.2. Regressão linear múltipla
 - 7.8.3. Regressão logística
 - 7.8.4. Árvores de regressão
 - 7.8.5. Introdução às máquinas de suporte vetorial (SVM)
 - 7.8.6. Medidas de adequação
- 7.9. *Clustering*
 - 7.9.1. Conceitos básicos
 - 7.9.2. *Clustering* hierárquico
 - 7.9.3. Métodos probabilísticos
 - 7.9.4. Algoritmo EM
 - 7.9.5. Método *B-Cubed*
 - 7.9.6. Métodos implícitos
- 7.10. Mineração de texto e processamento linguagem natural(PLN)
 - 7.10.1. Conceitos básicos
 - 7.10.2. Criação do corpus
 - 7.10.3. Análise descritiva
 - 7.10.4. Introdução à análise de sentimentos

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

- 8.1. Aprendizagem Profunda
 - 8.1.1. Tipos de aprendizagem profunda
 - 8.1.2. Aplicações da aprendizagem profunda
 - 8.1.3. Vantagens e desvantagens da aprendizagem profunda
- 8.2. Operações
 - 8.2.1. Adição
 - 8.2.2. Produto
 - 8.2.3. Transferência
- 8.3. Camadas
 - 8.3.1. Camada de entrada
 - 8.3.2. Camada oculta
 - 8.3.3. Camada de saída
- 8.4. Ligação de Camadas e Operações
 - 8.4.1. Design de arquiteturas
 - 8.4.2. Conexão entre camadas
 - 8.4.3. Propagação para a frente
- 8.5. Construção da primeira rede neuronal
 - 8.5.1. Design da rede
 - 8.5.2. Estabelecer os pesos
 - 8.5.3. Treino da rede
- 8.6. Treinador e Otimizador
 - 8.6.1. Seleção do otimizador
 - 8.6.2. Estabelecimento de uma função de perda
 - 8.6.3. Estabelecimento de uma métrica
- 8.7. Aplicação dos Princípios das Redes Neuronais
 - 8.7.1. Funções de ativação
 - 8.7.2. Propagação para trás
 - 8.7.3. Ajuste dos parâmetros
- 8.8. Dos neurónios biológicos aos neurónios artificiais
 - 8.8.1. Funcionamento de um neurónio biológico
 - 8.8.2. Transferência de conhecimentos para os neurónios artificiais
 - 8.8.3. Estabelecer de relações entre os dois

- 8.9. Implementação do MLP (Perceptron Multicamadas) com o Keras
 - 8.9.1. Definição da estrutura da rede
 - 8.9.2. Compilação do modelo
 - 8.9.3. Treino do modelo
- 8.10. Hiperparâmetros de *Fine tuning* de Redes Neurais
 - 8.10.1. Seleção da função de ativação
 - 8.10.2. Estabelecer a *Learning rate*
 - 8.10.3. Ajuste dos pesos

Módulo 9. Treino de redes 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. Geração de dados sintéticos
 - 9.8.3. Transformação de texto
- 9.9. Aplicação Prática de *Transfer Learning*
 - 9.9.1. Treino de transferência de aprendizagem
 - 9.9.2. Extração de características
 - 9.9.3. Aprendizagem profunda
- 9.10. Regularização
 - 9.10.1. L e L
 - 9.10.2. Regularização por entropia máxima
 - 9.10.3. *Dropout*

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

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

- 10.5. Carga de conjuntos de dados com o *TensorFlow*
 - 10.5.1. Carga de conjuntos de dados com o *TensorFlow*
 - 10.5.2. Pré-processamento de dados com o *TensorFlow*
 - 10.5.3. Utilizar de ferramentas do *TensorFlow* para a manipulação de dados
- 10.6. A API *tfdata*
 - 10.6.1. Utilização da API *tfdata* para o processamento de dados
 - 10.6.2. Construção de fluxo de dados com *tfdata*
 - 10.6.3. Utilização da API *tfdata* para o treino de modelos
- 10.7. O formato *TFRecord*
 - 10.7.1. Utilização da API *TFRecord* para a serialização de dados
 - 10.7.2. Carregar arquivos *TFRecord* com *TensorFlow*
 - 10.7.3. Utilização de arquivos *TFRecord* para o treino de modelos
- 10.8. Camadas de pré-processamento do Keras
 - 10.8.1. Utilização da API de pré-processamento do Keras
 - 10.8.2. Construção de *pipelined* de pré-processamento com o Keras
 - 10.8.3. Utilização da API de pré-processamento do Keras para o treino de modelos
- 10.9. O projeto *TensorFlow Datasets*
 - 10.9.1. Utilização de *TensorFlow Datasets* para o carregamento de dados
 - 10.9.2. Pré-processamento de dados com o *TensorFlow Datasets*
 - 10.9.3. Utilização de *TensorFlow Datasets* para o treino de modelos
- 10.10. Construção de uma Aplicação de *Deep Learning* com *TensorFlow*
 - 10.10.1. Aplicação Prática
 - 10.10.2. Construção de uma aplicação de *Deep Learning* com *TensorFlow*
 - 10.10.3. Treino de um modelo com o *TensorFlow*
 - 10.10.4. Utilizar a aplicação para previsão de resultados

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

- 11.1. A Arquitetura *Visual Cortex*
 - 11.1.1. Funções do córtex visual
 - 11.1.2. Teoria da visão computacional
 - 11.1.3. Modelos de processamento de imagens
- 11.2. Camadas convolucionais
 - 11.2.1. Reutilização de pesos na convolução
 - 11.2.2. Convolução D
 - 11.2.3. Funções de ativação



- 11.3. Camadas de agrupamento e implementação de camadas de agrupamento
 - 11.3.1. *Pooling e Striding*
 - 11.3.2. *Flattening*
 - 11.3.3. Tipos de *Pooling*
- 11.4. Arquitetura CNN
 - 11.4.1. Arquitetura VGG
 - 11.4.2. Arquitetura *AlexNet*
 - 11.4.3. Arquitetura *ResNet*
- 11.5. Implementação de uma CNN ResNet- usando Keras
 - 11.5.1. Inicialização de pesos
 - 11.5.2. Definição da camada de entrada
 - 11.5.3. Definição da saída
- 11.6. Utilização de modelos pré-treinados do Keras
 - 11.6.1. Características dos modelos pré-treinados
 - 11.6.2. Usos dos modelos pré-treinados
 - 11.6.3. Vantagens dos modelos pré-treinados
- 11.7. Modelos pré-treinados para a aprendizagem por transferência
 - 11.7.1. A Aprendizagem por transferência
 - 11.7.2. Processo de aprendizagem por transferência
 - 11.7.3. Vantagens do aprendizagem por transferência
- 11.8. Classificação e Localização em *Deep Computer Vision*
 - 11.8.1. Classificação de imagens
 - 11.8.2. Localização de objetos em imagens
 - 11.8.3. Detecção de objetos
- 11.9. Detecção e seguimento de objetos
 - 11.9.1. Métodos de detecção de objetos
 - 11.9.2. Algoritmos de seguimento de objetos
 - 11.9.3. Técnicas de seguimento e localização
- 11.10. Segmentação semântica
 - 11.10.1. Aprendizagem profunda para a segmentação semântica
 - 11.10.2. Detecção de bordas
 - 11.10.3. Métodos de segmentação baseado sem regras

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

- 12.1. Geração de texto utilizando RNN
 - 12.1.1. Treino de uma RNN para geração de texto
 - 12.1.2. Geração de linguagem natural com RNN
 - 12.1.3. Aplicações de geração de texto com RNN
- 12.2. Criação de conjuntos de dados de treino
 - 12.2.1. Preparação dos dados para o treino de uma RNN
 - 12.2.2. Armazenamento do conjunto de dados de treino
 - 12.2.3. Limpeza e transformação dos dados
 - 12.2.4. Análise de Sentimento
- 12.3. Classificação da opiniões com RNN
 - 12.3.1. Detecção de temas nos comentários
 - 12.3.2. Análise de sentimento com algoritmos de aprendizagem profunda
- 12.4. Rede codificadora-descodificadora para a tradução automática neural
 - 12.4.1. Treino de uma RNN para a tradução automática
 - 12.4.2. Utilização de uma rede *encoder-decoder* para a tradução automática
 - 12.4.3. Melhoria da precisão da tradução automática com RNNs
- 12.5. Mecanismos de atenção
 - 12.5.1. Implementação de mecanismos de atenção em RNN
 - 12.5.2. Utilização de mecanismos de atenção para melhorar a precisão dos modelos
 - 12.5.3. Vantagens dos mecanismos de atenção nas redes 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*. Comparativo
 - 12.9.1. Comparação entre as diferentes bibliotecas de *Transformers*
 - 12.9.2. Uso das outras bibliotecas de *Transformers*
 - 12.9.3. Vantagens das outras bibliotecas de *Transformers*
- 12.10. Desenvolvimento de uma aplicação de PLN com RNN e Atenção. Aplicação Prática
 - 12.10.1. Desenvolvimento de uma aplicação de processamento de linguagem natural com RNN e RNN e atenção
 - 12.10.2. Utilização de RNN, mecanismos de atenção e modelos *Transformers* na aplicação
 - 12.10.3. Avaliação da aplicação prática

Módulo 13. Autoencoders, GANs, e Modelos de Difusão

- 13.1. Representação de dados eficientes
 - 13.1.1. Redução da dimensionalidade
 - 13.1.2. Aprendizagem profunda
 - 13.1.3. Representações compactas
- 13.2. Realização da PCA com um codificador automático linear incompleto
 - 13.2.1. Processo de treino
 - 13.2.2. Implementação em Python
 - 13.2.3. Utilização de dados de teste
- 13.3. Codificadores automáticos empilhados
 - 13.3.1. Redes 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. Geração de imagens
 - 13.8.3. Treino de redes neuronais profundas
- 13.9. Redes generativas antagónicas e modelos de difusão
 - 13.9.1. Geração de conteúdos a partir de imagens
 - 13.9.2. Modelação de distribuições de dados
 - 13.9.3. Utilização de redes contraditórias
- 13.10. Implementação dos Modelos
 - 13.10.1. Aplicação Prática
 - 13.10.2. Implementação dos modelos
 - 13.10.3. Utilização de dados reais
 - 13.10.4. Avaliação dos resultados

Módulo 14. Computação bioinspirada

- 14.1. Introdução à computação bioinspirada
 - 14.1.1. Introdução à computação bioinspirada
- 14.2. Algoritmos de inspiração social
 - 14.2.1. Computação bioinspirada baseada em colónias de formigas
 - 14.2.2. Variantes dos algoritmos de colónias de formigas
 - 14.2.3. Computação baseada em nuvens de partículas
- 14.3. Algoritmos genéticos
 - 14.3.1. Estrutura geral
 - 14.3.2. Implementações dos principais operadores
- 14.4. Estratégias de exploração do espaço para algoritmos genéticos
 - 14.4.1. Algoritmo CHC
 - 14.4.2. Problemas multimodais
- 14.5. Modelos de computação evolutiva
 - 14.5.1. Estratégias evolutivas
 - 14.5.2. Programação evolutiva
 - 14.5.3. Algoritmos baseados em evolução diferencial

- 14.6. Modelos de computação evolutiva (II)
 - 14.6.1. Modelos de evolução baseados na estimativa das distribuições (EDA)
 - 14.6.2. Programação genética
- 14.7. Programação evolutiva aplicada a problemas de aprendizagem
 - 14.7.1. A aprendizagem baseada em regras
 - 14.7.2. Métodos evolutivos em problemas de seleção de exemplos
- 14.8. Problemas multiobjetivo
 - 14.8.1. Conceito de dominância
 - 14.8.2. Aplicação de algoritmos evolutivos a problemas multiobjetivos
- 14.9. Redes 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. Indústrias
 - 15.5.1. Implicações da IA na Indústria. Oportunidades e desafios
 - 15.5.2. Casos de utilização
- 15.6. Potenciais riscos relacionados com a utilização de IA na Indústria
 - 15.6.1. Casos de utilização
 - 15.6.2. Potenciais riscos relacionados com a utilização de IA
 - 15.6.3. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.7. Administração pública
 - 15.7.1. Implicações da IA na Administração pública. Oportunidades e desafios
 - 15.7.2. Casos de utilização
 - 15.7.3. Potenciais riscos relacionados com a utilização de IA
 - 15.7.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.8. Educação
 - 15.8.1. Implicações da IA na educação. Oportunidades e desafios
 - 15.8.2. Casos de utilização
 - 15.8.3. Potenciais riscos relacionados com a utilização de IA
 - 15.8.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.9. Silvicultura e agricultura
 - 15.9.1. Implicações da IA na Indústria 4.0 Oportunidades e desafios
 - 15.9.2. Casos de utilização
 - 15.9.3. Potenciais riscos relacionados com a utilização de IA
 - 15.9.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.10. Recursos Humanos
 - 15.10.1. Implicações da IA nos Recursos Humanos Oportunidades e desafios
 - 15.10.2. Casos de utilização
 - 15.10.3. Potenciais riscos relacionados com a utilização de IA
 - 15.10.4. Potenciais desenvolvimentos/utilizações futuras da IA

Módulo 16. Inovações de Inteligência Artificial em Diagnóstico por Imagem

- 16.1. Tecnologias e ferramentas de Inteligência Artificial no Diagnóstico por Imagem com o IBM Watson Imaging Clinical Review
 - 16.1.1. Plataformas de software líderes para análise de imagens médicas
 - 16.1.2. Ferramentas de Deep Learning específicas para radiologia
 - 16.1.3. Inovações de hardware para acelerar o processamento de imagens
 - 16.1.4. Integração de sistemas de Inteligência Artificial nas infra-estruturas hospitalares existentes
- 16.2. Métodos estatísticos e algoritmos para interpretação de imagens médicas com DeepMind AI for Breast Cancer Analysis
 - 16.2.1. Algoritmos de segmentação de imagens
 - 16.2.2. Técnicas de classificação e detecção em imagiologia médica
 - 16.2.3. Utilização de Redes Neurais Convolucionais em Radiologia
 - 16.2.4. Métodos de redução do ruído e de melhoria da qualidade da imagem
- 16.3. Conceção de experiências e análise de resultados no domínio do diagnóstico por imagem com a API Google Cloud Healthcare
 - 16.3.1. Conceção de protocolos de validação de algoritmos de Inteligência Artificial.
 - 16.3.2. Métodos estatísticos para comparar o desempenho da Inteligência Artificial e radiologistas
 - 16.3.3. Criação de estudos multicêntricos para ensaios de Inteligência Artificial
 - 16.3.4. Interpretação e apresentação dos resultados dos testes de eficácia
- 16.4. Detecção de padrões subtis em imagens de baixa resolução
 - 16.4.1. Inteligência artificial para o diagnóstico precoce de doenças neurodegenerativas
 - 16.4.2. Aplicações de Inteligência Artificial em Cardiologia Intervencionista
 - 16.4.3. Utilização de Inteligência Artificial para otimização de protocolos de imagiologia
- 16.5. Análise e processamento de imagens biomédicas
 - 16.5.1. Técnicas de pré-processamento para melhorar a interpretação automática
 - 16.5.2. Análise de texturas e padrões em imagens histológicas
 - 16.5.3. Extração de características clínicas a partir de imagens de ultra-sons
 - 16.5.4. Métodos de análise de imagens longitudinais em estudos clínicos
- 16.6. Visualização avançada de dados em diagnóstico por imagem com o OsiriX MD
 - 16.6.1. Desenvolvimento de interfaces gráficas para a exploração de imagens 3D
 - 16.6.2. Ferramentas para visualizar alterações temporais em imagens médicas
 - 16.6.3. Técnicas de realidade aumentada para o ensino da anatomia
 - 16.6.4. Sistemas de visualização em tempo real para procedimentos cirúrgicos
- 16.7. Processamento de linguagem natural em relatórios e documentação de imagens médicas com o Nuance PowerScribe 360
 - 16.7.1. Geração automática de relatórios radiológicos
 - 16.7.2. Extração de informações relevantes de registos médicos electrónicos
 - 16.7.3. Análise semântica para correlacionar achados imagiológicos e clínicos
 - 16.7.4. Ferramentas de pesquisa e recuperação de imagens baseadas em descrições textuais
- 16.8. Integração e processamento de dados heterogéneos na imagiologia médica
 - 16.8.1. Fusões de modalidades de imagem para diagnósticos abrangentes
 - 16.8.2. Integração de dados laboratoriais e genéticos na análise de imagens
 - 16.8.3. Sistemas para o tratamento de grandes volumes de dados de imagem
 - 16.8.4. Estratégias para a normalização de *datasets* de várias fontes
- 16.9. Aplicações de redes neurais na interpretação de imagens médicas com Zebra Medical Vision
 - 16.9.1. Utilização de redes generativas para imagiologia médica sintética
 - 16.9.2. Redes Neurais para Classificação Automática de Tumores
 - 16.9.3. *Deep Learning* para análise de séries temporais em imagens funcionais
 - 16.9.4. Adaptação de modelos pré-treinados em *datasets* específicos da imagiologia médica
- 16.10. Modelação preditiva e o seu impacto no diagnóstico por imagem com o IBM Watson Oncology
 - 16.10.1. Modelos preditivos para avaliação do risco em doentes oncológicos
 - 16.10.2. Ferramentas preditivas para a monitorização de doenças crónicas
 - 16.10.3. Análise de sobrevivência utilizando dados de imagiologia médica
 - 16.10.4. Previsão da progressão da doença por meio de *Machine Learning*



Módulo 17. Aplicações Avançadas de IA em Estudos e Análise de Imagens Médicas

- 17.1. Conceção e execução de estudos observacionais utilizando Inteligência Artificial em imagiologia médica com a Flatiron Health
 - 17.1.1. Critérios de seleção de populações em estudos observacionais de Inteligência Artificial
 - 17.1.2. Métodos de controlo de variáveis de confusão em estudos de imagiologia
 - 17.1.3. Estratégias de acompanhamento a longo prazo em estudos observacionais
 - 17.1.4. Análise de resultados e validação de modelos de Inteligência Artificial em contextos clínicos reais
- 17.2. Validação e calibração de modelos de IA na interpretação de imagens com Arterys Cardio AI
 - 17.2.1. Técnicas de validação cruzada aplicadas a modelos de Diagnóstico por Imagem
 - 17.2.2. Métodos de calibração de probabilidades em previsões de Inteligência Artificial
 - 17.2.3. Normas de desempenho e métricas de exatidão para a avaliação da IA de Inteligência Artificial
 - 17.2.4. Aplicação de testes de robustez em diferentes populações e condições.
- 17.3. Métodos de integração de dados de imagiologia com outras fontes biomédicas
 - 17.3.1. Técnicas de fusão de dados para melhorar a interpretação de imagens
 - 17.3.2. Análise conjunta de imagens e dados genómicos para diagnósticos precisos
 - 17.3.3. Integração da informação clínica e laboratorial na Inteligência Artificial
 - 17.3.4. Desenvolvimento de interfaces de utilizador para a visualização integrada de dados multidisciplinares
- 17.4. Utilização de dados de imagiologia médica na investigação multidisciplinar com o Enlitic Curie
 - 17.4.1. Colaboração interdisciplinar para análise avançada de imagens
 - 17.4.2. Aplicação de técnicas de inteligência artificial de outros domínios no diagnóstico por imagem
 - 17.4.3. Desafios e soluções na gestão de dados grandes e heterogéneos
 - 17.4.4. Estudos de casos de aplicações multidisciplinares bem sucedidas
- 17.5. Algoritmos de aprendizagem profunda específicos para imagiologia médica com AIDOC
 - 17.5.1. Desenvolvimento de arquitecturas de redes neuronais para imagens específicas
 - 17.5.2. Otimização de hiperparâmetros para modelos de imagiologia médica
 - 17.5.3. Transferência de Aprendizagem e sua aplicabilidade em Radiologia

- 17.6. Desafios na interpretação e visualização de características aprendidas por modelação profunda
 - 17.6.1. Otimizar a interpretação de imagens médicas através da automatização com Viz.ai
 - 17.6.2. Automatização de rotinas de diagnóstico para eficiência operacional
 - 17.6.3. Sistemas de alerta precoce na deteção de anomalias
 - 17.6.4. Reduzir a carga de trabalho dos radiologistas utilizando ferramentas de Inteligência Artificial
 - 17.6.5. O impacto da automatização na precisão e rapidez dos diagnósticos
- 17.7. Simulação e modelação computacional em diagnóstico por imagem
 - 17.7.1. Simulações para treino e validação de algoritmos de IA
 - 17.7.2. Modelação de doenças e sua representação em imagens sintéticas
 - 17.7.3. Utilização de simulações para o planeamento de tratamentos e cirurgias
 - 17.7.4. Avanços em técnicas computacionais para o processamento de imagens em tempo real
- 17.8. Realidade virtual e aumentada na visualização e análise de imagens médicas
 - 17.8.1. Aplicações de realidade virtual para o ensino de diagnóstico por imagem
 - 17.8.2. Utilização de Realidade Aumentada em procedimentos cirúrgicos guiados por imagem
 - 17.8.3. Ferramentas de visualização avançadas para o planeamento terapêutico
 - 17.8.4. Desenvolvimento de interfaces imersivas para a revisão de estudos radiológicos
- 17.9. Ferramentas de extração de dados aplicadas ao diagnóstico por imagem com radiómica
 - 17.9.1. Técnicas de extração de dados de grandes repositórios de imagens médicas
 - 17.9.2. Aplicações de análise de padrões em coleções de dados de imagem
 - 17.9.3. Identificação de biomarcadores através da extração de dados de imagens
 - 17.9.4. Integrar a extração de dados e a aprendizagem automática para descobertas clínicas
- 17.10. Desenvolvimento e validação de biomarcadores utilizando a análise de imagens com Oncimmune
 - 17.10.1. Estratégias para identificar biomarcadores imagiológicos em várias doenças
 - 17.10.2. Validação clínica de biomarcadores imagiológicos para utilização diagnóstica
 - 17.10.3. Impacto dos biomarcadores de imagem na personalização do tratamento
 - 17.10.4. Tecnologias emergentes na deteção e análise de biomarcadores através da Inteligência Artificial.

Módulo 18. Personalização e automatização do diagnóstico médico através da inteligência artificial

- 18.1. Aplicação de Inteligência Artificial na sequenciação genómica e correlação com achados imagiológicos com Fabric Genomics
 - 18.1.1. Técnicas de inteligência artificial para a integração de dados genómicos e de imagiologia
 - 18.1.2. Modelos preditivos para correlacionar variantes genéticas com patologias visíveis por imagem
 - 18.1.3. Desenvolvimento de algoritmos para a análise automática de sequências e sua representação em imagens
 - 18.1.4. Estudos de casos sobre o impacto clínico da genómica e da fusão de imagens
- 18.2. Avanços em Inteligência Artificial para análise detalhada de imagens biomédicas com PathAI
 - 18.2.1. Inovações nas técnicas de processamento e análise de imagens a nível celular
 - 18.2.2. Aplicação de Inteligência Artificial para melhorar a resolução em imagens de microscopia
 - 18.2.3. Algoritmos de *Deep Learning* especializada na deteção de padrões submicroscópicos
 - 18.2.4. Impacto dos avanços da Inteligência Artificial na investigação biomédica e no diagnóstico clínico
- 18.3. Automação na aquisição e processamento de imagens médicas com a Butterfly Network
 - 18.3.1. Sistemas automatizados para a otimização dos parâmetros de aquisição de imagem
 - 18.3.2. Inteligência artificial na gestão e manutenção de equipamentos de imagiologia
 - 18.3.3. Algoritmos para processamento de imagens em tempo real durante procedimentos médicos
 - 18.3.4. Histórias de sucesso na implementação de sistemas automatizados em hospitais e clínicas
- 18.4. Personalização do diagnóstico através da Inteligência Artificial e da medicina de precisão com Tempus AI
 - 18.4.1. Modelos de Inteligência Artificial para diagnósticos personalizados baseados em perfis genéticos e de imagem
 - 18.4.2. Estratégias para a integração de dados clínicos e de imagiologia no planeamento terapêutico
 - 18.4.3. Impacto da medicina de precisão nos resultados clínicos através da IA
 - 18.4.4. Desafios éticos e práticos na implementação da medicina personalizada

- 18.5. Inovações no diagnóstico assistido por IA com a Caption Health
 - 18.5.1. Desenvolvimento de novas ferramentas de Inteligência Artificial para a detecção precoce de doenças
 - 18.5.2. Avanços nos algoritmos de Inteligência Artificial para a interpretação de patologias complexas
 - 18.5.3. Integração do diagnóstico assistido por IA Integração do diagnóstico assistido por IA na prática clínica de rotina
 - 18.5.4. Avaliação da eficácia e da aceitação da Inteligência Artificial de diagnóstico pelos profissionais de saúde
- 18.6. Aplicações de Inteligência Artificial na análise de imagens do microbioma com DayTwo AI
 - 18.6.1. Técnicas de Inteligência Artificial para análise de imagens em estudos de microbioma
 - 18.6.2. Correlação dos dados de imagiologia do microbioma com indicadores de saúde
 - 18.6.3. Impacto dos resultados do microbioma nas decisões terapêuticas
 - 18.6.4. Desafios na normalização e validação de imagens do microbioma
- 18.7. Uso de *wearables* para melhorar a interpretação das imagens de diagnóstico com o AliveCor
 - 18.7.1. Integração de dados *wearables* com imagiologia médica para um diagnóstico completo
 - 18.7.2. Algoritmos de IA para análise de dados contínuos e representação de imagens
 - 18.7.3. Inovações tecnológicas em *wearables* para monitorização da saúde
 - 18.7.4. Estudos de casos sobre a melhoria da qualidade de vida através de *wearables* e diagnósticos por imagem
- 18.8. Inteligência artificial para gerir dados de diagnóstico por imagem em ensaios clínicos
 - 18.8.1. Ferramentas de IA para uma gestão eficiente de grandes volumes de dados de imagem
 - 18.8.2. Estratégias para garantir a qualidade e integridade dos dados em estudos multicêntricos
 - 18.8.3. Aplicações de Inteligência Artificial para análise preditiva em ensaios clínicos
 - 18.8.4. Desafios e oportunidades na normalização dos protocolos de imagiologia em ensaios globais
- 18.9. Desenvolvimento de tratamentos e vacinas com a ajuda da Inteligência Artificial avançada
 - 18.9.1. Utilização da Inteligência Artificial para conceber tratamentos personalizados com base em dados clínicos e de imagiologia
 - 18.9.2. Modelos de Inteligência Artificial no Desenvolvimento Acelerado de Vacinas com Apoio ao Diagnóstico por Imagem
 - 18.9.3. Avaliação da eficácia dos tratamentos através da monitorização de imagens

- 18.9.4. Impacto da Inteligência Artificial na redução do tempo e dos custos no desenvolvimento de novas terapias

- 18.10. Aplicações de IA em imunologia e estudos de resposta imunitária com ImmunoMind
 - 18.10.1. Modelos de IA para a interpretação de imagens relacionadas com a resposta imunitária
 - 18.10.2. Integração de dados de imagiologia e análise imunológica para diagnósticos exactos
 - 18.10.3. Desenvolvimento de biomarcadores de imagiologia para doenças auto-imunes
 - 18.10.4. Avanços na personalização dos tratamentos imunológicos através da utilização da Inteligência Artificial

Módulo 19. *Big Data* e Análise Preditiva em Imagiologia Médica

- 19.1. *Big Data* em Diagnóstico por imagem: conceitos e ferramentas com GE Healthcare Edison
 - 19.1.1. Fundamentos de *Big Data* aplicado à imagiologia
 - 19.1.2. Ferramentas e plataformas para o tratamento de grandes volumes de dados de imagem
 - 19.1.3. Desafios na integração e análise de *Big Data* em Imagiologia
 - 19.1.4. Casos de utilização de *Big Data* em diagnóstico por imagem
- 19.2. Extração de dados de registos de imagiologia biomédica com o IBM Watson Imaging
 - 19.2.1. Técnicas avançadas de extração de dados para identificar padrões em imagens médicas
 - 19.2.2. Estratégias para extrair características relevantes de grandes bases de dados de imagens
 - 19.2.3. Aplicações de *clustering* e classificação em registos de imagem
 - 19.2.4. Impacto da extração de dados na melhoria dos diagnósticos e tratamentos
- 19.3. Algoritmos de aprendizagem automática na análise de imagens com o Google DeepMind Health
 - 19.3.1. Desenvolvimento de algoritmos supervisionados e não supervisionados para imagiologia médica
 - 19.3.2. Inovações em técnicas de aprendizagem automática para o reconhecimento de padrões de doenças
 - 19.3.3. Aplicações de aprendizagem profunda na segmentação e classificação de imagens
 - 19.3.4. Avaliação da eficácia e da precisão dos algoritmos de aprendizagem automática em estudos clínicos

- 19.4. Técnicas de análise preditiva aplicadas ao diagnóstico por imagem com a Predictive Oncology
 - 19.4.1. Modelos preditivos para a identificação precoce de doenças a partir de imagens
 - 19.4.2. Utilização de análises preditivas para monitorização e avaliação do tratamento
 - 19.4.3. Integração de dados clínicos e de imagiologia para enriquecer os modelos de previsão
 - 19.4.4. Desafios na implementação de técnicas preditivas na prática clínica
- 19.5. Modelos de Inteligência Artificial baseados em imagens para Epidemiologia com BlueDot
 - 19.5.1. Aplicação da Inteligência Artificial na análise de surtos epidémicos utilizando imagens
 - 19.5.2. Modelos de propagação de doenças visualizados por técnicas de imagiologia
 - 19.5.3. Correlação entre dados epidemiológicos e achados imagiológicos
 - 19.5.4. Contribuição da Inteligência Artificial para o estudo e controlo das pandemias
- 19.6. Análise de redes biológicas e padrões de doenças a partir de imagens
 - 19.6.1. Aplicação da teoria das redes na análise de imagens para a compreensão das patologias
 - 19.6.2. Modelos computacionais para simular redes biológicas visíveis em imagens
 - 19.6.3. Integração da análise de imagens e de dados moleculares para mapear doenças
 - 19.6.4. Impacto destas análises no desenvolvimento de terapias personalizadas
- 19.7. Desenvolvimento de ferramentas de prognóstico clínico baseadas em imagens
 - 19.7.1. Ferramentas de Inteligência Artificial para a previsão da evolução clínica a partir de imagens de diagnóstico
 - 19.7.2. Avanços na elaboração de relatórios de previsão automatizados
 - 19.7.3. Integração de modelos de prognóstico em sistemas clínicos
 - 19.7.4. Validação e aceitação clínica de ferramentas de prognóstico baseadas em IA
- 19.8. Visualização e comunicação avançadas de dados complexos com o Tableau
 - 19.8.1. Técnicas de visualização para representação multidimensional de dados de imagem
 - 19.8.2. Ferramentas interactivas para navegar em grandes conjuntos de dados de imagens
 - 19.8.3. Estratégias para a comunicação eficaz de resultados complexos através de visualizações
 - 19.8.4. Impacto da visualização avançada na educação médica e na tomada de decisões
- 19.9. Segurança dos dados e desafios da gestão de *Big Data*
 - 19.9.1. Medidas de segurança para proteger grandes volumes de dados de imagiologia médica
 - 19.9.2. Desafios em matéria de privacidade e ética na gestão de dados de imagem em grande escala

- 19.9.3. Soluções tecnológicas para a gestão segura de *Big Data* da saúde
- 19.9.4. Estudos de caso sobre violações de segurança e como foram resolvidas
- 19.10. Aplicações práticas e estudos de casos em *Big Data* biomédico
 - 19.10.1. Exemplos de aplicações bem sucedidas de *Big Data* no diagnóstico e tratamento de doenças
 - 19.10.2. Estudos de caso sobre a integração de *Big Data* nos sistemas de saúde
 - 19.10.3. Lições aprendidas de projetos de *Big Data* no sector biomédico
 - 19.10.4. Direções futuras e potencialidades de *Big Data* na medicina

Módulo 20. Aspectos éticos e jurídicos da inteligência artificial no diagnóstico por imagem

- 20.1. Ética na aplicação da inteligência artificial no diagnóstico por imagem com *Ethics and Algorithms Toolkit*
 - 20.1.1. Princípios éticos fundamentais na utilização da Inteligência Artificial no diagnóstico
 - 20.1.2. Gestão dos enviesamentos algorítmicos e do seu impacto na equidade do diagnóstico
 - 20.1.3. Consentimento informado na era da Inteligência Artificial de diagnóstico
 - 20.1.4. Desafios éticos na implantação internacional de tecnologias de Inteligência Artificial
- 20.2. Considerações legais e regulamentares sobre a Inteligência Artificial aplicada à imagiologia médica com Compliance.ai
 - 20.2.1. Quadro regulamentar atual para a Inteligência Artificial no diagnóstico por imagem
 - 20.2.2. Conformidade com os regulamentos de privacidade e proteção de dados
 - 20.2.3. Requisitos de validação e certificação para algoritmos de Inteligência Artificial nos cuidados de saúde
 - 20.2.4. Responsabilidade jurídica em caso de diagnóstico incorreto por parte da Inteligência Artificial
- 20.3. Consentimento informado e aspectos éticos na utilização de dados clínicos
 - 20.3.1. Revisão dos processos de consentimento informado adaptados à Inteligência Artificial
 - 20.3.2. Educação dos doentes sobre a utilização da Inteligência Artificial nos cuidados de saúde
 - 20.3.3. Transparência na utilização de dados clínicos para formação em Inteligência Artificial
 - 20.3.4. Respeito pela autonomia dos doentes nas decisões baseadas na IA
- 20.4. Inteligência artificial e responsabilidade na investigação clínica
 - 20.4.1. Atribuição de responsabilidades na utilização da Inteligência Artificial para o diagnóstico
 - 20.4.2. Implicações dos bugs de Inteligência Artificial na prática clínica
 - 20.4.3. Seguros e cobertura dos riscos associados à utilização da Inteligência Artificial
 - 20.4.4. Estratégias para a gestão de incidentes relacionados com a IA

- 20.5. O impacto da inteligência artificial na equidade e no acesso aos cuidados de saúde com a AI for Good
 - 20.5.1. Avaliar o impacto da Inteligência Artificial na distribuição de serviços médicos
 - 20.5.2. Estratégias para garantir um acesso equitativo à tecnologia de IA
 - 20.5.3. A inteligência artificial como ferramenta para reduzir as disparidades no domínio da saúde
 - 20.5.4. Estudos de caso sobre a implementação da Inteligência Artificial em ambientes com recursos limitados
- 20.6. Privacidade e proteção de dados em projectos de investigação com Duality SecurePlus
 - 20.6.1. Estratégias para garantir a confidencialidade dos dados em projectos de Inteligência Artificial
 - 20.6.2. Técnicas avançadas para a anonimização dos dados dos doentes
 - 20.6.3. Desafios jurídicos e éticos na proteção de dados pessoais
 - 20.6.4. Impacto das violações de segurança na confiança do público
- 20.7. Inteligência Artificial e sustentabilidade na investigação biomédica com o Algoritmo Verde
 - 20.7.1. Utilizar a Inteligência Artificial para melhorar a eficiência e a sustentabilidade na investigação
 - 20.7.2. Avaliação do ciclo de vida das tecnologias de Inteligência Artificial nos cuidados de saúde
 - 20.7.3. Impacto ambiental da infraestrutura tecnológica da Inteligência Artificial
 - 20.7.4. Práticas sustentáveis no desenvolvimento e implantação da Inteligência Artificial
- 20.8. Auditoria e explicabilidade dos modelos de Inteligência Artificial no contexto clínico com o IBM AI Fairness 360
 - 20.8.1. Importância da auditoria regular dos algoritmos de IA
 - 20.8.2. Técnicas para melhorar a explicabilidade dos modelos de Inteligência Artificial
 - 20.8.3. Desafios na comunicação das decisões baseadas em IA aos doentes e aos médicos
 - 20.8.4. Regulamentos sobre a transparência dos algoritmos de Inteligência Artificial
- 20.9. Inovação e empreendedorismo no domínio da Inteligência Artificial clínica com a Hindsait
 - 20.9.1. Oportunidades para *startups* em tecnologias de inteligência artificial para a saúde
 - 20.9.2. Colaboração público-privada no desenvolvimento da Inteligência Artificial
 - 20.9.3. Desafios para os empresários no quadro regulamentar da saúde
 - 20.9.4. Histórias de sucesso e lições aprendidas no empreendedorismo da IA clínica
- 20.10. Considerações éticas na colaboração internacional em investigação clínica com a Aliança Global para a Genómica e a Saúde (GA4GH)
 - 20.10.1. Coordenação ética em projectos internacionais de IA
 - 20.10.2. Gerir as diferenças culturais e regulamentares nas parcerias internacionais
 - 20.10.3. Estratégias para uma inclusão equitativa nos estudos globais
 - 20.10.4. Desafios e soluções no intercâmbio de dados




Pretende aumentar a sua segurança na tomada de decisões clínicas através da utilização da Inteligência Artificial? Com este programa universitário, em menos de um ano será possível"

06

Metodologia

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

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





“

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

Estudo de Caso para contextualizar todo o conteúdo

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

“

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



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



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

Um método de aprendizagem inovador e diferente

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

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

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

Numa dada situação, o que deve fazer um profissional? Esta é a questão que enfrentamos no método do caso, um método de aprendizagem orientado para a ação.

Ao longo do Curso, os estudantes serão confrontados com múltiplos casos da vida real. Terão de integrar todo o seu conhecimento, investigar, argumentar e defender as suas ideias e decisões.

Relearning Methodology

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

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

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

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

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



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

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

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

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

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



Material de estudo

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

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



Masterclasses

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

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




Estágios de aptidões e competências


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



Leituras complementares

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



**Case studies**

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

**Resumos interativos**

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

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

**Testing & Retesting**

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



07

Certificação

O Mestrado em Inteligência Artificial no Diagnóstico por imagem garante, para além de um conteúdo mais rigoroso e atualizado, o acesso a uma certificação a título próprio emitida pela TECH Global University.



“

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

Este programa permitirá a obtenção do certificado do **Mestrado em Inteligência Artificial no Diagnóstico por imagem** 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 ([boletim oficial](#)). 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 académicos.


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

Certificação: **Mestrado em Inteligência Artificial em Diagnóstico por imagem**

Modalidade: **online**

Duração: **12 meses**

Créditos: **90 ECTS**



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

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



Mestrado Inteligência Artificial em Diagnóstico por Imagem

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

Mestrado

Inteligência Artificial em Diagnóstico por Imagem

