

Mestrado Próprio

Inteligência Artificial na Prática Clínica



Mestrado Próprio Inteligência Artificial na Prática Clínica

- » Modalidade: online
- » Duração: 12 meses
- » Certificação: TECH Universidade Tecnológica
- » Horário: ao seu próprio ritmo
- » Exames: online

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

Índice

01

Apresentação

pág. 4

02

Objetivos

pág. 8

03

Competências

pág. 18

04

Direção do curso

pág. 22

05

Estrutura e conteúdo

pág. 26

06

Metodologia

pág. 44

07

Certificação

pág. 54

01

Apresentação

A Inteligência Artificial (IA) desempenha um papel cada vez mais importante tanto na investigação clínica como na atenção médica. Entre as razões, destaca-se o facto de esses sistemas ajudarem na identificação de patologias através da análise de imagens médicas (como radiografias ou tomografias computadorizadas). Assim, os especialistas podem detetar anomalias com maior precisão e rapidez. Por sua vez, isto implica um diagnóstico mais precoce e até a deteção de doenças em estádios iniciais. Neste contexto, a TECH lançou uma qualificação universitária que aprofundará a integração da Aprendizagem Automática na área clínica. Além disso, baseia-se numa metodologia 100% online para que os estudantes possam conciliar os seus estudos com as restantes atividades diárias.



“

Analisaré como a IA interpreta dados genéticos para desenhar estratégias terapêuticas específicas, graças a este plano de estudos 100% online”

A análise de *Big Data* melhora significativamente a assistência médica e a investigação na área da saúde. Esses sistemas avançados proporcionam aos especialistas a oportunidade de personalizar os tratamentos. Informações dos pacientes, como o seu historial médico, genética ou estilo de vida, são utilizadas para adaptar os planos terapêuticos e medicamentos de forma individualizada. Além disso, essas ferramentas contribuem para realizar um monitoramento contínuo dos pacientes fora do ambiente clínico, o que se revela especialmente vantajoso para os utilizadores que sofrem de condições crónicas. Assim, os recursos da IA contribuem para o desenvolvimento de procedimentos de abordagem mais eficazes e com uma atenção mais segura.

Por isso, a TECH desenhou um Mestrado Próprio que aprofundará a análise de *Big Data* e Aprendizagem Automática na Investigação Clínica. O plano de estudos abordará tópicos como a Mineração de dados, tanto em registos clínicos como biomédicos, ao mesmo tempo que se foca em algoritmos e fornece técnicas de análise preditiva. Por outro lado, a formação explorará as interações que ocorrem nas redes biológicas para a identificação de padrões de doença. Além disso, o plano de estudos dará especial atenção aos fatores éticos e legais da IA no contexto médico. Desta forma, os estudantes adquirirão uma consciência responsável ao realizar os seus procedimentos.

É importante destacar que, para consolidar todo esse conteúdo, a TECH recorre à revolucionária metodologia de *Relearning*. Este sistema de ensino baseia-se na repetição de conceitos-chave, para consolidar uma compreensão ótima. O único requisito para os alunos é ter um dispositivo eletrónico (como um telemóvel, computador ou tablet) ligado à Internet, para poderem aceder ao Campus Virtual e visualizar os conteúdos a qualquer momento. Assim, aprenderão no conforto das suas casas, sem necessidade de presença física e de horários predefinidos.

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

- ♦ O desenvolvimento de casos práticos apresentados por especialistas em Inteligência Artificial na Prática Clínica
- ♦ Os conteúdos gráficos, esquemáticos e eminentemente práticos com os quais o curso foi concebido reúnem informação científica e prática sobre as disciplinas indispensáveis para o exercício profissional
- ♦ Os exercícios práticos onde o processo de autoavaliação pode ser efetuado a fim de melhorar a aprendizagem
- ♦ O seu foco especial em metodologias inovadoras
- ♦ As aulas teóricas, perguntas ao especialista, fóruns de discussão sobre questões controversas e atividades de reflexão individual
- ♦ A disponibilidade de acesso aos conteúdos a partir de qualquer dispositivo fixo ou portátil com conexão à Internet



Dominará o TensorFlow Datasets para o carregamento de dados e conseguirá um pré-processamento eficiente de dados médicos graças a esta qualificação

“

*Estará na vanguarda no campo médico!
Esta especialização funde a excelência
clínica com a revolução tecnológica da
Aprendizagem Automática”*

*A estrutura modular da qualificação
permitirá uma progressão coerente,
desde os fundamentos até às
aplicações mais avançadas.*

*Esqueça a memorização! Com o sistema
de Relearning, integrará os conceitos de
forma natural e progressiva.*

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

O seu conteúdo multimédia, elaborado com a última tecnologia educativa, permitirá ao profissional um aprendizado situado e contextual, ou seja, um ambiente simulado que proporcionará uma capacitação imersiva programada para se treinar em situações reais.

O design deste curso 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 Mestrado Próprio transformará os alunos em autênticos líderes, capazes de superar os desafios atuais e futuros na Medicina. Os alunos terão um entendimento profundo sobre a IA, o que contribuirá para o desenvolvimento de soluções inovadoras para transformar a assistência médica. Desta forma, os profissionais aplicarão técnicas de análise de dados médicos, o desenvolvimento de modelos preditivos para ensaios clínicos e a implementação de soluções inovadoras para a personalização de tratamentos.




“


Ponha em dia a sua prática clínica diária para estar na vanguarda da revolução tecnológica em saúde, contribuindo para o avanço da Prática Clínica”



Objetivos gerais

- ♦ Compreender os fundamentos teóricos da Inteligência Artificial
- ♦ Estudar os diferentes tipos de dados e compreender o ciclo de vida dos dados
- ♦ Avaliar o papel crucial dos dados no desenvolvimento e implementação de soluções de Inteligência Artificial
- ♦ Aprofundar a compreensão dos algoritmos e da complexidade para resolver problemas específicos
- ♦ Explorar a base teórica das redes neurais para o desenvolvimento da *Deep Learning*
- ♦ Analisar a computação bioinspirada e a sua relevância para o desenvolvimento de sistemas inteligentes
- ♦ Analisar as estratégias de Inteligência Artificial atuais em vários domínios, identificando oportunidades e desafios
- ♦ Obter uma visão integral da transformação da Investigação Clínica através da IA, desde os seus fundamentos históricos até às aplicações atuais
- ♦ Aprender métodos eficazes para integrar dados heterogêneos na Investigação Clínica, incluindo processamento de linguagem natural e visualização avançada de dados
- ♦ Adquirir conhecimentos sólidos sobre a validação de modelos e simulações no âmbito biomédico, explorando o uso de *datasets* sintéticos e aplicações práticas da IA na investigação em saúde
- ♦ Compreender e aplicar tecnologias de sequenciação genómica, análise de dados com IA e uso de IA em imagens biomédicas
- ♦ Adquirir conhecimentos especializados em áreas chave como personalização de terapias, medicina de precisão, diagnóstico assistido por IA e gestão de ensaios clínicos
- ♦ Obter conhecimentos sólidos sobre os conceitos de *Big Data* no âmbito clínico e familiarizar-se com ferramentas essenciais para a sua análise
- ♦ Aprofundar-se em dilemas éticos, rever considerações legais, explorar o impacto socioeconómico e 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

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

Módulo 4. Extração 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. 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 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 da conceção de modelos
- ♦ Afinar hiperparâmetros para o *Fine Tuning* de redes neuronais, melhorando o seu desempenho em tarefas específicas

Módulo 9. Treino de redes neuronais profundas

- ♦ Resolver problemas relacionados com gradientes na formação de redes neuronais profundas
- ♦ Explorar e aplicar diferentes otimizadores para melhorar a eficiência e a convergência dos modelos
- ♦ Programar a taxa de aprendizagem para ajustar dinamicamente a velocidade de convergência do modelo
- ♦ Compreender e abordar o sobreajuste através de estratégias específicas durante o treino
- ♦ Aplicar diretrizes práticas para garantir o treino eficiente e eficaz de redes neuronais profundas

- ♦ Implementar a *Transfer Learning* como uma técnica avançada para melhorar o desempenho do modelo em tarefas específicas
- ♦ Explorar e aplicar técnicas de *Data Augmentation* para enriquecer conjuntos de dados e melhorar a generalização do modelo
- ♦ Desenvolver aplicações práticas utilizando a *Transfer Learning* para resolver problemas do mundo real
- ♦ Compreender e aplicar técnicas de regularização para melhorar a generalização e evitar o sobreajuste em redes neurais profundas

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

- ♦ Dominar os fundamentos do *TensorFlow* e a sua integração com o NumPy para um tratamento e computação eficientes dos dados
- ♦ Personalizar modelos e algoritmos de treino utilizando as capacidades avançadas do *TensorFlow*
- ♦ Explorar a API tfdata para gerir e manipular eficientemente conjuntos de dados
- ♦ Implementar o formato TFRecord para armazenar e aceder a grandes conjuntos de dados *TensorFlow*
- ♦ Utilizar camadas de pré-processamento do Keras para facilitar a construção de modelos personalizados
- ♦ Explore o projeto *TensorFlow Datasets* para acessar conjuntos de dados predefinidos e melhorar a eficiência do desenvolvimento
- ♦ Desenvolver uma aplicação de *Deep Learning* com *TensorFlow*, integrando os conhecimentos adquiridos no módulo
- ♦ Aplicar de forma prática todos os conceitos aprendidos na construção e treino de modelos personalizados com *TensorFlow* em situações do mundo real

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

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

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

- ♦ Desenvolver competências na geração de textos utilizando Redes Neurais Recorrentes (RNN)
- ♦ Aplicar RNN na classificação de opiniões para análise de sentimentos em textos
- ♦ Compreender e aplicar mecanismos de atenção em modelos de processamento de linguagem natural

- ♦ Analisar e utilizar modelos *Transformers* em tarefas específicas de PNL
- ♦ Explorando a aplicação de modelos *Transformers* no contexto do processamento de imagens e da visão computacional
- ♦ Familiarizar-se com a biblioteca *Transformers* de *Hugging Face* para a implementação eficiente de modelos avançados
- ♦ Comparar diferentes bibliotecas de *Transformers* para avaliar a sua adequação a tarefas específicas
- ♦ Desenvolver uma aplicação prática de PLN que integre RNN e mecanismos de atenção para resolver problemas do mundo real

Módulo 13. Autoencoders, GANs, e modelos de divulgação

- ♦ Desenvolver representações de dados eficientes utilizando *Autoencoders*, *GANs* e Modelos de Difusão
- ♦ Realizar PCA utilizando um codificador automático linear incompleto para otimizar a representação dos dados
- ♦ Implementar e compreender o funcionamento de codificadores automáticos empilhados
- ♦ Explorar e aplicar codificadores automáticos convolucionais para representações visuais eficientes de dados
- ♦ Analisar e aplicar a eficácia dos codificadores automáticos esparsos na representação de dados
- ♦ Gerar imagens de moda a partir do conjunto de dados MNIST utilizando *Autoencoders*
- ♦ Compreender o conceito de Redes Generativas Antagônicas (*GANs*) e Modelos de Difusão
- ♦ Implementar e comparar o desempenho de modelos de difusão e *GANs* na geração de dados

Módulo 14. Computação bioinspirada

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

Módulo 15. Inteligência Artificial Estratégias e aplicações

- ♦ Desenvolver estratégias para a implementação da inteligência artificial nos serviços financeiros
- ♦ Analisar as implicações da inteligência artificial na prestação de serviços de saúde
- ♦ Identificar e avaliar os riscos associados à utilização da inteligência artificial no setor da saúde
- ♦ Avaliar os riscos potenciais associados à utilização da IA na indústria
- ♦ Aplicar técnicas de inteligência artificial na indústria para melhorar a produtividade

- ♦ Conceber soluções de inteligência artificial para otimizar os processos na administração pública
- ♦ Avaliar a aplicação de tecnologias de IA no setor da educação
- ♦ Aplicar técnicas de inteligência artificial na silvicultura e na agricultura para melhorar a produtividade
- ♦ Melhorar os processos de recursos humanos através da utilização estratégica da inteligência artificial

Módulo 16. Diagnóstico na prática clínica através da IA

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

Módulo 17. Tratamento e controlo do paciente com IA

- ♦ Interpretar resultados para a criação ética de *datasets* e a aplicação estratégica em emergências sanitárias
- ♦ Adquirir competências avançadas na apresentação, visualização e gestão de dados de IA na saúde
- ♦ Obter uma perspetiva integral das tendências emergentes e inovações tecnológicas em IA aplicada à saúde
- ♦ Desenvolver algoritmos de IA para aplicações específicas, como o monitoramento da saúde, facilitando a implementação eficaz de soluções na prática médica
- ♦ Projetar e implementar tratamentos médicos individualizados ao analisar com a IA dados clínicos e genómicos dos pacientes

Módulo 18. Personalização da saúde através da IA

- ♦ Aprofundar as tendências emergentes em IA aplicada à saúde personalizada e o seu impacto futuro
- ♦ Definir as aplicações da IA para personalizar tratamentos médicos, que abrangem desde a análise genómica até à gestão da dor
- ♦ Diferenciar algoritmos específicos de IA para o desenvolvimento de aplicações relacionadas com o design de fármacos ou a robótica cirúrgica
- ♦ Delimitar as tendências emergentes em IA aplicada à saúde personalizada e o seu impacto futuro
- ♦ Promover a inovação através da criação de estratégias orientadas para melhorar a atenção médica

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

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

Módulo 20. Ética e regulamentação na IA médica

- ♦ Compreender os princípios éticos fundamentais e as regulamentações legais aplicáveis à implementação de IA na medicina
- ♦ Dominar os princípios de governança de dados
- ♦ Entender os quadros regulatórios internacionais e locais
- ♦ Garantir o cumprimento normativo no uso de dados e ferramentas de IA no setor da saúde
- ♦ Desenvolver competências para desenhar sistemas de IA centrados no ser humano, promovendo a equidade e transparência no aprendizado automático



Desfrute dos conteúdos académicos mais atualizados do panorama educativo, disponíveis em formatos multimédia inovadores para otimizar os seus estudos”

03

Competências

Esta qualificação universitária proporcionará aos alunos uma atualização relativamente à aplicação da IA no âmbito da Investigação Clínica. Desta forma, os especialistas estarão equipados com competências avançadas e práticas para enfrentar desafios biomédicos complexos, desde a análise de dados até à simulação de processos biológicos. Além disso, proporcionará um entendimento integral das tecnologias de ponta, como a sequenciação genómica e a análise de imagens biomédicas. Por outro lado, terão um amplo conhecimento sobre os aspetos éticos, legais e regulamentares.




“

A IA na Prática Clínica promete melhorar a qualidade da atenção médica, reduzir erros e abrir novas fronteiras para a investigação biomédica”



Competências gerais

- Dominar as técnicas de mineração de dados, incluindo a seleção, o pré-processamento e a transformação de dados complexos
- Conceber e desenvolver sistemas inteligentes capazes de aprender e de se adaptar a ambientes em mudança
- Controlar as ferramentas de aprendizagem automática e a sua aplicação na mineração de dados para a tomada de decisões
- Utilizar *Autoencoders*, GANs e Modelos de Difusão para resolver desafios específicos em Inteligência Artificial
- Implementar uma rede codificadora-descodificadora para tradução automática neuronal
- Aplicar os princípios fundamentais das redes neurais na resolução de problemas específicos
- Utilizar ferramentas, plataformas e técnicas de IA, abordando desde a análise de dados até à aplicação de redes neurais e modelação preditiva
- Aplicar modelos computacionais para simular processos biológicos e respostas a tratamentos, utilizando a IA para melhorar a compreensão de fenómenos biomédicos complexos
- Abordar desafios contemporâneos no domínio biomédico, incluindo a gestão eficiente de ensaios clínicos e a aplicação de IA em imunologia





Competências específicas

- Aplicar técnicas e estratégias de IA para melhorar a eficiência no setor do *retalho*
- Aprofundar a compreensão e a aplicação dos algoritmos genéticos.
- Implementar técnicas de redução de ruído utilizando codificadores automáticos
- Criar eficazmente conjuntos de dados de treino para tarefas de processamento de linguagem natural (PLN)
- Executar camadas de agrupamento e a sua utilização em modelos de *Deep Computer Vision* com o Keras
- Utilizar funções e gráficos *TensorFlow* para otimizar o desempenho de modelos personalizados
- Melhorar o desenvolvimento e a aplicação de *chatbots* e assistentes virtuais, compreendendo o seu funcionamento e potenciais aplicações
- Dominar a reutilização de camadas pré-treinadas para otimizar e acelerar o processo de treino
- Construir a primeira rede neural, aplicando na prática os conceitos aprendidos
- Ativar o Perceptron Multicamadas (MLP) usando a biblioteca Keras
- Aplicar técnicas de exploração e pré-processamento de dados, identificando e preparando os dados para uma utilização efetiva em modelos de aprendizagem automática
- Implementar estratégias eficazes para tratar valores em falta em conjuntos de dados, aplicando métodos de imputação ou eliminação sensíveis ao contexto
- Investigar linguagens e software para a criação de ontologias, utilizando ferramentas específicas para o desenvolvimento de modelos semânticos
- Desenvolver técnicas de limpeza de dados para garantir a qualidade e a exatidão da informação utilizada nas análises posteriores
- Dominar as ferramentas, plataformas e técnicas de IA utilizadas na Investigação Clínica, abordando desde a análise de dados até à aplicação de redes neuronais e modelagem preditiva
- Aplicar modelos computacionais na simulação de processos biológicos, doenças e respostas a tratamentos, utilizando ferramentas de IA para melhorar a compreensão e representação de fenómenos biomédicos complexos
- Aplicar as tecnologias de sequenciação genómica e análise de dados com inteligência IA
- Usar a IA na análise de imagens biomédicas
- Adquirir competências na visualização avançada e comunicação eficaz de dados complexos, com um foco no desenvolvimento de ferramentas baseadas em IA

04

Direção do curso

Com o objetivo de oferecer formações de qualidade e com um elevado nível educativo, a TECH reúne prestigiados profissionais com ampla experiência em IA na Prática Clínica. Neste sentido, o plano de estudos caracteriza-se por dispor de um corpo docente que oferece o conteúdo mais exclusivo e completo do mercado académico. Desta forma, cada módulo foi desenhado com o maior grau de especificidade, permitindo ao estudante consolidar e desenvolver as suas capacidades ao máximo. Assim, terão as garantias necessárias para se especializarem e evoluírem rumo ao seu sucesso profissional.



“

*Uma equipa de professores experientes
guiá-lo-á ao longo de todo o processo
de aprendizagem e resolverá todas as
dúvidas que possam surgir”*

Direção



Dr. Peralta Martín-Palomino, Arturo

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

**Sr. Martín-Palomino Sahagún, Fernando**

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

Professores**Dr. Carrasco González, Ramón Alberto**

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

Sr. Popescu Radu, Daniel Vasile

- ♦ 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 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

05

Estrutura e conteúdo

Esta qualificação académica funde o rigor científico da Investigação Clínica com as inovações disruptivas da Aprendizagem Automática. Formado por 20 módulos, o presente programa abrangerá desde a interpretação de dados médicos até ao desenvolvimento de algoritmos preditivos e a implementação de soluções tecnológicas em ambientes clínicos. O plano de estudos oferecerá conteúdos que unem a teoria à prática, estabelecendo as bases da IA e a sua aplicação específica no contexto médico. Desta forma, os alunos estarão preparados para liderar avanços na personalização de tratamentos e na otimização da atenção sanitária.



“

Aprofundar-se-á na ciência de dados em saúde, explorando a bioestatística e a análise de grandes dados, com 2.250 horas de conteúdos inovadores”

Módulo 1. Fundamentos da Inteligência Artificial

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

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

Módulo 2. Tipos e ciclo de vida do dado

- 2.1. A estatística
 - 2.1.1. Estatística Estatística descritiva, inferências estatísticas
 - 2.1.2. População, amostra indivíduo
 - 2.1.3. Variáveis: Definição, escalas de medição
- 2.2. Tipos de dados estatísticos
 - 2.2.1. De acordo com o tipo
 - 2.2.1.1. Quantitativos: Dados contínuos e dados discretos
 - 2.2.1.2. Qualitativos: Dados binominais, dados nominais, dados ordinais
 - 2.2.2. De acordo com a sua forma
 - 2.2.2.1. Numérico
 - 2.2.2.2. Texto
 - 2.2.2.3. Lógico
 - 2.2.3. De acordo com a sua fonte
 - 2.2.3.1. Primários
 - 2.2.3.2. Secundários

- 2.3. Ciclo de vida dos dados
 - 2.3.1. Etapas do ciclo
 - 2.3.2. Marcos do ciclo
 - 2.3.3. Princípios FAIR
- 2.4. Etapas iniciais do ciclo
 - 2.4.1. Definição de metas
 - 2.4.2. Determinação de recursos necessários
 - 2.4.3. Diagrama de Gantt
 - 2.4.4. Estrutura de dados
- 2.5. Recolha de dados
 - 2.5.1. Metodologia de recolha
 - 2.5.2. Ferramentas de recolha
 - 2.5.3. Canais de recolha
- 2.6. Limpeza de dados
 - 2.6.1. Fases de limpeza de dados
 - 2.6.2. Qualidade dos dados
 - 2.6.3. Manipulação de dados (com R)
- 2.7. Análise de dados, interpretação e avaliação dos resultados
 - 2.7.1. Medidas estatísticas
 - 2.7.2. Indicadores de relação
 - 2.7.3. Extração de dados
- 2.8. Armazém de dados (*Datawarehouse*)
 - 2.8.1. Elementos incluídos
 - 2.8.2. Design
 - 2.8.3. Aspetos a considerar
- 2.9. Disponibilidade dos dados
 - 2.9.1. Acesso
 - 2.9.2. Utilidade
 - 2.9.3. Segurança
- 2.10. Aspetos regulamentares
 - 2.10.1. Lei da Proteção de Dados
 - 2.10.2. Boas práticas
 - 2.10.3. Outros aspetos regulamentares

Módulo 3. O dado na Inteligência Artificial

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

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

Módulo 4. Extração 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. Comparação
- 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. Comparação
 - 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 *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. Detenção 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*. Comparação
 - 12.9.1. Comparação entre as diferentes bibliotecas de *Transformers*
 - 12.9.2. Uso das outras bibliotecas de *Transformers*
 - 12.9.3. Vantagens das outras bibliotecas de *Transformers*
- 12.10. Desenvolvimento de uma aplicação de PLN com RNN e Atenção. Aplicação Prática
 - 12.10.1. Desenvolvimento de uma aplicação de processamento de linguagem natural com RNN e atenção
 - 12.10.2. Utilização de RNN, mecanismos de atenção e modelos *Transformers* na aplicação
 - 12.10.3. Avaliação da aplicação prática

Módulo 13. Autoencoders, GANs, e modelos de difusão

- 13.1. Representação de dados eficientes
 - 13.1.1. Redução da dimensionalidade
 - 13.1.2. Aprendizagem profunda
 - 13.1.3. Representações compatas
- 13.2. Realização da PCA com um codificador automático linear incompleto
 - 13.2.1. Processo de treino
 - 13.2.2. Implementação em Python
 - 13.2.3. Utilização de dados de teste

- 13.3. Codificadores automáticos empilhados
 - 13.3.1. Redes neurais profundas
 - 13.3.2. Construção de arquiteturas de codificação
 - 13.3.3. Utilização da regularização
- 13.4. Autoencodificadores convolucionais
 - 13.4.1. Design do modelo convolucionais
 - 13.4.2. Treino do modelo convolucionais
 - 13.4.3. Avaliação dos resultados
- 13.5. Redução do ruído dos codificadores automáticos
 - 13.5.1. Aplicação de filtros
 - 13.5.2. Design de modelos de codificação
 - 13.5.3. Utilização de técnicas de regularização
- 13.6. Codificadores automáticos dispersos
 - 13.6.1. Aumento da eficiência da codificação
 - 13.6.2. Minimizar o número de parâmetros
 - 13.6.3. Utilização de técnicas de regularização
- 13.7. Codificadores automáticos variacionais
 - 13.7.1. Utilização da otimização variacional
 - 13.7.2. Aprendizagem profunda não supervisionada
 - 13.7.3. Representações latentes profundas
- 13.8. Geração de imagens MNIST de moda
 - 13.8.1. Reconhecimento de padrões
 - 13.8.2. Geração de imagens
 - 13.8.3. Treino de redes neurais profundas
- 13.9. Redes generativas antagônicas 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 colônias de formigas
 - 14.2.2. Variantes dos algoritmos de colônias de formigas
 - 14.2.3. Computação baseada em nuvens de partículas
- 14.3. Algoritmos genéticos
 - 14.3.1. Estrutura geral
 - 14.3.2. Implementações dos principais operadores
- 14.4. Estratégias de exploração do espaço para algoritmos genéticos
 - 14.4.1. Algoritmo CHC
 - 14.4.2. Problemas multimodais
- 14.5. Modelos de computação evolutiva
 - 14.5.1. Estratégias evolutivas
 - 14.5.2. Programação evolutiva
 - 14.5.3. Algoritmos baseados em evolução diferencial
- 14.6. Modelos de computação evolutiva (II)
 - 14.6.1. Modelos de evolução baseados na estimativa das distribuições (EDA)
 - 14.6.2. Programação genética
- 14.7. Programação evolutiva aplicada a problemas de aprendizagem
 - 14.7.1. A aprendizagem baseada em regras
 - 14.7.2. Métodos evolutivos em problemas de seleção de exemplos
- 14.8. Problemas multiobjetivo
 - 14.8.1. Conceito de dominância
 - 14.8.2. Aplicação de algoritmos evolutivos a problemas multiobjetivos
- 14.9. Redes neurais (I)
 - 14.9.1. Introdução às redes neurais
 - 14.9.2. Exemplo prático com redes neurais
- 14.10. Redes neurais (II)
 - 14.10.1. Casos de utilização de redes neurais na investigação médica
 - 14.10.2. Casos de utilização de redes neurais na economia
 - 14.10.3. Casos de utilização de redes neurais na visão artificial

Módulo 15. Inteligência Artificial Estratégias e aplicações

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

- 16.1. Tecnologias e ferramentas para o diagnóstico assistido por IA
 - 16.1.1. Desenvolvimento de software para o diagnóstico assistido por IA em diversas especialidades médicas mediante ChatGPT
 - 16.1.2. Uso de algoritmos avançados para a análise rápida e precisa de sintomas e sinais clínicos
 - 16.1.3. Integração de IA em dispositivos de diagnóstico para melhorar a eficiência
 - 16.1.4. Ferramentas de IA para auxiliar na interpretação de resultados de testes laboratoriais mediante IBM Watson Health
- 16.2. Integração de dados clínicos multimodais para o diagnóstico
 - 16.2.1. Sistemas de IA para combinar dados de imagens, laboratório e registos clínicos mediante AutoML
 - 16.2.2. Ferramentas para a correlação de dados multimodais em diagnósticos mais precisos mediante Enlitic Curie
 - 16.2.3. Uso de IA para analisar padrões complexos a partir de diferentes tipos de dados clínicos mediante Flatiron Health's OncologyCloud
 - 16.2.4. Integração de dados genómicos e moleculares no diagnóstico assistido por IA

- 16.3. Criação e análise de *datasets* em saúde com IA mediante Google Cloud Healthcare API
 - 16.3.1. Desenvolvimento de bases de dados clínicas para o treino de modelos de IA
 - 16.3.2. Uso de IA para a análise e extração de *insights* de grandes *datasets* de saúde
 - 16.3.3. Ferramentas de IA para a limpeza e preparação de dados clínicos
 - 16.3.4. Sistemas de IA para identificar tendências e padrões em dados de saúde
 - 16.4. Visualização e manuseio de dados de saúde com IA
 - 16.4.1. Ferramentas de IA para a visualização interativa e compreensível de dados de saúde
 - 16.4.2. Sistemas de IA para o manuseio eficiente de grandes volumes de dados clínicos
 - 16.4.3. Uso de *dashboards* baseados em IA para a monitorização de indicadores de saúde
 - 16.4.4. Tecnologias de IA para a gestão e segurança de dados de saúde
 - 16.5. Reconhecimento de padrões e *machine learning* em diagnósticos clínicos mediante PathAI
 - 16.5.1. Aplicação de técnicas de *machine learning* para o reconhecimento de padrões em dados clínicos
 - 16.5.2. Uso de IA na identificação precoce de doenças através da análise de padrões com PathAI
 - 16.5.3. Desenvolvimento de modelos preditivos para diagnósticos mais precisos
 - 16.5.4. Implementação de algoritmos de aprendizagem automática na interpretação de dados de saúde
 - 16.6. Interpretação de imagens médicas mediante IA mediante Aidoc
 - 16.6.1. Sistemas de IA para a detecção e classificação de anomalias em imagens médicas
 - 16.6.2. Uso de aprendizagem profunda na interpretação de radiografias, ressonâncias e tomografias
 - 16.6.3. Ferramentas de IA para melhorar a precisão e a velocidade no diagnóstico por imagens
 - 16.6.4. Implementação de IA para a assistência na tomada de decisões clínicas baseadas em imagens
 - 16.7. Processamento da linguagem natural sobre histórias médicas para o diagnóstico clínico mediante ChatGPT e Amazon Comprehend Medical
 - 16.7.1. Uso de PNL para a extração de informação relevante de históricos clínicos
 - 16.7.2. Sistemas de IA para analisar notas de médicos e relatórios de pacientes
 - 16.7.3. Ferramentas de IA para resumir e classificar informação de histórias médicas
 - 16.7.4. Aplicação de PNL na identificação de sintomas e diagnósticos a partir de textos clínicos
 - 16.8. Validação e avaliação de modelos de diagnóstico assistido por IA mediante ConcertAI
 - 16.8.1. Métodos para a validação e teste de modelos de IA em ambientes clínicos reais
 - 16.8.2. Avaliação do desempenho e precisão de ferramentas de diagnóstico assistido por IA
 - 16.8.3. Uso de IA para assegurar a confiabilidade e ética no diagnóstico clínico
 - 16.8.4. Implementação de protocolos de avaliação contínua para sistemas de IA em saúde
 - 16.9. IA no diagnóstico de doenças raras mediante Face2Gene
 - 16.9.1. Desenvolvimento de sistemas de IA especializados na identificação de doenças raras
 - 16.9.2. Uso de IA para analisar padrões atípicos e sintomatologia complexa
 - 16.9.3. Ferramentas de IA para o diagnóstico precoce e preciso de doenças raras
 - 16.9.4. Implementação de bases de dados globais com IA para melhorar o diagnóstico de doenças raras
 - 16.10. Casos de sucesso e desafios na implementação de diagnóstico por IA
 - 16.10.1. Análise de estudos de caso onde a IA melhorou significativamente o diagnóstico clínico
 - 16.10.2. Avaliação dos desafios na adoção de IA em ambientes clínicos
 - 16.10.3. Discussão sobre as barreiras éticas e práticas na implementação de IA para diagnóstico
 - 16.10.4. Exame das estratégias para superar obstáculos na integração de IA no diagnóstico médico
- Módulo 17. Tratamento e controlo do paciente com IA**
- 17.1. Sistemas de tratamento assistido por IA
 - 17.1.1. Desenvolvimento de sistemas de IA para auxiliar na tomada de decisões terapêuticas
 - 17.1.2. Uso de IA para personalização de tratamentos com base em perfis individuais
 - 17.1.3. Implementação de ferramentas de IA na administração de doses e horários de medicação
 - 17.1.4. Integração de IA na monitorização e ajuste de tratamentos em tempo real

- 17.2. Definição de indicadores para o controle do estado de saúde do paciente
 - 17.2.1. Estabelecimento de parâmetros-chave por meio de IA para o acompanhamento da saúde do paciente
 - 17.2.2. Uso de IA para identificar indicadores preditivos de saúde e doenças
 - 17.2.3. Desenvolvimento de sistemas de alerta precoce baseados em indicadores de saúde
 - 17.2.4. Implementação de IA para a avaliação contínua do estado de saúde do paciente
- 17.3. Ferramentas para a monitorização e controle de indicadores de saúde
 - 17.3.1. Desenvolvimento de aplicativos móveis e dispositivos vestíveis com IA para o acompanhamento da saúde
 - 17.3.2. Implementação de sistemas de IA para análise em tempo real dos dados de saúde
 - 17.3.3. Uso de *dashboards* baseados em IA para visualização e monitoramento de indicadores de saúde
 - 17.3.4. Integração de dispositivos IoT na monitorização contínua de indicadores de saúde com IA
- 17.4. IA no planejamento e execução de procedimentos médicos com o Sistema Cirúrgico da Vinci da Intuitive Surgical
 - 17.4.1. Uso de sistemas de IA para otimizar o planejamento de cirurgias e procedimentos médicos
 - 17.4.2. Implementação de IA na simulação e prática de procedimentos cirúrgicos
 - 17.4.3. Uso de IA para melhorar a precisão e eficácia na execução de procedimentos médicos
 - 17.4.4. Aplicação de IA na coordenação e gestão de recursos cirúrgicos
- 17.5. Algoritmos de aprendizado de máquina para o estabelecimento de tratamentos terapêuticos
 - 17.5.1. Uso de *machine learning* para desenvolver protocolos de tratamento personalizados
 - 17.5.2. Implementação de algoritmos preditivos para a seleção de terapias eficazes
 - 17.5.3. Desenvolvimento de sistemas de IA para a adaptação de tratamentos em tempo real
 - 17.5.4. Aplicação de IA na análise da eficácia de diferentes opções terapêuticas
- 17.6. Adaptabilidade e atualização contínua de protocolos terapêuticos por meio de IA com IBM Watson for Oncology
 - 17.6.1. Implementação de sistemas de IA para a revisão e atualização dinâmica de tratamentos
 - 17.6.2. Uso de IA na adaptação de protocolos terapêuticos a novos descobrimentos e dados
 - 17.6.3. Desenvolvimento de ferramentas de IA para personalização contínua de tratamentos
 - 17.6.4. Integração de IA na resposta adaptativa à evolução das condições do paciente
- 17.7. Otimização de serviços de saúde com tecnologia de IA com Optum
 - 17.7.1. Uso de IA para melhorar a eficiência e qualidade dos serviços de saúde
 - 17.7.2. Implementação de sistemas de IA para a gestão de recursos sanitários
 - 17.7.3. Desenvolvimento de ferramentas de IA para otimização de fluxos de trabalho em hospitais
 - 17.7.4. Aplicação de IA na redução de tempos de espera e melhoria do atendimento ao paciente
- 17.8. Aplicação de IA na resposta a emergências sanitárias
 - 17.8.1. Implementação de sistemas de IA para a gestão rápida e eficiente de crises sanitárias com BlueDot
 - 17.8.2. Uso de IA na otimização da distribuição de recursos em emergências
 - 17.8.3. Desenvolvimento de ferramentas de IA para previsão e resposta a surtos de doenças
 - 17.8.4. Integração de IA em sistemas de alerta e comunicação durante emergências sanitárias
- 17.9. Colaboração interdisciplinar em tratamentos assistidos por IA
 - 17.9.1. Promoção da colaboração entre diferentes especialidades médicas por meio de sistemas de IA
 - 17.9.2. Uso de IA para integrar conhecimentos e técnicas de diversas disciplinas no tratamento
 - 17.9.3. Desenvolvimento de plataformas de IA para facilitar a comunicação e coordenação interdisciplinar
 - 17.9.4. Implementação de IA na criação de equipes de tratamento multidisciplinares
- 17.10. Experiências bem-sucedidas de IA no tratamento de doenças
 - 17.10.1. Análise de casos de sucesso no uso de IA para tratamentos eficazes de doenças
 - 17.10.2. Avaliação do impacto da IA na melhoria dos resultados dos tratamentos
 - 17.10.3. Documentação de experiências inovadoras no uso de IA em diferentes áreas médicas
 - 17.10.4. Discussão sobre os avanços e desafios na implementação de IA nos tratamentos médicos

Módulo 18. Personalização da saúde através da IA

- 18.1. Aplicações de IA em genômica para medicina personalizada com DeepGenomics
 - 18.1.1. Desenvolvimento de algoritmos de IA para análise de sequências genéticas e sua relação com doenças
 - 18.1.2. Uso de IA na identificação de marcadores genéticos para tratamentos personalizados
 - 18.1.3. Implementação de IA para interpretação rápida e precisa de dados genômicos
 - 18.1.4. Ferramentas de IA na correlação de genótipos com respostas a medicamentos
- 18.2. IA em farmacogenômica e design de medicamentos com AtomWise
 - 18.2.1. Desenvolvimento de modelos de IA para prever a eficácia e segurança de medicamentos
 - 18.2.2. Uso de IA na identificação de alvos terapêuticos e design de fármacos
 - 18.2.3. Aplicação de IA na análise de interações gene-droga para personalização de tratamentos
 - 18.2.4. Implementação de algoritmos de IA para acelerar a descoberta de novos medicamentos
- 18.3. Monitoramento personalizado com dispositivos inteligentes e IA
 - 18.3.1. Desenvolvimento de wearables com IA para o acompanhamento contínuo de indicadores de saúde
 - 18.3.2. Uso de IA na interpretação de dados coletados por dispositivos inteligentes com FitBit
 - 18.3.3. Implementação de sistemas de alerta precoce baseados em IA para condições de saúde
 - 18.3.4. Ferramentas de IA para personalização de recomendações de estilo de vida e saúde
- 18.4. Sistemas de apoio à decisões clínicas com IA
 - 18.4.1. Implementação de IA para auxiliar médicos na tomada de decisões clínicas com Oracle Cerner
 - 18.4.2. Desenvolvimento de sistemas de IA que fornecem recomendações baseadas em dados clínicos
 - 18.4.3. Uso de IA na avaliação de riscos e benefícios de diferentes opções terapêuticas
 - 18.4.4. Ferramentas de IA para integração e análise de dados de saúde em tempo real
- 18.5. Tendências na personalização da saúde com IA
 - 18.5.1. Análise das últimas tendências em IA para personalização do cuidado de saúde
 - 18.5.2. Uso de IA no desenvolvimento de abordagens preventivas e preditivas em saúde
 - 18.5.3. Implementação de IA na adaptação de planos de saúde às necessidades individuais
 - 18.5.4. Exploração de novas tecnologias de IA no campo da saúde personalizada
- 18.6. Avanços em robótica cirúrgica assistida por IA com o Sistema Cirúrgico da Vinci da Intuitive Surgical
 - 18.6.1. Desenvolvimento de robôs cirúrgicos com IA para procedimentos precisos e minimamente invasivos
 - 18.6.2. Uso de IA para criar modelos preditivos de doenças com base em dados individuais com OncoraMedical
 - 18.6.3. Implementação de sistemas de IA para planejamento cirúrgico e simulação de operações
 - 18.6.4. Avanços na integração de *feedback* tátil e visual em robótica cirúrgica com IA
- 18.7. Desenvolvimento de modelos preditivos para prática clínica personalizada
 - 18.7.1. Uso de IA para criar modelos preditivos de doenças com base em dados individuais
 - 18.7.2. Implementação de IA na previsão de respostas a tratamentos
 - 18.7.3. Desenvolvimento de ferramentas de IA para antecipação de riscos de saúde
 - 18.7.4. Aplicação de modelos preditivos no planejamento de intervenções preventivas
- 18.8. IA em gestão e tratamento personalizado da dor com Kaia Health
 - 18.8.1. Desenvolvimento de sistemas de IA para avaliação e manejo personalizado da dor
 - 18.8.2. Uso de IA na identificação de padrões de dor e respostas a tratamentos
 - 18.8.3. Implementação de ferramentas de IA na personalização de terapias para dor
 - 18.8.4. Aplicação de IA no monitoramento e ajuste de planos de tratamento da dor
- 18.9. Autonomia do Paciente e Participação Ativa na Personalização
 - 18.9.1. Promoção da autonomia do paciente por meio de ferramentas de IA para gestão de sua saúde com Ada Health
 - 18.9.2. Desenvolvimento de sistemas de IA que capacitam os pacientes na tomada de decisões
 - 18.9.3. Uso de IA para fornecer informações e educação personalizada aos pacientes
 - 18.9.4. Ferramentas de IA que facilitam a participação ativa do paciente em seu tratamento

- 18.10. Integração de IA em histórias clínicas eletrônicas com Oracle Cerner
 - 18.10.1. Implementação de IA para análise e gestão eficiente de histórias clínicas eletrônicas
 - 18.10.2. Desenvolvimento de ferramentas de IA para extração de *insights* clínicos de registros eletrônicos
 - 18.10.3. Uso de IA na melhoria da precisão e acessibilidade dos dados em histórias clínicas
 - 18.10.4. Aplicação de IA para correlação de dados de histórias clínicas com planos de tratamento

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

- 19.1. Fundamentos de *Big Data* em saúde
 - 19.1.1. A explosão de dados no âmbito da saúde
 - 19.1.2. Conceito de *Big Data* e principais ferramentas
 - 19.1.3. Aplicações de *Big Data* em saúde
- 19.2. Processamento e análise de textos em dados de saúde com KNIME e Python
 - 19.2.1. Conceitos de processamento de linguagem natural
 - 19.2.2. Técnicas de *embedding*
 - 19.2.3. Aplicação de processamento de linguagem natural em saúde
- 19.3. Métodos avançados de recuperação de dados em saúde com KNIME e Python
 - 19.3.1. Exploração de técnicas inovadoras para a recuperação eficiente de dados em saúde
 - 19.3.2. Desenvolvimento de estratégias avançadas para extração e organização de informações em ambientes de saúde
 - 19.3.3. Implementação de métodos de recuperação de dados adaptativos e personalizados para diversos contextos clínicos
- 19.4. Avaliação de qualidade na análise de dados de saúde com KNIME e Python
 - 19.4.1. Desenvolvimento de indicadores para avaliação rigorosa da qualidade dos dados em ambientes de saúde
 - 19.4.2. Implementação de ferramentas e protocolos para garantir a qualidade dos dados utilizados em análises clínicas
 - 19.4.3. Avaliação contínua da precisão e confiabilidade dos resultados em projetos de análise de dados de saúde
- 19.5. Mineração de dados e aprendizado de máquina em saúde com KNIME e Python
 - 19.5.1. Principais metodologias para mineração de dados
 - 19.5.2. Integração de dados de saúde
 - 19.5.3. Detecção de padrões e anomalias em dados de saúde

- 19.6. Áreas inovadoras de *Big Data* e IA em saúde
 - 19.6.1. Exploração de novas fronteiras na aplicação de *Big Data* e IA para transformar o setor de saúde
 - 19.6.2. Identificação de oportunidades inovadoras para a integração de tecnologias de *Big Data* e IA nas práticas médicas
 - 19.6.3. Desenvolvimento de abordagens vanguardistas para aproveitar ao máximo o potencial de *Big Data* e IA no âmbito da saúde
- 19.7. Coleta e pré-processamento de dados médicos com KNIME e Python
 - 19.7.1. Desenvolvimento de metodologias eficientes para a coleta de dados médicos em ambientes clínicos e de pesquisa
 - 19.7.2. Implementação de técnicas avançadas de pré-processamento para otimizar a qualidade e utilidade dos dados médicos
 - 19.7.3. Desenvolvimento de estratégias de coleta e pré-processamento que garantam a confidencialidade e privacidade das informações médicas
- 19.8. Visualização de dados e comunicação em saúde com ferramentas como PowerBI e Python
 - 19.8.1. Desenvolvimento de ferramentas inovadoras de visualização em saúde
 - 19.8.2. Estratégias criativas de comunicação em saúde
 - 19.8.3. Integração de tecnologias interativas em saúde
- 19.9. Segurança de dados e governança no setor de saúde
 - 19.9.1. Desenvolvimento de estratégias integradas de segurança de dados para proteger a confidencialidade e privacidade no setor de saúde
 - 19.9.2. Implementação de frameworks de governança eficazes para garantir a gestão ética e responsável de dados em ambientes médicos
 - 19.9.3. Desenvolvimento de políticas e procedimentos para garantir a integridade e disponibilidade de dados médicos, abordando desafios específicos do setor de saúde
- 19.10. Aplicações práticas de *Big Data* em saúde
 - 19.10.1. Desenvolvimento de soluções especializadas para gerenciar e analisar grandes volumes de dados em ambientes de saúde
 - 19.10.2. Utilização de ferramentas práticas baseadas em *Big Data* para apoiar a tomada de decisões clínicas
 - 19.10.3. Aplicação de abordagens inovadoras de *Big Data* para enfrentar desafios específicos no setor de saúde

Módulo 20. Ética e regulamentação na IA médica

- 20.1. Princípios éticos no uso de IA na medicina
 - 20.1.1. Análise e adoção de princípios éticos no desenvolvimento e uso de sistemas de IA médica
 - 20.1.2. Integração de valores éticos na tomada de decisões assistida por IA em contextos médicos
 - 20.1.3. Estabelecimento de diretrizes éticas para garantir um uso responsável da inteligência artificial na medicina
- 20.2. Privacidade de dados e consentimento em contextos médicos
 - 20.2.1. Desenvolvimento de políticas de privacidade para proteger dados sensíveis em aplicações de IA médica
 - 20.2.2. Garantia de consentimento informado na coleta e uso de dados pessoais no âmbito médico
 - 20.2.3. Implementação de medidas de segurança para salvaguardar a privacidade dos pacientes em ambientes de IA médica
- 20.3. Ética na pesquisa e desenvolvimento de sistemas de IA médica
 - 20.3.1. Avaliação ética de protocolos de pesquisa no desenvolvimento de sistemas de IA para a saúde
 - 20.3.2. Garantia de transparência e rigor ético nas fases de desenvolvimento e validação de sistemas de IA médica
 - 20.3.3. Considerações éticas na publicação e compartilhamento de resultados no âmbito da IA médica
- 20.4. Impacto social e responsabilidade na IA para saúde
 - 20.4.1. Análise do impacto social da IA na prestação de serviços de saúde
 - 20.4.2. Desenvolvimento de estratégias para mitigar riscos e responsabilidade ética em aplicações de IA na medicina
 - 20.4.3. Avaliação contínua do impacto social e adaptação de sistemas de IA para contribuir positivamente para a saúde pública
- 20.5. Desenvolvimento sustentável da IA no setor saúde
 - 20.5.1. Integração de práticas sustentáveis no desenvolvimento e manutenção de sistemas de IA em saúde
 - 20.5.2. Avaliação do impacto ambiental e econômico das tecnologias de IA no âmbito sanitário
 - 20.5.3. Desenvolvimento de modelos de negócios sustentáveis para garantir a continuidade e melhoria das soluções de IA no setor de saúde
- 20.6. Governança de dados e marcos regulatórios internacionais em IA médica
 - 20.6.1. Desenvolvimento de marcos de governança para a gestão ética e eficiente de dados em aplicações de IA médica
 - 20.6.2. Adaptação a normativas e regulamentações internacionais para garantir a conformidade ética e legal
 - 20.6.3. Participação ativa em iniciativas internacionais para estabelecer padrões éticos no desenvolvimento de sistemas de IA médica
- 20.7. Aspectos econômicos da IA no âmbito sanitário
 - 20.7.1. Análise das implicações econômicas e custos-benefícios na implementação de sistemas de IA em saúde
 - 20.7.2. Desenvolvimento de modelos de negócios e financiamento para facilitar a adoção de tecnologias de IA no setor sanitário
 - 20.7.3. Avaliação da eficiência econômica e equidade no acesso a serviços de saúde impulsionados por IA
- 20.8. Design centrado no humano de sistemas de IA médica
 - 20.8.1. Integração de princípios de design centrado no humano para melhorar a usabilidade e aceitação de sistemas de IA médica
 - 20.8.2. Participação de profissionais de saúde e pacientes no processo de design para garantir a relevância e eficácia das soluções
 - 20.8.3. Avaliação contínua da experiência do usuário e feedback para otimizar a interação com sistemas de IA em ambientes médicos
- 20.9. Equidade e transparência em aprendizado de máquina médico
 - 20.9.1. Desenvolvimento de modelos de aprendizado de máquina médico que promovam a equidade e a transparência
 - 20.9.2. Implementação de práticas para mitigar vieses e garantir a equidade na aplicação de algoritmos de IA no âmbito da saúde
 - 20.9.3. Avaliação contínua da equidade e transparência no desenvolvimento e implementação de soluções de aprendizado de máquina em medicina
- 20.10. Segurança e políticas na implementação de IA na medicina
 - 20.10.1. Desenvolvimento de políticas de segurança para proteger a integridade e confidencialidade dos dados em aplicações de IA médica
 - 20.10.2. Implementação de medidas de segurança no lançamento de sistemas de IA para prevenir riscos e garantir a segurança do paciente
 - 20.10.3. Avaliação contínua das políticas de segurança para se adaptar aos avanços tecnológicos e novos desafios na implementação de IA na medicina

06

Metodologia de estudo

A TECH é a primeira universidade do mundo a unir a metodologia dos **case studies** com o **Relearning**, um sistema de aprendizado 100% online baseado na repetição guiada.

Essa estratégia de ensino inovadora foi projetada para oferecer aos profissionais a oportunidade de atualizar conhecimentos e desenvolver habilidades de forma intensiva e rigorosa. Um modelo de aprendizagem que coloca o aluno no centro do processo acadêmico e lhe dá o papel principal, adaptando-se às suas necessidades e deixando de lado as metodologias mais convencionais.



“

*A TECH prepara você para enfrentar
novos desafios em ambientes incertos
e alcançar o sucesso em sua carreira”*

O aluno: a prioridade de todos os programas da TECH

Na metodologia de estudo da TECH, o aluno é o protagonista absoluto. As ferramentas pedagógicas de cada programa foram selecionadas levando-se em conta as demandas de tempo, disponibilidade e rigor acadêmico que, atualmente, os alunos, bem como os empregos mais competitivos do mercado, exigem.

Com o modelo educacional assíncrono da TECH, é o aluno quem escolhe quanto tempo passa estudando, como decide estabelecer suas rotinas e tudo isso no conforto do dispositivo eletrônico de sua escolha. O aluno não precisa assistir às aulas presenciais, que muitas vezes não poderá comparecer. As atividades de aprendizado serão realizadas de acordo com sua conveniência. O aluno sempre poderá decidir quando e de onde estudar.

“

*Na TECH, o aluno NÃO terá aulas ao vivo
(das quais poderá nunca participar)”*



Os programas de ensino mais abrangentes do mundo

A TECH se caracteriza por oferecer os programas acadêmicos mais completos no ambiente universitário. Essa abrangência é obtida por meio da criação de programas de estudo que cobrem não apenas o conhecimento essencial, mas também as últimas inovações em cada área.

Por serem constantemente atualizados, esses programas permitem que os alunos acompanhem as mudanças do mercado e adquiram as habilidades mais valorizadas pelos empregadores. Dessa forma, os alunos da TECH recebem uma preparação abrangente que lhes dá uma vantagem competitiva significativa para avançar em suas carreiras.

Além disso, eles podem fazer isso de qualquer dispositivo, PC, tablet ou smartphone.

“

O modelo da TECH é assíncrono, portanto, você poderá estudar com seu PC, tablet ou smartphone onde quiser, quando quiser e pelo tempo que quiser”

Case studies ou Método de caso

O método de casos tem sido o sistema de aprendizado mais amplamente utilizado pelas melhores escolas de negócios do mundo. Desenvolvido em 1912 para que os estudantes de direito não aprendessem a lei apenas com base no conteúdo teórico, sua função também era apresentar a eles situações complexas da vida real. Assim, eles poderiam tomar decisões informadas e fazer julgamentos de valor sobre como resolvê-los. Em 1924 foi estabelecido como o método de ensino padrão em Harvard.

Com esse modelo de ensino, é o próprio aluno que desenvolve sua competência profissional por meio de estratégias como o *Learning by doing* ou o *Design Thinking*, usados por outras instituições renomadas, como Yale ou Stanford.

Esse método orientado para a ação será aplicado em toda a trajetória acadêmica do aluno com a TECH. Dessa forma, o aluno será confrontado com várias situações da vida real e terá de integrar conhecimentos, pesquisar, argumentar e defender suas ideias e decisões. A premissa era responder à pergunta sobre como eles agiriam diante de eventos específicos de complexidade em seu trabalho diário.




Método Relearning

Na TECH os *case studies* são alimentados pelo melhor método de ensino 100% online: o *Relearning*.

Esse método rompe com as técnicas tradicionais de ensino para colocar o aluno no centro da equação, fornecendo o melhor conteúdo em diferentes formatos. Dessa forma, consegue revisar e reiterar os principais conceitos de cada matéria e aprender a aplicá-los em um ambiente real.

Na mesma linha, e de acordo com várias pesquisas científicas, a repetição é a melhor maneira de aprender. Portanto, a TECH oferece entre 8 e 16 repetições de cada conceito-chave dentro da mesma lição, apresentadas de uma forma diferente, a fim de garantir que o conhecimento seja totalmente incorporado durante o processo de estudo.

O Relearning permitirá uma aprendizagem com menos esforço e mais desempenho, fazendo com que você se envolva mais em sua especialização, desenvolvendo seu espírito crítico e sua capacidade de defender argumentos e contrastar opiniões: uma equação de sucesso.



Um Campus Virtual 100% online com os melhores recursos didáticos

Para aplicar sua metodologia de forma eficaz, a TECH se concentra em fornecer aos alunos materiais didáticos em diferentes formatos: textos, vídeos interativos, ilustrações e mapas de conhecimento, entre outros. Todos eles são projetados por professores qualificados que concentram seu trabalho na combinação de casos reais com a resolução de situações complexas por meio de simulação, o estudo de contextos aplicados a cada carreira profissional e o aprendizado baseado na repetição, por meio de áudios, apresentações, animações, imagens etc.

As evidências científicas mais recentes no campo da neurociência apontam para importância de levar em conta o local e o contexto em que o conteúdo é acessado antes de iniciar um novo processo de aprendizagem. A capacidade de ajustar essas variáveis de forma personalizada ajuda as pessoas a lembrar e armazenar o conhecimento no hipocampo para retenção a longo prazo. Trata-se de um modelo chamado *Neurocognitive context-dependent e-learning* que é aplicado conscientemente nesse curso universitário.

Por outro lado, também para favorecer ao máximo o contato entre mentor e mentorado, é oferecida uma ampla variedade de possibilidades de comunicação, tanto em tempo real quanto em diferido (mensagens internas, fóruns de discussão, serviço telefônico, contato por e-mail com a secretaria técnica, bate-papo, videoconferência etc.).

Da mesma forma, esse Campus Virtual muito completo permitirá que os alunos da TECH organizem seus horários de estudo de acordo com sua disponibilidade pessoal ou obrigações de trabalho. Dessa forma, eles terão um controle global dos conteúdos acadêmicos e de suas ferramentas didáticas, em função de sua atualização profissional acelerada.



O modo de estudo online deste programa permitirá que você organize seu tempo e ritmo de aprendizado, adaptando-o à sua agenda”

A eficácia do método é justificada por quatro conquistas fundamentais:

1. Os alunos que seguem este método não só assimilam os conceitos, mas também desenvolvem a capacidade intelectual através de exercícios de avaliação de situações reais e de aplicação de conhecimentos.
2. A aprendizagem se consolida nas habilidades práticas, permitindo ao aluno integrar melhor o conhecimento à prática clínica.
3. A assimilação de ideias e conceitos se torna mais fácil e eficiente, graças à abordagem de situações decorrentes da realidade.
4. A sensação de eficiência do esforço investido se torna um estímulo muito importante para os alunos, o que se traduz em um maior interesse pela aprendizagem e um aumento no tempo dedicado ao curso.

A metodologia universitária mais bem avaliada por seus alunos

Os resultados desse modelo acadêmico inovador podem ser vistos nos níveis gerais de satisfação dos alunos da TECH.


A avaliação dos alunos sobre a qualidade do ensino, a qualidade dos materiais, a estrutura e os objetivos do curso é excelente. Não é de surpreender que a instituição tenha se tornado a universidade mais bem avaliada por seus alunos na plataforma de avaliação Trustpilot, com uma pontuação de 4,9 de 5.

Acesse o conteúdo do estudo de qualquer dispositivo com conexão à Internet (computador, tablet, smartphone) graças ao fato da TECH estar na vanguarda da tecnologia e do ensino.

Você poderá aprender com as vantagens do acesso a ambientes de aprendizagem simulados e com a abordagem de aprendizagem por observação, ou seja, aprender com um especialista.



Assim, os melhores materiais educacionais, cuidadosamente preparados, estarão disponíveis neste programa:



Material de estudo

O conteúdo didático foi elaborado especialmente para este curso pelos especialistas que irão ministrá-lo, o que permite que o desenvolvimento didático seja realmente específico e concreto.

Posteriormente, esse conteúdo é adaptado ao formato audiovisual, para criar o método de trabalho online, com as técnicas mais recentes que nos permitem lhe oferecer a melhor qualidade em cada uma das peças que colocaremos a seu serviço.



Práticas de aptidões e competências

Serão realizadas atividades para desenvolver as habilidades e competências específicas em cada área temática. Práticas e dinâmicas para adquirir e desenvolver as competências e habilidades que um especialista precisa desenvolver no âmbito da globalização.



Resumos interativos


Apresentamos os conteúdos de forma atraente e dinâmica em pílulas multimídia que incluem áudio, vídeos, imagens, diagramas e mapas conceituais com o objetivo de reforçar o conhecimento.


Este sistema exclusivo de capacitação por meio da apresentação de conteúdo multimídia foi premiado pela Microsoft como "Caso de sucesso na Europa"



Leituras complementares

Artigos recentes, documentos científicos, guias internacionais, entre outros. Na biblioteca virtual do estudante você terá acesso a tudo o que for necessário para completar sua capacitação.





07

Certificação

O Mestrado Próprio em Inteligência Artificial na Prática Clínica garante, além da formação mais rigorosa e atualizada, o acesso a um certificado de Mestrado Próprio emitido pela TECH Universidade Tecnológica.



“

*Conclua este programa de estudos
com sucesso e receba seu certificado
sem sair de casa e sem burocracias”*

Este **Mestrado Próprio em Inteligência Artificial na Prática Clínica** conta com o conteúdo educacional mais completo e atualizado do mercado.

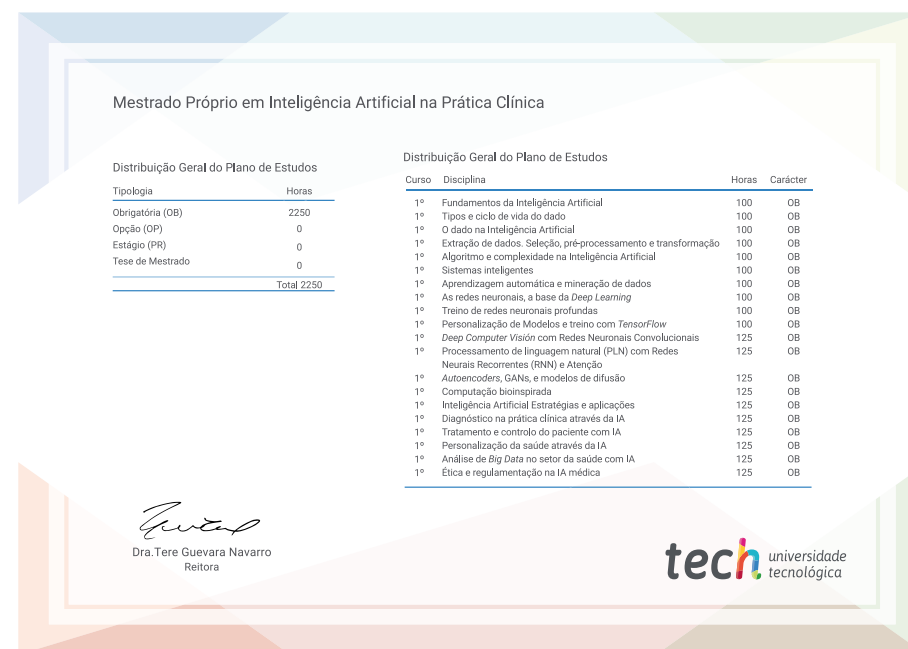
Uma vez aprovadas as avaliações, o aluno receberá por correio, com aviso de receção, o certificado* correspondente ao título de **Mestrado Próprio** emitido pela **TECH Universidade Tecnológica**.

O certificado emitido pela **TECH Universidade Tecnológica** expressará a qualificação obtida no Mestrado Próprio, atendendo aos requisitos normalmente exigidos pelas bolsas de emprego, concursos públicos e avaliação de carreiras profissionais.

Certificação: **Mestrado Próprio em Inteligência Artificial na Prática Clínica**

Modalidade: **online**

Duração: **12 meses**



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

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

tech universidade
tecnológica

Mestrado Próprio
Inteligência Artificial
na Prática Clínica

- » Modalidade: online
- » Duração: 12 meses
- » Certificação: TECH Universidade Tecnológica
- » Horário: ao seu próprio ritmo
- » Exames: online

Mestrado Próprio

Inteligência Artificial na Prática Clínica

