

Mestrado Próprio

Inteligência Artificial na Pesquisa Clínica



Mestrado Próprio Inteligência Artificial na Pesquisa Clínica

- » Modalidade: online
- » Duração: 12 meses
- » Certificado: TECH Universidade Tecnológica
- » Dedicção: 16h/semana
- » Horário: no seu próprio ritmo
- » Provas: online

Acesso ao site: www.techtute.com/br/inteligencia-artificial/mestrado-proprio/mestrado-proprio-inteligencia-artificial-pesquisa-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

Certificado

pág. 52

01

Apresentação

No contexto da Pesquisa Clínica, a Inteligência Artificial (IA) tornou-se uma ferramenta essencial para analisar grandes quantidades de dados de forma eficiente e precisa. Dessa forma, o sistema contribui para avanços significativos tanto na compreensão quanto no tratamento de doenças. Por exemplo, no caso do câncer, a aprendizagem automática é usada para identificar lesões tumorais em imagens médicas de alta resolução. Além disso, ao examinar as informações genômicas, os pacientes podem receber terapias mais eficazes que reduzem a ocorrência de efeitos colaterais. Em resposta a isso, a TECH está desenvolvendo um programa que irá imergir os médicos em inovações nesse campo, a fim de melhorar sua prática de saúde. E tudo em um conveniente formato totalmente digital!



“

Graças a este programa 100% online, você analisará de forma abrangente os princípios essenciais da aprendizagem de máquina e sua implementação na análise de dados biomédicos”

Durante os tratamentos terapêuticos, os usuários precisam ser constantemente monitorados por profissionais médicos para verificar a eficácia dos tratamentos. Nesse sentido, a Inteligência Artificial é útil para coletar dados em tempo real sobre o estado clínico dos indivíduos. Além disso, suas ferramentas detectam até mesmo mudanças discretas na saúde para alertar os especialistas quando necessário. Dessa forma, os profissionais podem aplicar modificações com base nas reações dos indivíduos e evitar futuros problemas com risco de vida.

Ciente de sua importância, a TECH implementa um Mestrado Próprio que abordará em detalhes as aplicações específicas da Inteligência Artificial no campo da Pesquisa Clínica. Projetado por especialistas da área, a grade curricular se aprofundará na simulação computacional em biomedicina e na análise avançada de dados clínicos. Dessa forma, os especialistas adquirirão habilidades avançadas para implementar a aprendizagem automática em situações biomédicas complexas. Por outro lado, o plano de estudos enfatizará as considerações éticas e legais do uso da Inteligência Artificial para que os alunos desenvolvam seus procedimentos sob uma perspectiva altamente deontológica.

Deve-se observar que a metodologia desse programa reforça seu caráter inovador. A TECH oferece um ambiente educacional 100% online, adaptado às necessidades de profissionais ocupados que buscam avançar em suas carreiras. Portanto, será possível planejar seus horários individuais e cronogramas de avaliação. A capacitação também emprega o novo sistema de *Relearning*, baseado na repetição de conceitos-chave para fixar o conhecimento e facilitar o aprendizado. Assim, a combinação de flexibilidade e uma abordagem pedagógica robusta o torna altamente acessível. Os profissionais também terão acesso a uma biblioteca repleta de recursos audiovisuais, incluindo infográficos e resumos interativos. Além disso, o programa universitário incluirá casos clínicos reais que tornarão o desenvolvimento do programa o mais próximo possível da realidade do atendimento médico.

Este **Mestrado Próprio em Inteligência Artificial em Pesquisa Clínica** conta com o conteúdo mais completo e atualizado do mercado. Suas principais características são:

- O desenvolvimento de estudos de caso apresentados por especialistas em Inteligência Artificial em Pesquisa Clínica.
- O conteúdo gráfico, esquemático e extremamente útil fornece informações científicas e práticas sobre aquelas disciplinas indispensáveis para o exercício da profissão
- Exercícios práticos onde o processo de autoavaliação é realizado para melhorar a aprendizagem
- Destaque especial para as metodologias inovadoras
- Lições teóricas, perguntas a especialistas, fóruns de discussão sobre temas controversos e trabalhos de reflexão individual
- Disponibilidade de acesso a todo o conteúdo a partir de qualquer dispositivo, fixo ou portátil, com conexão à Internet



A capacidade da Inteligência Artificial de integrar dados de várias fontes e prever resultados contribuirá para tornar sua prática médica mais precisa e personalizada"

“

Para que você possa atingir seus objetivos acadêmicos de forma flexível, a TECH oferece uma metodologia de aprendizagem 100% online, baseada no livre acesso aos conteúdos e na personalização do ensino”

O corpo docente do programa conta com profissionais do setor, que transferem toda a experiência adquirida ao longo de suas carreiras para esta capacitação, além de especialistas reconhecidos de sociedades de referência e universidades de prestígio.

O conteúdo multimídia, desenvolvido com a mais recente tecnologia educacional, permitirá ao profissional uma aprendizagem contextualizada, ou seja, realizada através de um ambiente simulado, proporcionando uma capacitação imersiva e programada para praticar diante de situações reais.

A estrutura deste programa se concentra na Aprendizagem Baseada em Problemas, através da qual o profissional deverá resolver as diferentes situações de prática profissional que surgirem ao longo do curso acadêmico. Para isso, contará com a ajuda de um inovador sistema de vídeo interativo realizado por especialistas reconhecidos.

Deseja se aprofundar na implementação de Big Data? Gerencie as técnicas mais eficazes de aprendizado de máquina graças a este Mestrado Próprio.

A capacitação inclui a análise dos aspectos éticos, legais e regulatórios, o envolvimento com a responsabilidade e a conscientização dos desafios contemporâneos.



02

Objetivos

Esta capacitação fornecerá aos alunos um conhecimento abrangente de Inteligência Artificial aplicada à Pesquisa Clínica. Dessa forma, os profissionais estarão altamente qualificados para enfrentar os desafios atuais e futuros da área médica. Além disso, os especialistas aprenderão sobre aspectos éticos e inovadores que os ajudarão a transformar o setor de saúde. Além disso, lidarão com técnicas avançadas de análise de dados médicos, desenvolvimento de modelos preditivos para testes clínicos e implementação de soluções criativas para personalização de tratamentos. Isso permitirá que os especialistas tratem com eficácia as complexidades clínicas por meio de abordagens baseadas em evidências.



“

Você vai se aprofundar nas tecnologias mais recentes e nas aplicações mais revolucionárias da Inteligência Artificial em Pesquisa Clínica, usando os melhores recursos multimídia”



Objetivos gerais

- ♦ Compreender os fundamentos teóricos da Inteligência Artificial
- ♦ Estudar os diferentes tipos de dados e entender o ciclo de vida dos dados
- ♦ Avaliar a função crucial dos dados no desenvolvimento e na implementação de soluções de Inteligência Artificial
- ♦ Analisar os algoritmos e complexidade para resolver problemas específicos
- ♦ Explorar a base teórica das redes neurais para o desenvolvimento do *Deep Learning*
- ♦ Analisar a computação bioinspirada e sua relevância para o desenvolvimento de sistemas inteligentes
- ♦ Analisar as estratégias atuais de Inteligência Artificial em vários campos, identificando oportunidades e desafios
- ♦ Obter uma visão abrangente da transformação da pesquisa clínica por meio da IA, desde seus fundamentos históricos até os aplicativos atuais
- ♦ Aprender métodos eficazes para integrar dados heterogêneos à pesquisa clínica, incluindo processamento de linguagem natural e visualização avançada de dados
- ♦ Adquirir uma sólida compreensão da validação e simulação de modelos no campo biomédico, explorando o uso de *datasets* sintéticos e aplicações práticas de IA na pesquisa em saúde
- ♦ Compreender e aplicar tecnologias de sequenciamento genômico, análise de dados de IA e o uso de IA em imagens biomédicas
- ♦ Adquirir conhecimento especializado em áreas importantes, como personalização de terapias, medicina de precisão, diagnósticos assistidos por IA e gestão de ensaios clínicos
- ♦ Obter uma sólida compreensão dos conceitos de *Big Data* no ambiente clínico e familiarizar-se com as ferramentas essenciais para sua análise
- ♦ Aprofundar os dilemas éticos, analisar as considerações legais, explorar o impacto socioeconômico e o futuro da IA na área da 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 seus primórdios até seu estado atual, identificando os principais marcos e desenvolvimentos
- Compreender o funcionamento das redes neurais e sua aplicação em modelos de aprendizado em Inteligência Artificial
- Estudar os princípios e as aplicações dos algoritmos genéticos, analisando sua utilidade na solução de problemas complexos
- Analisar a importância dos thesauri, vocabulários e taxonomias na estruturação e no processamento de dados para sistemas de IA
- Explorar o conceito da web semântica e sua influência na organização e compreensão das informações em ambientes digitais

Módulo 2. Tipos e ciclo de vida dos dados

- Compreender os conceitos fundamentais de estatística e sua aplicação na análise de dados
- Identificar e classificar diferentes tipos de dados estatísticos, desde dados quantitativos até qualitativos
- Analisar o ciclo de vida dos dados, desde a geração até o descarte, identificando os principais estágios
- Explorar os estágios iniciais do ciclo de vida dos dados, destacando a importância do planejamento e da estrutura dos dados
- Estudar os processos de coleta de dados, incluindo a metodologia, ferramentas e canais de coleta
- Explorar o conceito de *Datawarehouse* (Armazém de dados), com ênfase nos elementos que o integram e em seu projeto
- Analisar os aspectos regulatórios relacionados à gestão de dados, cumprindo as normas de privacidade e segurança e as práticas recomendadas

Módulo 3. Os dados na Inteligência Artificial

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

Módulo 4. Mineração de dados. Seleção, pré-processamento e transformação

- ♦ Dominar as técnicas de inferência estatística para compreender e aplicar métodos estatísticos na mineração de dados
- ♦ Realizar uma análise exploratória detalhada de conjuntos de dados para identificar padrões, anomalias e tendências relevantes
- ♦ Desenvolver habilidades para a preparação de dados, incluindo sua limpeza, integração e formatação para uso na mineração de dados
- ♦ Implementar estratégias eficazes para lidar com valores perdidos em conjuntos de dados, aplicando métodos de imputação ou eliminação conforme o contexto
- ♦ Identificar e mitigar o ruído presente nos dados, utilizando técnicas de filtragem e suavização para melhorar a qualidade do conjunto de dados
- ♦ Abordar o pré-processamento de dados em ambientes de *Big Data*

Módulo 5. Algoritmia e Complexidade em Inteligência Artificial

- ♦ Introduzir estratégias de design de algoritmos, fornecendo uma compreensão sólida dos enfoques fundamentais para a resolução de problemas
- ♦ Analisar a eficiência e complexidade dos algoritmos, aplicando técnicas de análise para avaliar o desempenho em termos de tempo e espaço
- ♦ Estudar e aplicar algoritmos de ordenação, compreendendo seu funcionamento e comparando sua eficiência em diferentes contextos
- ♦ Explorar algoritmos baseados em árvores, compreendendo sua estrutura e aplicações
- ♦ Investigar algoritmos com *Heaps*, analisando sua implementação e utilidade na manipulação eficiente de dados
- ♦ Analisar algoritmos baseados em grafos, explorando sua aplicação na representação e solução de problemas que envolvem relações complexas
- ♦ Estudar algoritmos *Greedy*, entendendo sua lógica e aplicações na resolução de problemas de otimização
- ♦ Investigar e aplicar a técnica de *backtracking* para a resolução sistemática de problemas, analisando sua eficácia em diversos cenários

Módulo 6. Sistemas inteligentes

- ♦ Explorar a teoria de agentes, compreendendo os conceitos fundamentais de seu funcionamento e sua aplicação em Inteligência Artificial e engenharia de Software
- ♦ Estudar a representação do conhecimento, incluindo a análise de ontologias e sua aplicação na organização de informações estruturadas
- ♦ Analisar o conceito da web semântica e seu impacto na organização e recuperação de informações em ambientes digitais

- ♦ Avaliar e comparar diferentes representações do conhecimento, integrando estas para melhorar a eficácia e precisão dos sistemas inteligentes
- ♦ Estudar racionadores semânticos, sistemas baseados em conhecimento e sistemas especialistas, compreendendo sua funcionalidade e aplicações na tomada de decisões inteligentes

Módulo 7: Machine learning e mineração de dados

- ♦ Introduzir os processos de descobrimento do conhecimento e os conceitos fundamentais do machine learning
- ♦ Estudar árvores de decisão como modelos de aprendizado supervisionado, compreendendo sua estrutura e aplicações
- ♦ Avaliar classificadores usando técnicas específicas para medir seu desempenho e precisão na classificação de dados
- ♦ Estudar redes neurais, compreendendo seu funcionamento e arquitetura para resolver problemas complexos de aprendizado de máquina
- ♦ Explorar métodos bayesianos e sua aplicação no aprendizado de máquina, incluindo redes bayesianas e classificadores bayesianos
- ♦ Analisar modelos de regressão e de resposta contínua para a previsão de valores numéricos a partir de dados
- ♦ Estudar técnicas de *agrupamento* para identificar padrões e estruturas em conjuntos de dados não rotulados
- ♦ Explorar a mineração de texto e o processamento de linguagem natural (NLP), compreendendo como técnicas de aprendizado de máquina são aplicadas para analisar e compreender o texto

Módulo 8. Redes Neurais como Base do *Deep Learning*

- ♦ Dominar os fundamentos do Aprendizado Profundo, compreendendo seu papel essencial no *Deep Learning*
- ♦ Explorar as operações fundamentais em redes neurais e compreender sua aplicação na construção de modelos
- ♦ Analisar as diferentes camadas utilizadas em redes neurais e aprender a selecioná-las adequadamente
- ♦ Compreender a combinação efetiva de camadas e operações para projetar arquiteturas de redes neurais complexas e eficientes
- ♦ Utilizar treinadores e otimizadores para ajustar e melhorar o desempenho das redes neurais
- ♦ Explorar a conexão entre neurônios biológicos e artificiais para uma compreensão mais profunda do design de modelos
- ♦ Ajustar hiperparâmetros para *oFine Tuning* de redes neurais, otimizando seu desempenho em tarefas específicas

Módulo 9. Treinamento de Redes Neurais Profundas

- ♦ Resolver problemas relacionados aos gradientes no treinamento de redes neurais profundas
- ♦ Explorar e aplicar diferentes otimizadores para melhorar a eficiência e 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 treinamento
- ♦ Aplicar diretrizes práticas para garantir um treinamento eficiente e eficaz de redes neurais profundas

- ♦ Implementar *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 *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 Treinamento com *TensorFlow*

- ♦ Dominar os fundamentos do *TensorFlow* e sua integração com o NumPy para um manejo eficiente de dados e cálculos
- ♦ Personalizar modelos e algoritmos de treinamento utilizando as capacidades avançadas do *TensorFlow*
- ♦ Explorar a API *tf.data* para gerenciar e manipular conjuntos de dados de maneira eficaz
- ♦ Implementar o formato *TFRecord* para armazenar e acessar grandes conjuntos de dados no *TensorFlow*
- ♦ Utilizar camadas de pré-processamento do Keras para facilitar a construção de modelos personalizados
- ♦ Explorar o projeto *TensorFlow Datasets* para acessar conjuntos de dados predefinidos e melhorar a eficiência no desenvolvimento
- ♦ Desenvolver uma aplicação de *Deep Learning* com *TensorFlow*, integrando os conhecimentos adquiridos no módulo
- ♦ Aplicar de maneira prática todos os conceitos aprendidos na construção e treinamento 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 sua relevância no *Deep Computer Vision*
- ♦ Explorar e aplicar camadas convolucionais para extrair características-chave de imagens
- ♦ Implementar camadas de pooling e sua utilização em modelos de *Deep Computer Vision* com Keras
- ♦ Analisar diversas arquiteturas de Redes Neurais Convolucionais (CNN) e sua aplicabilidade em diferentes contextos
- ♦ Desenvolver e implementar uma CNN ResNet utilizando a biblioteca Keras para melhorar a eficiência e desempenho do modelo
- ♦ Utilizar modelos pré-treinados de Keras para aproveitar a aprendizagem por transferência em tarefas específicas
- ♦ Aplicar técnicas de classificação e localização em ambientes de *Deep Computer Vision*
- ♦ Explorar estratégias de detecção e rastreamento de objetos usando Redes Neurais Convolucionais
- ♦ Implementar técnicas de segmentação semântica para compreender e classificar objetos em imagens de maneira detalhada

Módulo 12. Processamento de Linguagem Natural (PLN) com Redes Neurais Recorrentes (RNN) e Atenção

- ♦ Desenvolver habilidades em geração de texto usando Redes Neurais Recorrentes (RNN)
- ♦ Aplicar RNN na classificação de opiniões para análise de sentimentos em textos
- ♦ Compreender e aplicar os mecanismos de atenção em modelos de processamento de linguagem natural
- ♦ Analisar e utilizar modelos *Transformers* em tarefas específicas de NLP

- ♦ Explorar a aplicação de modelos *Transformers* no contexto de processamento de imagens e 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 sua adequação em tarefas específicas
- ♦ Desenvolver uma aplicação prática de NLP que integre RNN e mecanismos de atenção para resolver problemas do mundo real

Módulo 13. Autoencoders, GANs, e Modelos de Difusão

- ♦ Desenvolver representações eficientes de dados por meio de *Autoencoders*, *GANs* e Modelos de Difusão
- ♦ Realizar PCA utilizando um codificador automático linear incompleto para otimizar a representação de dados
- ♦ Implementar e compreender o funcionamento de codificadores automáticos empilhados
- ♦ Explorar e aplicar autoencoders convolucionais para representações eficientes de dados visuais
- ♦ Analisar e aplicar a eficácia de autoencoders esparsos na representação de dados
- ♦ Gerar imagens da moda do conjunto de dados MNIST utilizando *Autoencoders*
- ♦ Compreender o conceito de Redes Adversárias Generativas (*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 algoritmos de adaptação social como abordagem-chave na computação bioinspirada
- ♦ Analisar estratégias de exploração-exploração do espaço em algoritmos genéticos
- ♦ Examinar modelos de computação evolutiva no contexto da otimização
- ♦ Continuar a análise detalhada de modelos de computação evolutiva
- ♦ Aplicar programação evolutiva a problemas específicos de aprendizagem
- ♦ Abordar a complexidade de problemas multiobjetivo no contexto da computação bioinspirada
- ♦ Explorar a aplicação de redes neurais no âmbito da computação bioinspirada
- ♦ Analisar a implementação e a utilidade das redes neurais na computação bioinspirada

Módulo 15. Inteligência Artificial: Estratégias e aplicações

- ♦ Desenvolver estratégias de implementação de inteligência artificial em serviços financeiros
- ♦ Analisar as implicações da inteligência artificial na prestação de serviços de saúde
- ♦ Identificar e avaliar os riscos associados ao uso de IA no campo da saúde
- ♦ Avaliar os riscos potenciais vinculados ao uso de IA na indústria
- ♦ Aplicar técnicas de inteligência artificial na indústria para melhorar a produtividade
- ♦ Projetar soluções de inteligência artificial para otimizar processos na administração pública
- ♦ Avaliar a implementação de tecnologias de IA no setor educacional
- ♦ Aplicar técnicas de inteligência artificial na silvicultura e agricultura para melhorar a produtividade
- ♦ Otimizar processos de recursos humanos por meio do uso estratégico da inteligência artificial

Módulo 16. Métodos e Ferramentas de IA usadas na pesquisa clínica

- ♦ Obter uma visão abrangente de como a IA está transformando a pesquisa clínica, desde seus fundamentos históricos até os aplicativos atuais
- ♦ Implementar métodos e algoritmos estatísticos avançados em estudos clínicos para otimizar a análise de dados
- ♦ Projetar experimentos com abordagens inovadoras e realizar uma análise completa dos resultados em Pesquisa Clínica
- ♦ Aplicar o processamento de linguagem natural para melhorar a documentação científica e clínica no contexto da pesquisa
- ♦ Integrar de forma eficaz dados heterogêneos usando técnicas de última geração para aprimorar a pesquisa clínica interdisciplinar

Módulo 17. Pesquisa biomédica com IA

- ♦ Adquirir conhecimentos sólidos sobre a validação de modelos e simulações no campo biomédico, garantindo sua precisão e relevância clínica
- ♦ Integrar dados heterogêneos usando métodos avançados para enriquecer a análise multidisciplinar em Pesquisa Clínica
- ♦ Desenvolver algoritmos de aprendizagem profunda para melhorar a interpretação e a análise de dados biomédicos em estudos clínicos
- ♦ Explorar o uso de *datasets* sintéticos em estudos clínicos e para entender as aplicações práticas da IA na pesquisa em saúde
- ♦ Compreender o papel crucial da simulação computacional na descoberta de medicamentos, na análise de interações moleculares e na modelagem de doenças complexas

Módulo 18. Aplicação prática da IA na pesquisa clínica

- ♦ Adquirir experiência em áreas importantes, como personalização de terapias, medicina de precisão, diagnósticos assistidos por IA, gestão de ensaios clínicos e desenvolvimento de vacinas
- ♦ Incorporar a robótica e a automação em laboratórios clínicos para otimizar os processos e melhorar a qualidade dos resultados
- ♦ Explorar o impacto da IA sobre o microbioma, a microbiologia, *weareables* e o monitoramento remoto em estudos clínicos
- ♦ Abordar os desafios contemporâneos no campo biomédico, como a gestão eficiente de ensaios clínicos, o desenvolvimento de tratamentos assistidos por IA e a aplicação de IA em estudos de imunologia e resposta imunológica
- ♦ Inovar em diagnósticos assistidos por IA para melhorar a detecção precoce e a precisão do diagnóstico em ambientes de pesquisa clínica e biomédica

Módulo 19. Análise de *Big Data* e aprendizagem automática na pesquisa clínica

- ♦ Obter uma sólida compreensão dos conceitos de *Big Data* no ambiente clínico e familiarizar-se com as ferramentas essenciais utilizadas para sua análise
- ♦ Explorar técnicas avançadas de mineração de dados, algoritmos de aprendizagem de máquina, análise preditiva e aplicativos de IA em epidemiologia e saúde pública
- ♦ Analisar redes biológicas e padrões de doenças para identificar conexões e possíveis tratamentos
- ♦ Abordar a segurança dos dados e gerenciar os desafios associados a grandes volumes de dados na pesquisa biomédica
- ♦ Investigar estudos de caso que demonstrem o potencial do *Big Data* na pesquisa biomédica

Módulo 20. Aspectos éticos, legais e futuros da IA na pesquisa clínica

- Compreender os dilemas éticos que surgem ao aplicar a IA na pesquisa clínica e analisar as considerações legais e regulatórias relevantes no campo biomédico
- Abordar os desafios específicos do manejo do consentimento informado em estudos de IA
- Investigar como a IA pode influenciar a equidade e o acesso à assistência médica
- Analisar as perspectivas futuras sobre como a IA moldará a Pesquisa Clínica, explorando seu papel na sustentabilidade das práticas de pesquisa biomédica e identificando oportunidades de inovação e empreendedorismo
- Abordar de forma abrangente os aspectos éticos, legais e socioeconômicos da pesquisa clínica orientada por IA

“*Beneficie-se de um plano de estudos elaborado por especialistas e de um conteúdo de alta qualidade. Atualize sua prática clínica com a TECH!*”

03

Competências

Este Curso fornecerá aos alunos uma atualização completa e atualizada sobre a aplicação da Inteligência Artificial no ambiente de Pesquisa Clínica. Graças a este programa, os alunos terão habilidades avançadas e práticas para lidar de forma eficaz com os desafios biomédicos, como análise de dados e simulação de processos biológicos. Da mesma forma, os profissionais incorporarão tecnologias de última geração (incluindo o sequenciamento genômico) em seus procedimentos de rotina. Além disso, sua prática será caracterizada por levar em conta aspectos éticos, legais e regulatórios na aplicação da Inteligência Artificial na área médica.



“


Você contará com estudos de casos clínicos que aprimorarão suas habilidades em Machine Learning e Data Mining”



Competências gerais

- ♦ Dominar as técnicas de mineração de dados, incluindo a seleção, o pré-processamento e a transformação de dados complexos
- ♦ Projetar e desenvolver sistemas inteligentes capazes de aprender e se adaptar a ambientes em constante mudança
- ♦ Controlar as ferramentas de aprendizado de máquina e 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 de uma rede de codificador-decodificador para tradução automática neural
- ♦ Aplicar os princípios fundamentais das redes neurais na resolução de problemas específicos
- ♦ Usar ferramentas, plataformas e técnicas de IA, desde a análise de dados até a aplicação de redes neurais e modelagem preditiva
- ♦ Aplicar modelos computacionais para simular processos biológicos e respostas a tratamentos, usando IA para melhorar a compreensão de fenômenos biomédicos complexos
- ♦ Abordar desafios contemporâneos no campo biomédico, incluindo o manejo eficiente de testes clínicos e a aplicação de IA em imunologia





Competências específicas

- Aplicar técnicas e estratégias de IA para melhorar a eficiência no setor *retail*
- Ampliar a compreensão e a aplicação de algoritmos genéticos
- Implementar técnicas de redução de ruído usando codificadores automáticos
- Criar com eficiência conjuntos de dados de formação para tarefas de processamento de linguagem natural (NLP)
- Executar camadas de agrupamento e seu uso em modelos de *Deep Computer Vision* com Keras
- Usar funções e gráficos de *TensorFlow* para otimizar o desempenho de modelos personalizados
- Otimizar o desenvolvimento e a implementação de *chatbots* e assistentes virtuais, entendendo como eles funcionam e suas possíveis aplicações
- Dominar a reutilização de camadas pré-treinadas para otimizar e acelerar o processo de treinamento
- Construir a primeira rede neural, aplicando os conceitos aprendidos na prática
- Ativar o Perceptron de múltiplas camadas (MLP) usando a biblioteca Keras
- Aplicar técnicas de exploração e pré-processamento de dados, identificando e preparando dados para uso efetivo em modelos de aprendizado de máquina
- Implementar estratégias eficazes para lidar com valores perdidos em conjuntos de dados, aplicando métodos de imputação ou eliminação conforme o contexto
- Investigar linguagens e softwares para a criação de ontologias, usando ferramentas específicas para o desenvolvimento de modelos semânticos
- Desenvolver técnicas de limpeza de dados para garantir a qualidade e a precisão das informações usadas em análises subsequentes
- Dominar as ferramentas, plataformas e técnicas de IA usadas na Pesquisa Clínica, desde a análise de dados até a aplicação de redes neurais e modelagem preditiva
- Aplicar modelos computacionais na simulação de processos biológicos, doenças e respostas a tratamentos, usando ferramentas de IA para melhorar a compreensão e a representação de fenômenos biomédicos complexos
- Aplicar tecnologias de sequenciamento genômico e análise de dados com inteligência de IA
- Usar a IA na análise de imagens biomédicas
- Adquirir habilidades em visualização avançada e comunicação eficaz de dados complexos, com foco no desenvolvimento de ferramentas baseadas em IA



Uma capacitação que irá permitir que você aprimore a precisão do diagnóstico e a elaboração de tratamentos personalizados. Você revolucionará o setor de saúde com inovação!"

04

Direção do curso

Em sua premissa máxima de oferecer excelência educacional aos seus alunos, a TECH selecionou cuidadosamente o corpo docente que compõe esse programa. Esses profissionais têm um alto nível de conhecimento sobre Inteligência Artificial aplicada à Pesquisa Clínica, graças aos seus anos de experiência de trabalho em pesquisa. Dessa forma, esses especialistas são vozes autorizadas no campo e compartilharão seu conhecimento com os alunos. Por esse motivo, os materiais didáticos serão caracterizados por sua qualidade e pela combinação das tecnologias mais recentes nesse campo da saúde que avança rapidamente.



“

Uma equipe de professores especializados aplicará seu amplo conhecimento na área de Inteligência Artificial em Pesquisa Clínica nesse programa universitário"

Direção



Dr. Arturo Peralta Martín-Palomino

- ♦ CEO e CTO em Prometeus Soluções Globais
- ♦ CTO em Korporate Technologies
- ♦ CTO em AI Shephers GmbH
- ♦ Consultor e assessor estratégico de negócios da Alliance Medical
- ♦ Diretor de Design e Desenvolvimento na DocPath
- ♦ Doutor em Engenharia da Computação pela Universidade de Castilla-La Mancha
- ♦ Doutorado em Economia, Negócios e Finanças pela Universidade Camilo José Cela
- ♦ Doutor em Psicologia pela Universidade de Castilla-La Mancha
- ♦ Mestrado em MBA Executivo pela Universidade Isabel I
- ♦ Mestrado em Gestão de Vendas e Marketing pela Universidade Isabel I
- ♦ Mestrado especializado em Big Data por formação em Hadoop
- ♦ Mestrado em Tecnologias de Informação Avançadas pela Universidade de Castilla-La Mancha
- ♦ Membro: Grupo de pesquisa SMILE



Sr. Daniel Vasile Popescu Radu

- ♦ Especialista em Farmacologia, Nutrição e Dieta
- ♦ Produtor autônomo de conteúdos didáticos e científicos
- ♦ Nutricionista e dietista comunitário
- ♦ Farmacêutico comunitário
- ♦ Pesquisador
- ♦ Mestrado em Nutrição e Saúde na Universidade Aberta da Catalunha
- ♦ Mestrado em Psicofarmacologia pela Universidade de Valência
- ♦ Farmacêutico da Universidade Complutense de Madri
- ♦ Nutricionista-Dietista da Universidade Europeia Miguel de Cervantes

Professores

Ramón Alberto Carrasco González

- ♦ Especialista em Ciência da Computação e Inteligência Artificial
- ♦ Pesquisador
- ♦ Responsável por *Business Intelligence* (Marketing) na Caja General de Ahorros de Granada e no Banco Mare Nostrum
- ♦ Responsável por Sistemas de Informação (*Data Warehousing e Business Intelligence*) na Caja General de Ahorros de Granada e no Banco Mare Nostrum
- ♦ Doutorado em Inteligência Artificial pela Universidade de Granada
- ♦ Formado em Engenharia da Computação pela Universidade de Granada

05

Estrutura e conteúdo

Este Mestrado Próprio combinará o rigor científico da Pesquisa Clínica com as inovações revolucionárias da Inteligência Artificial. Composto por 20 módulos, o plano de estudos se aprofundará tanto na interpretação de dados médicos quanto no desenvolvimento de algoritmos preditivos. Além disso, o programa destacará a relevância da implementação de soluções tecnológicas em contextos clínicos. Com uma abordagem teórico-prática, os alunos dominarão os fundamentos da aprendizagem automática e sua aplicação correta na área médica. Assim, os alunos poderão liderar avanços na individualização de tratamentos e na otimização da assistência médica.



“

Acesse a biblioteca de recursos multimídia e o programa de estudos completo desde o primeiro dia. Sem horários fixos e sem necessidade de estar presente!”

Módulo 1. Fundamentos da Inteligência Artificial

- 1.1. História da inteligência artificial
 - 1.1.1. Quando começamos a falar de inteligência artificial?
 - 1.1.2. Referências no cinema
 - 1.1.3. Importância da inteligência artificial
 - 1.1.4. Tecnologias que habilitam e dão suporte à 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 de neurônios
 - 1.3.1. Fundamentos biológicos
 - 1.3.2. Modelo computacional
 - 1.3.3. Redes de neurônios 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. Geração da população inicial
 - 1.4.5. Algoritmo principal e operadores genéticos
 - 1.4.6. Avaliação de indivíduos: Fitness
- 1.5. Tesouros, vocabulários, taxonomias
 - 1.5.1. Vocabulários
 - 1.5.2. Taxonomias
 - 1.5.3. Tesouros
 - 1.5.4. Ontologias
 - 1.5.5. Representação do conhecimento: Web Semântica
- 1.6. Web Semântica
 - 1.6.1. Especificações RDF, RDFS e OWL
 - 1.6.2. Inferência/raciocínio
 - 1.6.3. *Linked Data*



- 1.7. Sistemas especializados e DSS
 - 1.7.1. Sistemas especializados
 - 1.7.2. Sistemas de suporte à decisão
- 1.8. *Chatbots* e assistentes virtuais
 - 1.8.1. Tipos de assistentes: assistentes de voz e texto
 - 1.8.2. Partes fundamentais para o desenvolvimento de um assistente: *Intenções*, entidades e fluxo de diálogo
 - 1.8.3. Integração Web, *Slack*, Whatsapp, Facebook
 - 1.8.4. Ferramentas para o desenvolvimento de assistentes: Dialog Flow, Watson Assistant
- 1.9. Estratégia de implementação da IA
- 1.10. O futuro da inteligência artificial
 - 1.10.1. Entendemos como detectar 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. Reflexões

Módulo 2. Tipos e ciclo de vida dos dados

- 2.1. Estatísticas
 - 2.1.1. Estatísticas: Estatísticas descritivas, inferências estatísticas
 - 2.1.2. População, amostra, individual
 - 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 binomiais, dados nominais, dados ordinais
 - 2.2.2. De acordo com sua forma
 - 2.2.2.1. Numérico
 - 2.2.2.2. Texto
 - 2.2.2.3. Lógico
 - 2.2.3. De acordo com a 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 objetivos
 - 2.4.2. Determinação de recursos necessários
 - 2.4.3. Diagrama de Gantt
 - 2.4.4. Estruturas dos dados
- 2.5. Coleta de dados
 - 2.5.1. Metodologia de coleta
 - 2.5.2. Ferramentas de coleta
 - 2.5.3. Canais de coleta
- 2.6. Limpeza de dados
 - 2.6.1. Fases da 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. Índices de relação
 - 2.7.3. Mineração de dados
- 2.8. Armazém de dados (*datawarehouse*)
 - 2.8.1. Elementos que o compõem
 - 2.8.2. Desenho
 - 2.8.3. Aspectos a considerar
- 2.9. Disponibilidade de dados
 - 2.9.1. Acesso
 - 2.9.2. Utilidade
 - 2.9.3. Segurança
- 2.10. Aspectos regulamentares
 - 2.10.1. Lei Geral de Proteção de Dados
 - 2.10.2. Boas práticas
 - 2.10.3. Outros aspectos regulamentares

Módulo 3. Os dados na Inteligência Artificial

- 3.1. Ciência de dados
 - 3.1.1. Ciência de dados
 - 3.1.2. Ferramentas avançadas para o cientista de dados
- 3.2. Dados, informações e conhecimentos
 - 3.2.1. Dados, informações e conhecimentos
 - 3.2.2. Tipos de dados
 - 3.2.3. Fontes de dados
- 3.3. De dados a informações
 - 3.3.1. Análise de dados
 - 3.3.2. Tipos de análise
 - 3.3.3. Extração de informações de um *Dataset*
- 3.4. Extração de informações 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 de 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 práticas recomendadas
 - 3.10.1. Práticas recomendadas para um cientista de dados
 - 3.10.2. O melhor modelo
 - 3.10.3. Ferramentas úteis

Módulo 4. Mineração de dados. Seleção, pré-processamento e transformação

- 4.1. Inferência estatística
 - 4.1.1. Estatística descritiva vs inferência estatística
 - 4.1.2. Procedimentos paramétricos
 - 4.1.3. Procedimentos paramétricos
- 4.2. Análise exploratória
 - 4.2.1. Análise descritiva
 - 4.2.2. Visualização
 - 4.2.3. Preparação dos dados
- 4.3. Preparação dos 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 verossimilhança
 - 4.4.3. Imputação de valores perdidos utilizando a aprendizagem de máquinas
- 4.5. O ruído nos dados
 - 4.5.1. Classes de ruído e seus atributos
 - 4.5.2. Filtragem de ruídos
 - 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 discretos
 - 4.7.2. Processo de discretização
- 4.8. Os dados
 - 4.8.1. Seleção de dados
 - 4.8.2. Perspectivas e critérios de seleção
 - 4.8.3. Métodos de seleção
- 4.9. Seleção de Instâncias
 - 4.9.1. Métodos para seleção de instâncias
 - 4.9.2. Seleção de protótipos
 - 4.9.3. Métodos avançados para seleção de instâncias
- 4.10. Pré-processamento de dados em ambientes *Big Data*

Módulo 5. Algoritmia e Complexidade em Inteligência Artificial

- 5.1. Introdução às Estratégias de design de algoritmos
 - 5.1.1. Recursividade
 - 5.1.2. Divisão e conquista
 - 5.1.3. Outras estratégias
- 5.2. Eficiência e análise de algoritmos
 - 5.2.1. Medidas de eficiência
 - 5.2.2. Como medir o tamanho da entrada
 - 5.2.3. Como medir o tempo de execução
 - 5.2.4. Melhor, pior e médio caso
 - 5.2.5. Notação assintótica
 - 5.2.6. Critérios de análise matemática para 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 bolha (Bubble sort)
 - 5.3.3. Ordenação por seleção (Selection sort)
 - 5.3.4. Ordenação por inserção (Insertion Sort)
 - 5.3.5. Ordenação por mistura (*merge_sort*)
 - 5.3.6. Classificação rápida (*quick_sort*)
- 5.4. Algoritmos com árvores
 - 5.4.1. Conceito de árvore
 - 5.4.2. Árvores binárias
 - 5.4.3. Caminhos de árvores
 - 5.4.4. Representar expressões
 - 5.4.5. Árvores binárias ordenadas
 - 5.4.6. Árvores binárias balanceadas
- 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 em largura
 - 5.6.3. Caminho em profundidade
 - 5.6.4. Ordenação topológica
- 5.7. Algoritmos *Greedy*
 - 5.7.1. A estratégia *Greedy*
 - 5.7.2. Elementos da estratégia *Greedy*
 - 5.7.3. Conversor de moedas
 - 5.7.4. Problema do Caixeiro Viajante
 - 5.7.5. Problema da mochila
- 5.8. Busca do caminho mínimo
 - 5.8.1. O problema do caminho mínimo
 - 5.8.2. Arco e ciclos negativos
 - 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 (algoritmo guloso)
 - 5.9.3. O algoritmo de Kruskal
 - 5.9.4. Análise de complexidade
- 5.10. *Backtracking*
 - 5.10.1. O *Backtracking*
 - 5.10.2. Técnicas alternativas

Módulo 6. Sistemas inteligentes

- 6.1. Teoria de Agentes
 - 6.1.1. História do conceito
 - 6.1.2. Definição de agente
 - 6.1.3. Agentes em Inteligência Artificial
 - 6.1.4. Agentes em Engenharia de Software
- 6.2. Arquiteturas de agentes
 - 6.2.1. O processo de raciocínio de um agente
 - 6.2.2. Agentes reativos
 - 6.2.3. Agentes dedutivos
 - 6.2.4. Agentes híbridos
 - 6.2.5. Comparativa
- 6.3. Informação e conhecimento
 - 6.3.1. Distinção entre dados, informações e conhecimentos
 - 6.3.2. Avaliação da qualidade dos dados
 - 6.3.3. Métodos de captura de dados
 - 6.3.4. Métodos de aquisição de informações
 - 6.3.5. Métodos de aquisição de conhecimentos
- 6.4. Representação do conhecimento
 - 6.4.1. A importância da representação do conhecimento
 - 6.4.2. Definição da representação do conhecimento através de 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 criação de ontologias
 - 6.6.1. Tríade RDF, Turtle e N
 - 6.6.2. RDF Schema
 - 6.6.3. OWL
 - 6.6.4. SPARQL
 - 6.6.5. Introdução às diferentes ferramentas para a criação de ontologias
 - 6.6.6. Instalação e uso do *Protégé*
- 6.7. Web Semântica
 - 6.7.1. O estado atual e futuro da segurança ad web semântica
 - 6.7.2. Aplicações da web semântica
- 6.8. Outros modelos de representação do conhecimento
 - 6.8.1. Vocabulários
 - 6.8.2. Visão global
 - 6.8.3. Taxonomias
 - 6.8.4. Tesouros
 - 6.8.5. Folksonomias
 - 6.8.6. Comparativa
 - 6.8.7. Mapas mentais
- 6.9. Avaliação e integração das representações do conhecimento
 - 6.9.1. Lógica de ordem zero
 - 6.9.2. Lógica de primeira ordem
 - 6.9.3. Lógica descritiva
 - 6.9.4. Relação entre diferentes tipos de lógica
 - 6.9.5. *Prolog*: programação baseada em lógica de alto nível
- 6.10. Raciocinadores Semânticos, Sistemas Baseados no Conhecimento e Sistemas Especialistas
 - 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 Especialistas
 - 6.10.5. Elementos e Arquitetura de Sistemas Especialistas
 - 6.10.6. Criação de Sistemas Especialistas

Módulo 7. Machine learning e mineração de dados

- 7.1. Introdução aos processos de descoberta de conhecimento e conceitos básicos de machine learning
 - 7.1.1. Conceitos-chave dos processos de descoberta do conhecimento
 - 7.1.2. Perspectiva histórica dos processos de descoberta do conhecimento
 - 7.1.3. Fases 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 machine learning
 - 7.1.6. Tipos de informações de machine learning
 - 7.1.7. Noções básicas de aprendizagem
 - 7.1.8. Noções básicas de aprendizagem não supervisionada
- 7.2. Exploração e pré-processamento de dados
 - 7.2.1. Processamento de dados
 - 7.2.2. Tratamento de dados no fluxo de análise de dados
 - 7.2.3. Tipos de dados
 - 7.2.4. Transformações 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 redução da dimensionalidade
- 7.3. Árvore de decisão
 - 7.3.1. Algoritmo ID
 - 7.3.2. Algoritmo
 - 7.3.3. Overtraining e poda
 - 7.3.4. Análise de resultados
- 7.4. Avaliação de classificadores
 - 7.4.1. Matrizes de confusão
 - 7.4.2. Matrizes de avaliação numérica
 - 7.4.3. Estatístico de Kappa
 - 7.4.4. Curvas Roc
- 7.5. Regras de classificação
 - 7.5.1. Medidas de avaliação de 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 de neurônios simples
 - 7.6.3. Algoritmo de *backpropagation*
 - 7.6.4. Introdução às redes neurais recorrentes
- 7.7. Métodos bayesianos
 - 7.7.1. Conceitos básicos de probabilidade
 - 7.7.2. Teorema de Bayes
 - 7.7.3. Naive Bayes
 - 7.7.4. Introdução às redes bayesianas
- 7.8. Modelos de regressão e 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 Vetores de Suporte (SVM)
 - 7.8.6. Medidas de bondade do ajuste
- 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 de linguagem natural (PNL)
 - 7.10.1. Conceitos básicos
 - 7.10.2. Criação do corpus
 - 7.10.3. Análise descritiva
 - 7.10.4. Introdução à análise de sentimentos

Módulo 8. Redes Neurais como Base do *Deep Learning*

- 8.1. Aprendizado profundo
 - 8.1.1. Tipos de aprendizagem profunda
 - 8.1.2. Aplicativos de aprendizagem profunda
 - 8.1.3. Vantagens e desvantagens da aprendizagem profunda
- 8.2. Operações
 - 8.2.1. Soma
 - 8.2.2. Produtos
 - 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. União de Camadas e Operações
 - 8.4.1. Design de arquiteturas
 - 8.4.2. Conexão entre camadas
 - 8.4.3. Propagação para frente
- 8.5. Construção da primeira rede neural
 - 8.5.1. Design da rede
 - 8.5.2. Definição dos pesos
 - 8.5.3. Treinamento da rede
- 8.6. Treinador e Otimizador
 - 8.6.1. Seleção do otimizador
 - 8.6.2. Definição de uma função de perda
 - 8.6.3. Definição de uma métrica
- 8.7. Aplicação dos princípios das redes neurais
 - 8.7.1. Funções de ativação
 - 8.7.2. Retropropagação
 - 8.7.3. Ajuste dos parâmetros
- 8.8. Dos neurônios biológicos para os artificiais
 - 8.8.1. Funcionamento de um neurônio biológico
 - 8.8.2. Transferência de conhecimento para os neurônios artificiais
 - 8.8.3. Estabelecimento de relações entre ambos

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

Módulo 9. Treinamento 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. Treinamento de transferência de aprendizagem
 - 9.2.2. Extração de características
 - 9.2.3. Aprendizado profundo
- 9.3. Otimizadores
 - 9.3.1. Otimizadores de descida de gradiente estocástico
 - 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 de 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. Diretrizes práticas
 - 9.6.1. Design de modelos
 - 9.6.2. Seleção de métricas e parâmetros de avaliação
 - 9.6.3. Testes de hipóteses

- 9.7. *Transfer Learning*
 - 9.7.1. Treinamento de transferência de aprendizagem
 - 9.7.2. Extração de características
 - 9.7.3. Aprendizado profundo
 - 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. Treinamento de transferência de aprendizagem
 - 9.9.2. Extração de características
 - 9.9.3. Aprendizado profundo
 - 9.10. Regularização
 - 9.10.1. L e L
 - 9.10.2. Regularização por máxima entropia
 - 9.10.3. *Dropout*
- Módulo 10. Personalização de Modelos e Treinamento com *TensorFlow***
- 10.1. *TensorFlow*
 - 10.1.1. Uso da biblioteca *TensorFlow*
 - 10.1.2. Treinamento de modelos com *TensorFlow*
 - 10.1.3. Operações com gráficos no *TensorFlow*
 - 10.2. *TensorFlow* e NumPy
 - 10.2.1. Ambiente computacional NumPy para *TensorFlow*
 - 10.2.2. Utilização de arrays NumPy com *TensorFlow*
 - 10.2.3. Operações NumPy para gráficos do *TensorFlow*
 - 10.3. Personalização de modelos e algoritmos de treinamento
 - 10.3.1. Construção de modelos personalizados com *TensorFlow*
 - 10.3.2. Gestão de parâmetros de treinamento
 - 10.3.3. Utilização de técnicas de otimização para treinamento
 - 10.4. Funções e gráficos do *TensorFlow*
 - 10.4.1. Funções com *TensorFlow*
 - 10.4.2. Utilização de gráficos para treinamento de modelos
 - 10.4.3. Otimização de gráficos com operações do *TensorFlow*
 - 10.5. Carregamento e pré-processamento de dados com *TensorFlow*
 - 10.5.1. Carregamento de conjuntos de dados com *TensorFlow*
 - 10.5.2. Pré-processamento de dados com *TensorFlow*
 - 10.5.3. Utilização de ferramentas do *TensorFlow* para manipulação de dados
 - 10.6. A API *tfddata*
 - 10.6.1. Utilização da API *tfddata* para processamento de dados
 - 10.6.2. Construção de fluxos de dados com *tfddata*
 - 10.6.3. Uso da API *tfddata* para treinamento de modelos
 - 10.7. O formato *TFRecord*
 - 10.7.1. Utilização da API *TFRecord* para serialização de dados
 - 10.7.2. Carregamento de arquivos *TFRecord* com *TensorFlow*
 - 10.7.3. Utilização de arquivos *TFRecord* para treinamento 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 *pipelines* de pré-processamento com Keras
 - 10.8.3. Uso da API de pré-processamento do Keras para treinamento de modelos
 - 10.9. O projeto *TensorFlow Datasets*
 - 10.9.1. Utilização de *TensorFlow Datasets* para upload de dados
 - 10.9.2. Pré-processamento de dados com *TensorFlow Datasets*
 - 10.9.3. Uso de *TensorFlow Datasets* para treinamento de modelos
 - 10.10. Construção de uma aplicação de *Deep Learning* com *TensorFlow*
 - 10.10.1. Aplicações práticas
 - 10.10.2. Construção de uma aplicação de *Deep Learning* com *TensorFlow*
 - 10.10.3. Treinamento de um modelo com *TensorFlow*
 - 10.10.4. Utilização da aplicação para previsão de resultados

Módulo 11. Deep Computer Vision com Redes Neurais Convolucionais

- 11.1. A Arquitetura *do Visual Cortex*
 - 11.1.1. Funções do córtex visual
 - 11.1.2. Teorias 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
 - 11.2.3. Funções de ativação
- 11.3. Camadas de agrupamento e implementação de camadas de agrupamento com o Keras
 - 11.3.1. *Agrupamento e Deslocamento*
 - 11.3.2. *Flattening*
 - 11.3.3. Tipos de *Pooling*
- 11.4. Arquiteturas CNN
 - 11.4.1. Arquitetura VGG
 - 11.4.2. Arquitetura *AlexNet*
 - 11.4.3. Arquitetura *ResNet*
- 11.5. Implementação de uma CNN *ResNet* usando o Keras
 - 11.5.1. Inicialização de pesos
 - 11.5.2. Definição da camada de entrada
 - 11.5.3. Definição da saída
- 11.6. Uso 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 aprendizado por transferência
 - 11.7.1. Aprendizagem por transferência
 - 11.7.2. Processo de aprendizagem por transferência
 - 11.7.3. Vantagens do aprendizagem por transferência
- 11.8. Classificação e localização em *Deep Computer Vision*
 - 11.8.1. Classificação de imagens
 - 11.8.2. Localização de objetos em imagens
 - 11.8.3. Detecção de objetos

- 11.9. Detecção e rastreamento de objetos
 - 11.9.1. Métodos de detecção de objetos
 - 11.9.2. Algoritmos de rastreamento de objetos
 - 11.9.3. Técnicas de rastreamento e localização
- 11.10. Segmentação semântica
 - 11.10.1. Aprendizagem profunda para segmentação semântica
 - 11.10.1. Detecção de bordas
 - 11.10.1. Métodos de segmentação baseados em regras

Módulo 12. Processamento de Linguagem Natural (PLN) com Redes Neurais Recorrentes (RNN) e Atenção

- 12.1. Geração de texto usando RNN
 - 12.1.1. Treinamento 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 do conjunto de dados de treinamento
 - 12.2.1. Preparação dos dados para treinamento de uma RNN
 - 12.2.2. Armazenamento do conjunto de dados de treinamento
 - 12.2.3. Limpeza e transformação dos dados
 - 12.2.4. Análise de sentimento
- 12.3. Classificação de 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 codificador-decodificador para tradução automática neural
 - 12.4.1. Treinamento de uma RNN para tradução automática
 - 12.4.2. Uso de uma rede *encoder-decoder* para tradução automática
 - 12.4.3. Aumento da precisão da tradução automática com RNN
- 12.5. Mecanismos de atenção
 - 12.5.1. Aplicação de mecanismos de atenção em RNN
 - 12.5.2. Uso de mecanismos de atenção para melhorar a precisão dos modelos
 - 12.5.3. Vantagens dos mecanismos de atenção em redes neurais

- 12.6. Modelos *Transformers*
 - 12.6.1. Uso de modelos *Transformers* para processamento de linguagem natural
 - 12.6.2. Aplicação de modelos *Transformers* para visão
 - 12.6.3. Vantagens dos modelos *Transformers*
- 12.7. *Transformers* para visão
 - 12.7.1. Uso de modelos *Transformers* para visão
 - 12.7.2. Processamento de dados Imagem
 - 12.7.3. Treinamento de modelos *Transformers* para visão
- 12.8. Biblioteca *Transformers* de *Hugging Face*
 - 12.8.1. Uso da Biblioteca *Transformers* de *Hugging Face*
 - 12.8.2. Aplicação da Biblioteca *Transformers* de *Hugging Face*
 - 12.8.3. Vantagens da Biblioteca *Transformers* de *Hugging Face*
- 12.9. Outras bibliotecas *Transformers*. Comparativa
 - 12.9.1. Comparação entre as diferentes bibliotecas *Transformers*
 - 12.9.2. Uso das diferentes bibliotecas *Transformers*
 - 12.9.3. Vantagens das diferentes bibliotecas *Transformers*
- 12.10. Desenvolvimento de um aplicativo de PLN com RNN e atenção. Aplicações práticas
 - 12.10.1. Desenvolvimento de um aplicativo de processamento de linguagem natural com RNN e atenção
 - 12.10.2. Uso de RNN, mecanismos de atenção e modelos *Transformers* no aplicativo
 - 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. Aprendizado profundo
 - 13.1.3. Representações compactas
- 13.2. Realização de PCA com um codificador automático linear incompleto
 - 13.2.1. Processo de treinamento
 - 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. Uso da regularização
- 13.4. Autoencoders convolucionais
 - 13.4.1. Design de modelos convolucionais
 - 13.4.2. Treinamento de modelos convolucionais
 - 13.4.3. Avaliação de resultados
- 13.5. Eliminação de ruído de codificadores automáticos
 - 13.5.1. Aplicação de filtros
 - 13.5.2. Design de modelos de codificação
 - 13.5.3. Uso de técnicas de regularização
- 13.6. Codificadores automáticos dispersos
 - 13.6.1. Aumentando a eficiência da codificação
 - 13.6.2. Minimizando o número de parâmetros
 - 13.6.3. Utilização de técnicas de regularização
- 13.7. Codificadores automáticos variacionais
 - 13.7.1. Utilização de 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. Treinamento de Redes Neurais Profundas
- 13.9. Redes adversárias generativas e modelos de difusão
 - 13.9.1. Geração de conteúdo a partir de imagens
 - 13.9.2. Modelagem de distribuições de dados
 - 13.9.3. Uso de redes adversárias
- 13.10. Implementação dos Modelos
 - 13.10.1. Aplicação Prática
 - 13.10.2. Implementação dos modelos
 - 13.10.3. Uso de dados reais
 - 13.10.4. Avaliação de resultados

Módulo 14. Computação bioinspirada

- 14.1. Introdução à computação bioinspirada
 - 14.1.1. Introdução à computação bioinspirada
- 14.2. Algoritmos de adaptação social
 - 14.2.1. Computação bioinspirada baseada em colônias de formigas
 - 14.2.2. Variantes dos algoritmos das 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 (I)
 - 14.5.1. Estratégias evolutivas
 - 14.5.2. Programação evolutiva
 - 14.5.3. Algoritmos baseados na evolução diferencial
- 14.6. Modelos de computação evolutiva (II)
 - 14.6.1. Modelos de evolução baseados em estimativas de distribuições (EDA)
 - 14.6.2. Programação genética
- 14.7. Programação evolutiva aplicada a dificuldades de aprendizagem
 - 14.7.1. Aprendizagem baseada em regras
 - 14.7.2. Métodos evolutivos em problemas de seleção de instâncias
- 14.8. Problemas multiobjetivo
 - 14.8.1. Conceito de dominância
 - 14.8.2. Aplicação de algoritmos evolutivos a problema multiobjetivo
- 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 uso de redes neurais na pesquisa médica
 - 14.10.2. Casos de uso de redes neurais em economia
 - 14.10.3. Casos de uso de redes neurais em 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 uso
 - 15.1.3. Riscos potenciais relacionados ao uso 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 uso
- 15.3. Riscos relacionados com o uso de IA no serviço de saúde
 - 15.3.1. Riscos potenciais relacionados ao uso de IA
 - 15.3.2. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.4. *Retail*
 - 15.4.1. Participação da IA no *Varejo* Oportunidades e desafios
 - 15.4.2. Casos de uso
 - 15.4.3. Riscos potenciais relacionados ao uso de IA
 - 15.4.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.5. Indústria
 - 15.5.1. Participação da IA na Indústria Oportunidades e desafios
 - 15.5.2. Casos de uso
- 15.6. Riscos potenciais relacionados ao uso de IA na indústria
 - 15.6.1. Casos de uso
 - 15.6.2. Riscos potenciais relacionados ao uso de IA
 - 15.6.3. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.7. Administração pública
 - 15.7.1. Participação da IA na administração pública Oportunidades e desafios
 - 15.7.2. Casos de uso
 - 15.7.3. Riscos potenciais relacionados ao uso de IA
 - 15.7.4. Potenciais desenvolvimentos/utilizações futuras da IA

- 15.8. Educação
 - 15.8.1. Participação da IA na educação Oportunidades e desafios
 - 15.8.2. Casos de uso
 - 15.8.3. Riscos potenciais relacionados ao uso de IA
 - 15.8.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.9. Silvicultura e agricultura
 - 15.9.1. Participação da IA na silvicultura e na agricultura Oportunidades e desafios
 - 15.9.2. Casos de uso
 - 15.9.3. Riscos potenciais relacionados ao uso de IA
 - 15.9.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.10. Recursos Humanos
 - 15.10.1. Implicações da IA para os recursos humanos. Oportunidades e desafios
 - 15.10.2. Casos de uso
 - 15.10.3. Riscos potenciais relacionados ao uso de IA
 - 15.10.4. Potenciais desenvolvimentos/utilizações futuras da IA

Módulo 16. Métodos e Ferramentas de IA usadas na pesquisa clínica

- 16.1. Tecnologias e Ferramentas de IA na pesquisa clínica
 - 16.1.1. Uso do aprendizado de máquina para identificar padrões em dados clínicos
 - 16.1.2. Desenvolvimento de algoritmos preditivos para ensaios clínicos
 - 16.1.3. Implementação de sistemas de IA para a melhoria no recrutamento de pacientes
 - 16.1.4. Ferramentas de IA para análise em tempo real de dados de pesquisa
- 16.2. Métodos estatísticos e algoritmos em estudos clínicos
 - 16.2.1. Aplicação de técnicas estatísticas avançadas para análise de dados clínicos
 - 16.2.2. Utilização de algoritmos para validação e verificação de resultados de ensaios
 - 16.2.3. Implementação de modelos de regressão e classificação em estudos clínicos
 - 16.2.4. Análise de grandes conjuntos de dados por meio de métodos estatísticos computacionais
- 16.3. Planejamento de experimentos e análise de resultados
 - 16.3.1. Estratégias para design eficiente de ensaios clínicos utilizando IA
 - 16.3.2. Técnicas de IA para análise e interpretação de dados experimentais
 - 16.3.3. Otimização de protocolos de pesquisa por meio de simulações de IA
 - 16.3.4. Avaliação da eficácia e segurança de tratamentos usando modelos de IA
- 16.4. Interpretação de imagens médicas por meio de IA em pesquisa
 - 16.4.1. Desenvolvimento de sistemas de IA para detecção automática de patologias em imagens
 - 16.4.2. Utilização de aprendizado profundo para classificação e segmentação em imagens médicas
 - 16.4.3. Ferramentas de IA para aprimorar a precisão em diagnósticos por imagem
 - 16.4.4. Análise de imagens radiológicas e de ressonância magnética por meio de IA
- 16.5. Análise de dados clínicos e biomédicos
 - 16.5.1. IA no processamento e análise de dados genômicos e proteômicos
 - 16.5.2. Ferramentas para análise integrada de dados clínicos e biomédicos
 - 16.5.3. Utilização de IA para identificar biomarcadores em pesquisa clínica
 - 16.5.4. Análise preditiva de resultados clínicos baseada em dados biomédicos
- 16.6. Visualização avançada de dados em pesquisa clínica
 - 16.6.1. Desenvolvimento de ferramentas de visualização interativa para dados clínicos
 - 16.6.2. Utilização de IA na criação de representações gráficas de dados complexos
 - 16.6.3. Técnicas de visualização para interpretação fácil de resultados de pesquisa
 - 16.6.4. Ferramentas de realidade aumentada e virtual para visualização de dados biomédicos
- 16.7. Processamento de linguagem natural em documentação científica e clínica
 - 16.7.1. Aplicação de PNL para análise de literatura científica e registros clínicos
 - 16.7.2. Ferramentas de IA para extração de informações relevantes de textos médicos
 - 16.7.3. Sistemas de IA para resumir e categorizar publicações científicas
 - 16.7.4. Utilização de PNL na identificação de tendências e padrões em documentação clínica
- 16.8. Processamento de dados heterogêneos em Pesquisa Clínica
 - 16.8.1. Técnicas de IA para integrar e analisar dados de diversas fontes clínicas
 - 16.8.2. Ferramentas para gerenciamento de dados clínicos não estruturados
 - 16.8.3. Sistemas de IA para correlação de dados clínicos e demográficos
 - 16.8.4. Análise de dados multidimensionais para obter *insights* clínicos

- 16.9. Aplicações de redes neurais na pesquisa biomédica
 - 16.9.1. Utilização de redes neurais para modelagem de doenças e previsão de tratamentos
 - 16.9.2. Implementação de redes neurais na classificação de doenças genéticas
 - 16.9.3. Desenvolvimento de sistemas de diagnóstico baseados em redes neurais
 - 16.9.4. Aplicação de redes neurais na personalização de tratamentos médicos
- 16.10. Modelagem preditiva e seu impacto na pesquisa clínica
 - 16.10.1. Desenvolvimento de modelos preditivos para antecipação de resultados clínicos
 - 16.10.2. Utilização de IA na previsão de efeitos colaterais e reações adversas
 - 16.10.3. Implementação de modelos preditivos na otimização de ensaios clínicos
 - 16.10.4. Análise de riscos em tratamentos médicos utilizando modelagem preditiva

Módulo 17. Pesquisa biomédica com IA

- 17.1. Planejamento e execução de estudos observacionais com IA
 - 17.1.1. Implementação de IA para seleção e segmentação de populações em estudos
 - 17.1.2. Uso de algoritmos para monitoramento em tempo real de dados de estudos observacionais
 - 17.1.3. Ferramentas de IA para identificação de padrões e correlações em estudos observacionais
 - 17.1.4. Automatização do processo de coleta e análise de dados em estudos observacionais
- 17.2. Validação e calibração de modelos em pesquisa clínica
 - 17.2.1. Técnicas de IA para assegurar precisão e confiabilidade de modelos clínicos
 - 17.2.2. Uso de IA na calibração de modelos preditivos em pesquisa clínica
 - 17.2.3. Métodos de validação cruzada aplicados a modelos clínicos por meio de IA
 - 17.2.4. Ferramentas de IA para avaliação da generalização de modelos clínicos
- 17.3. Métodos de integração de dados heterogêneos em pesquisa clínica
 - 17.3.1. Técnicas de IA para combinar dados clínicos, genômicos e ambientais
 - 17.3.2. Uso de algoritmos para lidar e analisar dados clínicos não estruturados
 - 17.3.3. Ferramentas de IA para normalização e padronização de dados clínicos
 - 17.3.4. Sistemas de IA para correlação de diferentes tipos de dados em pesquisa

- 17.4. Integração de dados biomédicos multidisciplinares
 - 17.4.1. Sistemas de IA para combinar dados de diferentes disciplinas biomédicas
 - 17.4.2. Algoritmos para análise integrada de dados clínicos e de laboratório
 - 17.4.3. Ferramentas de IA para visualização de dados biomédicos complexos
 - 17.4.4. Uso de IA na criação de modelos holísticos de saúde a partir de dados multidisciplinares
- 17.5. Algoritmos de aprendizado profundo em análise de dados biomédicos
 - 17.5.1. Implementação de redes neurais na análise de dados genéticos e proteômicos
 - 17.5.2. Uso de aprendizado profundo para identificação de padrões em dados biomédicos
 - 17.5.3. Desenvolvimento de modelos preditivos em medicina de precisão com aprendizado profundo
 - 17.5.4. Aplicação de IA na análise avançada de imagens biomédicas
- 17.6. Otimização de processos de pesquisa com automação
 - 17.6.1. Automação de rotinas de laboratório por meio de sistemas de IA
 - 17.6.2. Uso de IA para gestão eficiente de recursos e tempo em pesquisa
 - 17.6.3. Ferramentas de IA para otimização de fluxos de trabalho em pesquisa clínica
 - 17.6.4. Sistemas automatizados para acompanhamento e relato de avanços em pesquisa
- 17.7. Simulação e modelagem computacional em medicina com IA
 - 17.7.1. Desenvolvimento de modelos computacionais para simulação de cenários clínicos
 - 17.7.2. Uso de IA para simulação de interações moleculares e celulares
 - 17.7.3. Ferramentas de IA na criação de modelos preditivos de doenças
 - 17.7.4. Aplicação de IA na simulação de efeitos de fármacos e tratamentos
- 17.8. Uso da realidade virtual e aumentada em estudos clínicos
 - 17.8.1. Implementação de realidade virtual para formação e simulação em medicina
 - 17.8.2. Uso de realidade aumentada em procedimentos cirúrgicos e diagnósticos
 - 17.8.3. Ferramentas de realidade virtual para estudos de comportamento e psicologia
 - 17.8.4. Aplicação de tecnologias imersivas na reabilitação e terapia
- 17.9. Ferramentas de mineração de dados aplicadas à pesquisa biomédica
 - 17.9.1. Uso de técnicas de mineração de dados para extrair conhecimentos de bancos de dados biomédicos
 - 17.9.2. Implementação de algoritmos de IA para descoberta de padrões em dados clínicos
 - 17.9.3. Ferramentas de IA para identificação de tendências em grandes conjuntos de dados
 - 17.9.4. Aplicação de mineração de dados na geração de hipóteses de pesquisa

- 17.10. Desenvolvimento e validação de biomarcadores com inteligência artificial
 - 17.10.1. Uso de IA para identificação e caracterização de novos biomarcadores
 - 17.10.2. Implementação de modelos de IA para validação de biomarcadores em estudos clínicos
 - 17.10.3. Ferramentas de IA na correlação de biomarcadores com resultados clínicos
 - 17.10.4. Aplicação de IA na análise de biomarcadores para a medicina personalizada

Módulo 18. Aplicação prática da IA na pesquisa clínica

- 18.1. Tecnologias de sequenciamento genômico e análise de dados de IA
 - 18.1.1. Uso de IA para análise rápida e precisa de sequências genéticas
 - 18.1.2. Implementação de algoritmos de aprendizado automático na interpretação de dados genômicos
 - 18.1.3. Ferramentas de IA para identificação de variantes genéticas e mutações
 - 18.1.4. Aplicação de IA na correlação genômica com doenças e características
- 18.2. IA na análise de imagens biomédicas
 - 18.2.1. Desenvolvimento de sistemas de IA para detecção de anomalias em imagens médicas
 - 18.2.2. Uso da aprendizagem profunda na interpretação de raios X, ressonância magnética e tomografia computadorizada
 - 18.2.3. Ferramentas de IA para melhorar a precisão no diagnóstico por imagens
 - 18.2.4. Implementação de IA na classificação e segmentação de imagens biomédicas
- 18.3. Robótica e automação em laboratórios clínicos
 - 18.3.1. Uso de robôs para automação de testes e processos em laboratórios
 - 18.3.2. Implementação de sistemas automáticos para gestão de amostras biológicas
 - 18.3.3. Desenvolvimento de tecnologias robóticas para melhorar a eficiência e precisão em análises clínicas
 - 18.3.4. Aplicação de IA na otimização de fluxos de trabalho em laboratórios
- 18.4. IA na personalização de terapias e medicina de precisão
 - 18.4.1. Desenvolvimento de modelos de IA para personalização de tratamentos médicos
 - 18.4.2. Uso de algoritmos preditivos na seleção de terapias com base em perfis genéticos
 - 18.4.3. Ferramentas de IA na adaptação de doses e combinações de medicamentos
 - 18.4.4. Aplicação de IA na identificação de tratamentos eficazes para grupos específicos
- 18.5. Inovações em diagnósticos assistidos por IA
 - 18.5.1. Implementação de sistemas de IA para diagnósticos rápidos e precisos
 - 18.5.2. Uso de IA na identificação precoce de doenças por meio de análise de dados
 - 18.5.3. Desenvolvimento de ferramentas de IA para interpretação de testes clínicos
 - 18.5.4. Aplicação de IA na combinação de dados clínicos e biomédicos para diagnósticos abrangentes
- 18.6. Aplicativos de IA em estudos de microbioma e microbiologia
 - 18.6.1. Uso de IA na análise e mapeamento do microbioma humano
 - 18.6.2. Implementação de algoritmos para estudar a relação entre microbioma e doenças
 - 18.6.3. Ferramentas de IA na identificação de padrões em estudos microbiológicos
 - 18.6.4. Aplicação de IA na pesquisa de terapias baseadas no microbioma
- 18.7. Wearables e monitoramento remoto em estudos clínicos
 - 18.7.1. Desenvolvimento de dispositivos wearables com IA para monitoramento contínuo da saúde
 - 18.7.2. Uso de IA na interpretação de dados coletados por wearables
 - 18.7.3. Implementação de sistemas de monitoramento remoto em ensaios clínicos
 - 18.7.4. Aplicação de IA na previsão de eventos clínicos por meio de dados de wearables
- 18.8. IA na gestão de estudos clínicos
 - 18.8.1. Uso de sistemas de IA para otimização da gestão de ensaios clínicos
 - 18.8.2. Implementação de IA na seleção e acompanhamento de participantes
 - 18.8.3. Ferramentas de IA para análise de dados e resultados de ensaios clínicos
 - 18.8.4. Aplicação de IA na melhoria da eficiência e redução de custos em ensaios
- 18.9. Desenvolvimento de vacinas e tratamentos assistidos pela IA
 - 18.9.1. Uso de IA na aceleração do desenvolvimento de vacinas
 - 18.9.2. Implementação de modelos preditivos na identificação de potenciais tratamentos
 - 18.9.3. Ferramentas de IA para simular respostas a vacinas e medicamentos
 - 18.9.4. Aplicação de IA na personalização de vacinas e terapias

- 18.10. Aplicativos de IA em estudos de imunologia e resposta imunológica
 - 18.10.1. Desenvolvimento de modelos de IA para entender mecanismos imunológicos
 - 18.10.2. Uso de IA na identificação de padrões em respostas imunes
 - 18.10.3. Implementação de IA na pesquisa de distúrbios autoimunes
 - 18.10.4. Aplicação de IA na gestão de imunoterapias personalizadas

Módulo 19. Análise de *Big Data* e aprendizagem automática na pesquisa clínica

- 19.1. *Big Data* em pesquisa clínica: Conceitos e ferramentas
 - 19.1.1. A explosão de dados no âmbito da pesquisa clínica
 - 19.1.2. Conceito de *Big Data* e principais ferramentas
 - 19.1.3. Aplicações de *Big Data* em Pesquisa Clínica
- 19.2. Mineração de dados em registros clínicos e biomédicos
 - 19.2.1. Principais metodologias para a mineração de dados
 - 19.2.2. Integração de dados de registros clínicos e biomédicos
 - 19.2.3. Detecção de padrões e anomalias em registros clínicos e biomédicos
- 19.3. Algoritmos de aprendizado de máquina em pesquisa biomédica
 - 19.3.1. Técnicas de classificação em pesquisa biomédica
 - 19.3.2. Técnicas de regressão em pesquisa biomédica
 - 19.3.4. Técnicas não supervisionadas em pesquisa biomédica
- 19.4. Técnicas de análise preditiva em pesquisa clínica
 - 19.4.1. Técnicas de classificação em pesquisa clínica
 - 19.4.2. Técnicas de regressão em pesquisa clínica
 - 19.4.3. *Deep Learning* em pesquisa clínica
- 19.5. Modelos de IA em epidemiologia e saúde pública
 - 19.5.1. Técnicas de IA em epidemiologia e saúde pública
 - 19.5.2. Técnicas de regressão para epidemiologia e saúde pública
 - 19.5.3. Técnicas não supervisionadas em epidemiologia e saúde pública
- 19.6. Análise de redes biológicas e padrões de doenças
 - 19.6.1. Exploração de interações em redes biológicas para identificação de padrões de doença
 - 19.6.2. Integração de dados omics na análise de redes para caracterizar complexidades biológicas
 - 19.6.3. Aplicação de algoritmos de *machine learning* para descoberta de padrões de doença
- 19.7. Desenvolvimento de ferramentas para prognóstico clínico
 - 19.7.1. Criação de ferramentas inovadoras para prognóstico clínico baseadas em dados multidimensionais
 - 19.7.2. Integração de variáveis clínicas e moleculares no desenvolvimento de ferramentas de prognóstico
 - 19.7.3. Avaliação da eficácia das ferramentas de prognóstico em diversos contextos clínicos
- 19.8. Visualização e comunicação de dados complexos de forma avançada
 - 19.8.1. Utilização de técnicas de visualização avançada para representar dados biomédicos complexos
 - 19.8.2. Desenvolvimento de estratégias de comunicação efetiva para apresentar resultados de análises complexas
 - 19.8.3. Implementação de ferramentas de interatividade em visualizações para melhorar a compreensão
- 19.9. Segurança de dados e desafios de gestão de dados *Big Data*
 - 19.9.1. Abordagem de desafios na segurança de dados no contexto de *Big Data* biomédico
 - 19.9.2. Estratégias para a proteção da privacidade na gestão de grandes conjuntos de dados biomédicos
 - 19.9.3. Implementação de medidas de segurança para mitigar riscos no manuseio de dados sensíveis
- 19.10. Aplicações práticas e estudos de caso em *Big Data* biomédico
 - 19.10.1. Exploração de casos de sucesso na implementação de *Big Data* biomédico em pesquisa clínica
 - 19.10.2. Desenvolvimento de estratégias práticas para a aplicação de *Big Data* na tomada de decisões clínicas
 - 19.10.3. Avaliação de impacto e lições aprendidas por meio de estudos de caso no âmbito biomédico

Módulo 20. Aspectos éticos, legais e futuros da IA na pesquisa clínica

- 20.1. Ética na aplicação de IA em pesquisas clínicas
 - 20.1.1. Análise ética da tomada de decisões assistida por IA em ambientes de pesquisa clínica
 - 20.1.2. Ética no uso de algoritmos de IA para a seleção de participantes em estudos clínicos
 - 20.1.3. Considerações éticas na interpretação de resultados gerados por sistemas de IA em pesquisa clínica
- 20.2. Considerações legais e regulatórias sobre IA biomédica
 - 20.2.1. Análise da regulamentação legal no desenvolvimento e aplicação de tecnologias de IA no âmbito biomédico
 - 20.2.2. Avaliação da conformidade com regulamentações específicas para garantir a segurança e eficácia de soluções baseadas em IA
 - 20.2.3. Abordagem de desafios regulatórios emergentes associados ao uso de IA em pesquisa biomédica
- 20.3. Consentimento informado e aspectos éticos no uso de dados clínicos
 - 20.3.1. Desenvolvimento de estratégias para garantir um consentimento informado efetivo em projetos que envolvem IA
 - 20.3.2. Ética na coleta e uso de dados clínicos sensíveis no contexto de pesquisas impulsionadas por IA
 - 20.3.3. Abordagem de questões éticas relacionadas à propriedade e acesso a dados clínicos em projetos de pesquisa
- 20.4. IA e responsabilidade na pesquisa clínica
 - 20.4.1. Avaliação da responsabilidade ética e legal na implementação de sistemas de IA em protocolos de pesquisa clínica
 - 20.4.2. Desenvolvimento de estratégias para abordar possíveis consequências adversas da aplicação de IA no âmbito da pesquisa biomédica
 - 20.4.3. Considerações éticas na participação ativa da IA na tomada de decisões em pesquisa clínica
- 20.5. Impacto da IA na equidade e no acesso à assistência médica
 - 20.5.1. Avaliação do impacto de soluções de IA na equidade na participação em ensaios clínicos
 - 20.5.2. Desenvolvimento de estratégias para melhorar o acesso a tecnologias de IA em ambientes clínicos diversos
 - 20.5.3. Ética na distribuição de benefícios e riscos associados à aplicação de IA no cuidado de saúde
- 20.6. Privacidade e proteção de dados em projetos de pesquisa
 - 20.6.1. Garantia da privacidade dos participantes em projetos de pesquisa que envolvem o uso de IA
 - 20.6.2. Desenvolvimento de políticas e práticas para a proteção de dados em pesquisas biomédicas
 - 20.6.3. Abordagem de desafios específicos de privacidade e segurança no manejo de dados sensíveis no âmbito clínico
- 20.7. IA e sustentabilidade na pesquisa biomédica
 - 20.7.1. Avaliação do impacto ambiental e recursos associados à implementação de IA em pesquisas biomédicas
 - 20.7.2. Desenvolvimento de práticas sustentáveis na integração de tecnologias de IA em projetos de pesquisa clínica
 - 20.7.3. Ética na gestão de recursos e sustentabilidade na adoção de IA em pesquisas biomédicas
- 20.8. Auditoria e explicabilidade de modelos de IA no âmbito clínico
 - 20.8.1. Desenvolvimento de protocolos de auditoria para avaliar a confiabilidade e precisão de modelos de IA em pesquisa clínica
 - 20.8.2. Ética na explicabilidade de algoritmos para garantir a compreensão de decisões tomadas por sistemas de IA em contextos clínicos
 - 20.8.3. Abordagem de desafios éticos na interpretação de resultados de modelos de IA em pesquisas biomédicas
- 20.9. Inovação e empreendedorismo no campo da IA clínica
 - 20.9.1. Ética na inovação responsável ao desenvolver soluções de IA para aplicações clínicas
 - 20.9.2. Desenvolvimento de estratégias empresariais éticas no âmbito da IA clínica
 - 20.9.3. Considerações éticas na comercialização e adoção de soluções de IA no setor clínico
- 20.10. Considerações éticas na colaboração internacional em pesquisa clínica
 - 20.10.1. Desenvolvimento de acordos éticos e legais para a colaboração internacional em projetos de pesquisa impulsionados por IA
 - 20.10.2. Ética na participação de múltiplas instituições e países na pesquisa clínica com tecnologias de IA
 - 20.10.3. Abordagem de desafios éticos emergentes associados à colaboração global em pesquisas biomédicas

06

Metodología

Este curso oferece uma maneira diferente de aprender. Nossa metodologia é desenvolvida através de um modo de aprendizagem cíclico: o **Relearning**. Este sistema de ensino é utilizado, por exemplo, nas faculdades de medicina mais prestigiadas do mundo e foi considerado um dos mais eficazes pelas principais publicações científicas, como o **New England Journal of Medicine**.



“

Descubra o Relearning, um sistema que abandona a aprendizagem linear convencional para realizá-la através de sistemas de ensino cíclicos: uma forma de aprendizagem que se mostrou extremamente eficaz, especialmente em disciplinas que requerem memorização"

Estudo de caso para contextualizar todo o conteúdo

Nosso programa oferece um método revolucionário para desenvolver as habilidades e o conhecimento. Nosso objetivo é fortalecer as competências em um contexto de mudança, competitivo e altamente exigente.

“

Com a TECH você irá experimentar uma forma de aprender que está revolucionando as bases das universidades tradicionais em todo o mundo”



Você terá acesso a um sistema de aprendizagem baseado na repetição, por meio de um ensino natural e progressivo ao longo de todo o programa.



Um método de aprendizagem inovador e diferente

Este curso da TECH é um programa de ensino intensivo, criado do zero, que propõe os desafios e decisões mais exigentes nesta área, em âmbito nacional ou internacional. Através desta metodologia, o crescimento pessoal e profissional é impulsionado em direção ao sucesso. O método do caso, técnica que constitui a base deste conteúdo, garante que a realidade econômica, social e profissional mais atual seja adotada.

“

Nosso programa prepara você para enfrentar novos desafios em ambientes incertos e alcançar o sucesso na sua carreira”

Através de atividades de colaboração e casos reais, o aluno aprenderá a resolver situações complexas em ambientes reais de negócios.

O método do caso é o sistema de aprendizagem mais utilizado nas principais escolas de Informática do mundo, desde que elas existem. Desenvolvido em 1912 para que os estudantes de Direito não aprendessem a lei apenas com base no conteúdo teórico, o método do caso consistia em apresentar-lhes situações realmente complexas para que tomassem decisões conscientes e julgassem a melhor forma de resolvê-las. Em 1924 foi estabelecido como o método de ensino padrão em Harvard.

Em uma determinada situação, o que um profissional deveria fazer? Esta é a pergunta que abordamos no método do caso, um método de aprendizagem orientado para a ação. Ao longo do curso, os alunos vão se deparar com múltiplos casos reais. Terão que integrar todo o conhecimento, pesquisar, argumentar e defender suas ideias e decisões.

Metodologia Relearning

A TECH utiliza de maneira eficaz a metodologia do estudo de caso com um sistema de aprendizagem 100% online, baseado na repetição, combinando elementos didáticos diferentes em cada aula.

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

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

Na TECH você aprenderá através de uma metodologia de vanguarda, desenvolvida para capacitar os profissionais do futuro. Este método, na vanguarda da pedagogia mundial, se chama Relearning.

Nossa universidade é uma das únicas que possui a licença para usar este método de sucesso. Em 2019 conseguimos melhorar os níveis de satisfação geral dos nossos alunos (qualidade de ensino, qualidade dos materiais, estrutura dos curso, objetivos, entre outros) com relação aos indicadores da melhor universidade online.



No nosso programa, a aprendizagem não é um processo linear, ela acontece em espiral (aprender, desaprender, esquecer e reaprender). Portanto, combinamos cada um desses elementos de forma concêntrica. Esta metodologia já capacitou mais de 650 mil universitários com um sucesso sem precedentes em campos tão diversos como a bioquímica, a genética, a cirurgia, o direito internacional, habilidades administrativas, ciência do esporte, filosofia, direito, engenharia, jornalismo, história, mercados e instrumentos financeiros. Tudo isso em um ambiente altamente exigente, com um corpo discente com um perfil socioeconômico médio-alto e uma média de idade de 43,5 anos.

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

A partir das últimas evidências científicas no campo da neurociência, sabemos como organizar informações, ideias, imagens, memórias, mas sabemos também que o lugar e o contexto onde aprendemos algo é fundamental para nossa capacidade de lembrá-lo e armazená-lo no hipocampo, para mantê-lo em nossa memória a longo prazo.

Desta forma, no que se denomina Neurocognitive context-dependent e-learning, os diferentes elementos do nosso programa estão ligados ao contexto onde o aluno desenvolve sua prática profissional.



Neste programa, oferecemos o melhor material educacional, preparado especialmente para os profissionais:



Material de estudo

Todo o conteúdo foi criado especialmente para o curso pelos especialistas que irão ministrá-lo, o que faz com que o desenvolvimento didático seja realmente específico e concreto.

Posteriormente, esse conteúdo é adaptado ao formato audiovisual, para criar o método de trabalho online da TECH. Tudo isso, com as técnicas mais inovadoras que proporcionam alta qualidade em todo o material que é colocado à disposição do aluno.



Masterclasses

Há evidências científicas sobre a utilidade da observação de terceiros especialistas.

O "Learning from an expert" fortalece o conhecimento e a memória, além de gerar segurança para a tomada de decisões difíceis no futuro.




Práticas de habilidades e competências

Serão realizadas atividades para desenvolver competências e habilidades específicas em cada área temática. Práticas e dinâmicas para adquirir e ampliar as competências e habilidades que um especialista precisa desenvolver no contexto globalizado em que vivemos.



Leituras complementares

Artigos recentes, documentos de consenso e diretrizes internacionais, entre outros. Na biblioteca virtual da TECH o aluno terá acesso a tudo o que for necessário para complementar a sua capacitação.





Estudos de caso

Os alunos irão completar uma seleção dos melhores estudos de caso escolhidos especialmente para esta capacitação. Casos apresentados, analisados e orientados pelos melhores especialistas do cenário internacional.



Resumos interativos

A equipe da TECH apresenta o conteúdo de forma atraente e dinâmica através de pílulas multimídia que incluem áudios, vídeos, imagens, gráficos e mapas conceituais para consolidar o conhecimento.

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



Testing & Retesting

Avaliamos e reavaliamos periodicamente o conhecimento do aluno ao longo do programa, através de atividades e exercícios de avaliação e autoavaliação, para que possa comprovar que está alcançando seus objetivos.



07

Certificado

O Mestrado Próprio em Inteligência Artificial em Pesquisa Clínica garante, além da capacitação mais rigorosa e atualizada, o acesso a um título de Mestrado Próprio emitido pela TECH Universidade Tecnológica.



“

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

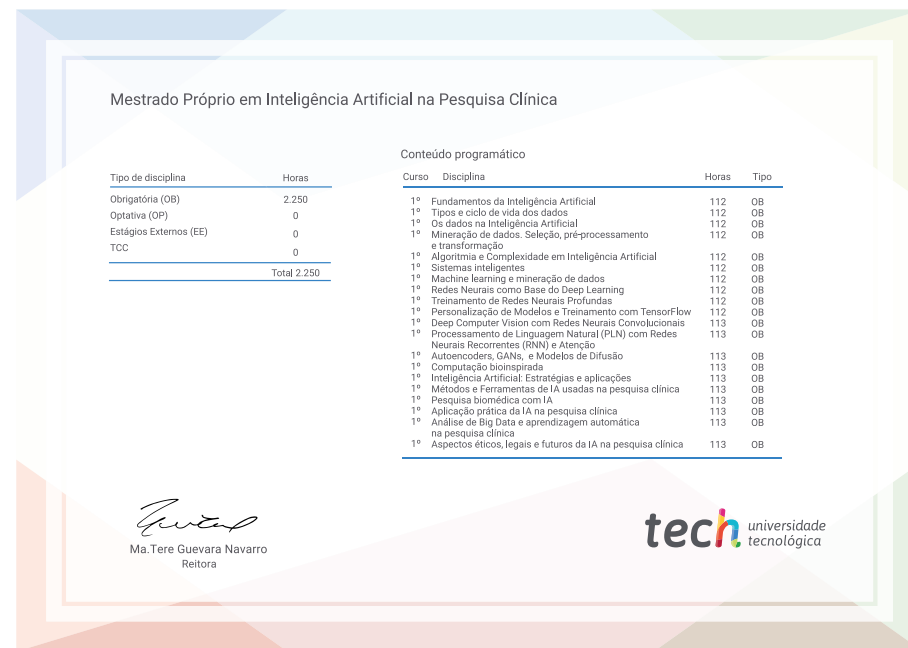
Este **Mestrado Próprio em Inteligência Artificial em Pesquisa Clínica** conta com o conteúdo mais completo e atualizado do mercado.

Uma vez aprovadas as avaliações, o aluno receberá por correio 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 empregos, concursos públicos e avaliação de carreira profissional.

Título: **Mestrado Próprio em Inteligência Artificial em Pesquisa Clínica**

N.º de Horas Oficiais: **2.250h**



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

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

tech universidade
tecnológica

Mestrado Próprio Inteligência Artificial na Pesquisa Clínica

- » Modalidade: online
- » Duração: 12 meses
- » Certificado: TECH Universidade Tecnológica
- » Dedicção: 16h/semana
- » Horário: no seu próprio ritmo
- » Provas: online

Mestrado Próprio

Inteligência Artificial na Pesquisa Clínica