

Mestrado Próprio

Inteligência Artificial na Prática Clínica



tech universidade
tecnológica

Mestrado Próprio Inteligência Artificial na Prática 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-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

Certificado

pág. 52

01

Apresentação

A Inteligência Artificial (IA) está desempenhando um papel cada vez mais importante na pesquisa clínica e na área da saúde. Um dos motivos para isso é que esses sistemas ajudam na identificação de patologias por meio da análise de imagens médicas (como raios X e tomografias computadorizadas). Dessa forma, os especialistas podem detectar anomalias com mais precisão e rapidez. Por sua vez, isso significa um diagnóstico precoce e até mesmo a detecção de doenças em estágios iniciais. Nesse contexto, a TECH lançou um programa que se aprofundará na integração do aprendizado de máquina em questões clínicas. Além disso, ele se baseia em uma metodologia 100% online para que os alunos possam combinar seus estudos com o restante de suas atividades diárias.



“

Você analisará como a IA interpreta os dados genéticos para projetar estratégias terapêuticas específicas, graças a este programa 100% online”

A análise de *Big Data* melhora significativamente o atendimento médico e a pesquisa na área da saúde. Esses sistemas avançados oferecem aos especialistas a oportunidade de personalizar os tratamentos. As informações do paciente, como histórico médico, genética e estilo de vida, são usadas para adaptar os planos de tratamento e os medicamentos a cada paciente. Além disso, essas ferramentas contribuem para o monitoramento contínuo de pacientes fora do ambiente clínico, o que é particularmente benéfico para usuários com doenças crônicas. Dessa forma, os recursos de IA contribuem para o desenvolvimento de procedimentos de abordagem mais eficazes e para um atendimento mais seguro.

Por esse motivo, a TECH elaborou um Mestrado Próprio que se aprofundará na análise do *Big Data* e aprendizado de máquina em pesquisa clínica. O plano de estudos abordará aspectos como a mineração de dados em registros clínicos e biomédicos, ao mesmo tempo em que se concentra em algoritmos e fornece técnicas de análise preditiva. Além disso, a capacitação explorará as interações que ocorrem em redes biológicas para a identificação de padrões de doenças. Além disso, o programa dará atenção especial aos fatores éticos e legais da IA no contexto médico. Dessa forma, os alunos adquirem uma consciência responsável ao realizar seus procedimentos.

Vale ressaltar que, para consolidar todo esse conteúdo, a TECH conta com a revolucionária metodologia do *Relearning*. Esse sistema de ensino baseia-se na reiteração de conceitos-chave para consolidar a compreensão ideal. O único requisito para os alunos é contar com um dispositivo eletrônico (como um telefone celular, computador ou tablet) conectado à Internet para acessar o Campus Virtual e visualizar o conteúdo a qualquer momento. Assim, eles aprenderão no conforto de suas casas, sem precisar de aulas presenciais e horários pré-estabelecidos.

Este **Mestrado Próprio em Inteligência Artificial em Prática Clínica** conta com o conteúdo científico 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



Você dominará os conjuntos de dados do TensorFlow para carregamento de dados e obterá um pré-processamento eficiente de dados médicos graças a esse programa”

“

Você estará na vanguarda da área médica! Este programa combina excelência clínica com a revolução tecnológica do aprendizado de máquina”

A equipe de professores deste programa inclui profissionais desta área, cuja experiência é somada a esta capacitação, além de reconhecidos especialistas de conceituadas sociedades científicas 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.

A estrutura modular do programa lhe permitirá uma progressão coerente desde o básico até os aplicativos mais avançados.

Não se preocupe em decorar o conteúdo! Com o sistema Relearning, você integrará os conceitos de forma natural e progressiva.



02

Objetivos

Este Mestrado Próprio transformará os alunos em verdadeiros líderes, capazes de superar os desafios atuais e futuros da medicina. Os alunos terão um conhecimento profundo de IA, o que contribuirá para o desenvolvimento de soluções inovadoras para transformar o setor de saúde. Dessa forma, os profissionais aplicarão técnicas de análise de dados médicos, o desenvolvimento de modelos preditivos para estudos clínicos e a implementação de soluções inovadoras para a personalização de tratamentos.




“

Atualize sua prática clínica diária para estar na vanguarda da revolução tecnológica na área da saúde, contribuindo para o avanço da Prática Clínica”



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



Justification

Standard list of comment

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 o *Fine 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. Diagnóstico na prática clínica através de IA

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

Módulo 17. Tratamento e controle do paciente com IA

- ♦ Interpretar os resultados para a criação ética de *datasets* e implementação estratégica em emergências de saúde
- ♦ Adquirir habilidades avançadas na apresentação, visualização e gestão de dados de IA de saúde
- ♦ Obter uma perspectiva abrangente sobre as tendências emergentes e inovações tecnológicas em IA aplicadas à saúde
- ♦ Desenvolver algoritmos de IA para aplicações específicas, como monitoramento de saúde, facilitando a implementação efetiva de soluções na prática médica
- ♦ Projetar e implementar tratamentos médicos individualizados analisando os dados clínicos e genômicos dos pacientes com IA

Módulo 18. Personalização da saúde por meio da IA

- ♦ Conhecer as tendências emergentes em IA aplicadas à saúde personalizada e seu impacto futuro
- ♦ Definir as aplicações da IA para personalizar tratamentos médicos, desde a análise genômica até o controle da dor
- ♦ Diferenciar algoritmos específicos de IA para o desenvolvimento de aplicativos relacionados ao design de medicamentos e à robótica cirúrgica
- ♦ Delinear as tendências emergentes em IA de saúde personalizada e seu impacto futuro
- ♦ Promover a inovação por meio da criação de estratégias para melhorar a assistência médica

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

- ♦ Adquirir um conhecimento sólido de coleta, filtragem e pré-processamento de dados médicos
- ♦ Desenvolver uma abordagem clínica baseada na qualidade e integridade dos dados no contexto das normas de privacidade
- ♦ Aplicar o conhecimento adquirido em casos de uso e aplicações práticas, permitindo que o aluno entenda e resolva desafios específicos do setor, desde a análise de texto até a visualização de dados e a segurança de informações médicas
- ♦ Definir técnicas de *Big Data* específicas do setor de saúde, incluindo processamento de texto, avaliação de qualidade e aplicação de algoritmos de aprendizado de máquina para personalização e análise
- ♦ Empregar procedimentos de *Big Data* para rastrear e monitorar a disseminação de doenças infecciosas em tempo real para uma resposta eficaz a epidemias



Módulo 20. Ética e regulamentação em IA médica

- Compreender os princípios éticos fundamentais e as normas legais aplicáveis à implementação da IA na medicina
- Dominar os princípios de governança de dados
- Compreender as estruturas regulatórias internacionais e locais
- Garantir a conformidade regulatória no uso de dados e ferramentas de IA no setor de saúde
- Desenvolver habilidades para projetar sistemas de IA centrados no ser humano, promovendo a justiça e a transparência no aprendizado de máquina

“*Aproveite o conteúdo acadêmico mais atualizado no cenário educacional, disponível em formatos multimídia inovadores para otimizar seu estudo*”

03

Competências

Esta capacitação fornecerá aos alunos uma atualização sobre a aplicação da IA no campo da pesquisa clínica. Dessa forma, os especialistas estarão equipados com habilidades práticas e avançadas para enfrentar desafios biomédicos complexos, desde a análise de dados até a simulação de processos biológicos. Também fornecerá uma compreensão abrangente das tecnologias de última geração, como sequenciamento genômico e análise de imagens biomédicas. Além disso, eles terão um amplo conhecimento de questões éticas, legais e regulatórias.




“

A IA na prática clínica promete melhorar a qualidade do atendimento médico, reduzir erros e abrir novas fronteiras para a pesquisa biomédica”



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 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

04

Direção do curso

Para oferecer uma capacitação de qualidade com alto nível educacional, a TECH reúne profissionais de prestígio com ampla experiência em IA na prática clínica. Nesse sentido, o programa é caracterizado por um corpo docente que oferece o plano de estudos mais exclusivo e completo do mercado acadêmico. Assim, eles projetaram cada módulo com o mais alto grau de especificidade, permitindo que os alunos consolidem e desenvolvam suas habilidades ao máximo. Assim, eles terão as garantias necessárias para se especializarem e evoluírem rumo ao sucesso profissional.



“

Uma equipe de professores experientes lhe orientará durante todo o processo de aprendizagem e responderá a todas as suas dúvidas”

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. Fernando Martín-Palomino Sahagún

- ♦ *Chief Technology Officer* e Diretor de P&D da AURA Diagnostics (medTech)
- ♦ Desenvolvimento de negócios na SARLIN
- ♦ Gestor de operações da Alliance Diagnostics
- ♦ Gestor de Inovação da Alliance Medical
- ♦ *Chief Information Officer* na Alliance Medical
- ♦ *Field Engineer & Project Management* em Radiologia Digital na Kodak
- ♦ MBA na Universidade Politécnica de Madrid
- ♦ *Executive Master* em Marketing e Vendas na ESADE
- ♦ Engenheiro Superior de Telecomunicações pela Universidade Alfonso X el Sabio

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

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

05

Estrutura e conteúdo

Esta capacitação acadêmica combina o rigor científico da pesquisa clínica com as inovações revolucionárias da aprendizagem automática. Composto por 20 módulos, este programa abrangerá tudo, desde a interpretação de dados médicos até o desenvolvimento de algoritmos preditivos e a implementação de soluções tecnológicas em ambientes clínicos. O plano de estudos oferecerá conteúdo que combina teoria e prática, estabelecendo os fundamentos da IA e sua aplicação específica na área médica. Assim, os alunos estarão preparados para liderar os avanços na personalização de tratamentos e na otimização da assistência médica.



“

Você se aprofundará na ciência dos dados de saúde, explorando a bioestatística e a análise de big data por meio de 2.250 horas de conteúdo inovador”

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. Perceptrão 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 verosimilhança
 - 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*
 - 5.9.1. 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 básicas 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 *tfdata*
 - 10.6.1. Utilização da API *tfdata* para processamento de dados
 - 10.6.2. Construção de fluxos de dados com *tfdata*
 - 10.6.3. Uso da API *tfdata* 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. Projeto *TensorFlow Datasets*
 - 10.9.1. Utilização do *TensorFlow Datasets* para carregamento de dados
 - 10.9.2. Pré-processamento de dados com o *TensorFlow Datasets*
 - 10.9.3. Uso do *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 aprendizado 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
 - 11.10.2. Detecção de bordas
 - 11.10.3. 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. Aplicação Prática
 - 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. Diagnóstico na prática clínica através de IA

- 16.1. Tecnologias e ferramentas para diagnósticos assistidos por IA
 - 16.1.1. Desenvolvimento de software para diagnóstico assistido por IA em várias especialidades médicas
 - 16.1.2. Uso de algoritmos avançados para análise rápida e precisa de sinais e sintomas 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 dos resultados de exames laboratoriais
- 16.2. Integração de dados clínicos multimodais para diagnóstico
 - 16.2.1. Sistemas de IA para combinar dados de imagens, laboratório e registros clínicos
 - 16.2.2. Ferramentas para correlacionar dados multimodais em diagnósticos mais precisos
 - 16.2.3. Uso de IA para analisar padrões complexos de diferentes tipos de dados clínicos
 - 16.2.4. Integração de dados genômicos e moleculares em diagnósticos assistidos por IA

- 16.3. Criação e análise de *datasets* de saúde com IA
 - 16.3.1. Desenvolvimento de banco de dados clínicos para treinamento de modelos de IA
 - 16.3.2. Uso de IA para analisar e extrair de *insights* de grandes *datasets* de saúde
 - 16.3.3. Ferramentas de IA para limpeza e preparação de dados clínicos
 - 16.3.4. Sistemas de IA para identificar tendências e padrões em dados de saúde
 - 16.4. Visualização e gestão de dados de saúde com IA
 - 16.4.1. Ferramentas de IA para visualização interativa e compreensível de dados de saúde
 - 16.4.2. Sistemas de IA para o manejo eficiente de grandes volumes de dados clínicos
 - 16.4.3. Uso de *dashboards* baseados em IA para monitoramento de indicadores de saúde
 - 16.4.4. Tecnologias de IA para gestão e segurança de dados de saúde
 - 16.5. Reconhecimento de padrões e *Machine Learning* em diagnósticos clínicos
 - 16.5.1. Aplicação de técnicas de *machine learning* para reconhecimento de padrões em dados clínicos
 - 16.5.2. Uso de IA na identificação precoce de doenças por meio da análise de padrões
 - 16.5.3. Desenvolvimento de modelos preditivos para diagnósticos mais precisos
 - 16.5.4. Implementação de algoritmos de aprendizado de máquina na interpretação de dados de saúde
 - 16.6. Interpretação de imagens médicas usando IA
 - 16.6.1. Sistemas de IA para detecção e classificação de anomalias em imagens médicas
 - 16.6.2. Uso da aprendizagem profunda na interpretação de raios X, ressonância magnética e tomografia computadorizada
 - 16.6.3. Ferramentas de IA para melhorar a precisão e a velocidade do diagnóstico por imagem
 - 16.6.4. Implementação da IA para assistência na tomada de decisões clínicas baseadas em imagens
 - 16.7. Processamento de linguagem natural em históricos médicos para diagnóstico clínico
 - 16.7.1. Utilização de PNL para extração de informações relevantes 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 informações de históricos médicos
 - 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
 - 16.8.1. Métodos para 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. Utilização de IA para assegurar confiabilidade e ética no diagnóstico clínico
 - 16.8.4. Implementação de protocolos de avaliação contínua para sistemas de IA na saúde
 - 16.9. IA no diagnóstico de doenças raras
 - 16.9.1. Desenvolvimento de sistemas de IA especializados na identificação de doenças raras
 - 16.9.2. Utilização de IA para analisar padrões atípicos e sintomatologia complexa
 - 16.9.3. Ferramentas de IA para diagnóstico precoce e preciso de doenças pouco frequentes
 - 16.9.4. Implementação de bancos de dados globais com IA para aprimorar 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 em diagnóstico médico
- Módulo 17. Tratamento e controle 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. Utilização 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 medicamentos
 - 17.1.4. Integração de IA no monitoramento e ajuste de tratamentos em tempo real

- 17.2. Definição de indicadores para controle do estado de saúde do paciente
 - 17.2.1. Estabelecimento de parâmetros-chave por meio de IA para monitoramento da saúde do paciente
 - 17.2.2. Uso de IA para identificar indicadores preditivos de saúde e doença
 - 17.2.3. Desenvolvimento de sistemas de alerta precoce baseados em indicadores de saúde
 - 17.2.4. Implementação de IA para avaliação contínua do estado de saúde do paciente
- 17.3. Ferramentas para monitoramento e controle de indicadores de saúde
 - 17.3.1. Desenvolvimento de aplicativos móveis e wearables com IA para monitoramento da saúde
 - 17.3.2. Implementação de sistemas de IA para análise em tempo real de dados de saúde
 - 17.3.3. Uso de *dashboards* baseados em IA para visualização e de indicadores de saúde
 - 17.3.4. Integração de dispositivos IoT no monitoramento contínuo de indicadores de saúde com IA
- 17.4. IA no Planejamento e Execução de Procedimentos Médicos
 - 17.4.1. Utilização 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 aprimorar 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 automático para 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 seleção de terapias eficazes
 - 17.5.3. Desenvolvimento de sistemas de IA para 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
 - 17.6.1. Implementação de sistemas de IA para revisão e atualização dinâmica de tratamentos
 - 17.6.2. Uso de IA na adaptação de protocolos terapêuticos a novas descobertas 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 dos serviços de saúde com tecnologia de IA
 - 17.7.1. Uso de IA para melhorar eficiência e qualidade dos serviços de saúde
 - 17.7.2. Implementação de sistemas de IA para 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 de saúde
 - 17.8.1. Implementação de sistemas de IA para gestão rápida e eficiente de crises sanitárias
 - 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 de saúde
- 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 diferentes 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 de tratamentos
 - 17.10.3. Documentação de experiências inovadoras no uso de IA em diferentes áreas médicas
 - 17.10.4. Discussão sobre avanços e desafios na implementação de IA em tratamentos médicos

Módulo 18. Personalização da saúde por meio da IA

- 18.1. Aplicações de IA em genômica para medicina personalizada
 - 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
 - 18.2.1. Desenvolvimento de modelos de IA para prever 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 gen-drug 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 monitoramento contínuo de indicadores de saúde
 - 18.3.2. Uso de IA na interpretação de dados coletados por dispositivos inteligentes
 - 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 suporte a decisões clínicas com IA
 - 18.4.1. Implementação de IA para auxiliar médicos na tomada de decisões clínicas
 - 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 a necessidades individuais
 - 18.5.4. Exploração de novas tecnologias de IA no campo da saúde personalizada
- 18.6. Avanços na robótica cirúrgica assistida por IA
 - 18.6.1. Desenvolvimento de robôs cirúrgicos com IA para procedimentos precisos e minimamente invasivos
 - 18.6.2. Uso de IA para melhorar a precisão e segurança em cirurgias assistidas por robôs
 - 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 baseados 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 na gestão e no tratamento personalizados da dor
 - 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 a 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
 - 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 personalizadas aos pacientes
 - 18.9.4. Ferramentas de IA que facilitam a participação ativa do paciente em seu tratamento
- 18.10. Integração de IA em registros médicos eletrônicos
 - 18.10.1. Implementação de IA para análise e gestão eficiente de prontuários médicos eletrônicos
 - 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 prontuários médicos
 - 18.10.4. Aplicação de IA para a correlação de dados de prontuários médicos com planos de tratamento

Módulo 19. Análise de *Big Data* no setor de 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 médica de textos em dados
 - 19.2.1. Conceitos de processamento de linguagem natural
 - 19.2.2. Técnicas de *embedding*
 - 19.2.3. Aplicação de processamento de linguagem natural na saúde
- 19.3. Métodos avançados de recuperação de dados em saúde
 - 19.3.1. Exploração de técnicas inovadoras para a recuperação eficiente de dados na saúde
 - 19.3.2. Desenvolvimento de estratégias avançadas para a 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 da qualidade na análise de dados de saúde
 - 19.4.1. Avaliação de qualidade em análise de dados 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 de resultados em projetos de análise de dados de saúde
- 19.5. Mineração de dados e aprendizado de máquina na área da saúde
 - 19.5.1. Principais metodologias para a mineração de dados
 - 19.5.2. Integração de dados de saúde
 - 19.5.3. Detecção de padrões e anomalias em dados de saúde
- 19.6. Áreas inovadoras de *Big Data* e IA 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 em práticas médicas
 - 19.6.3. Desenvolvimento de abordagens inovadoras para aproveitar ao máximo o potencial de *Big Data* e IA no âmbito da saúde

- 19.7. Coleta e pré-processamento de dados médicos
 - 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. Design 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
 - 19.8.1. Visualização de dados e comunicação em saúde
 - 19.8.2. Estratégias criativas de comunicação em saúde
 - 19.8.3. Integração de tecnologias interativas em saúde
- 19.9. Segurança e governança de dados no setor de saúde
 - 19.9.1. Desenvolvimento de estratégias abrangentes 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. Design de políticas e procedimentos que assegurem 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. Aplicações práticas de *Big Data* na 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 dentro do setor de saúde

Módulo 20. Ética e regulamentação em IA médica

- 20.1. Princípios éticos no uso da 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 a 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 em 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 de IA no setor de 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 de tecnologias de IA no âmbito da saúde
 - 20.5.3. Desenvolvimento de modelos de negócios sustentáveis para garantir a continuidade e melhoria de 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 setor de saúde
 - 20.7.1. Análise de implicações econômicas e custo-benefício 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. Projeto centrado no ser 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 efetividade 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 na aprendizagem de máquina médica
 - 20.9.1. Desenvolvimento de modelos de aprendizado automático 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 automático em medicina
- 20.10. Segurança e política na implementação da IA na medicina
 - 20.10.1. Desenvolvimento de políticas de segurança para proteger a integridade e confidencialidade de dados em aplicações de IA médica
 - 20.10.2. Implementação de medidas de segurança no deploy 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 em medicina

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 na Prática 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”*

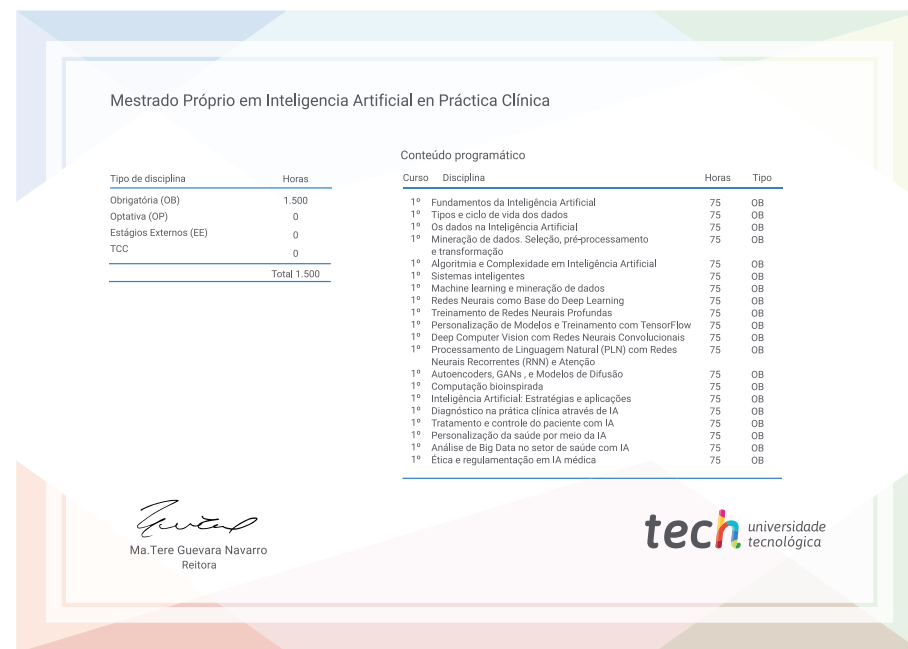
Este **Mestrado Próprio em Inteligência Artificial na Prática Clínica** conta com o conteúdo científico mais completo e atualizado do mercado.

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 emprego, concursos públicos e avaliação de carreira profissional.

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

N.º de Horas Oficiais: **500h**



*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 qualificação
desenvolvimento simulação

tech universidade
tecnológica

Mestrado Próprio Inteligência Artificial na Prática 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 Prática Clínica

