

Mestrado Próprio

Inteligência Artificial em Diagnóstico por Imagem





Mestrado Próprio

Inteligência Artificial em Diagnóstico por Imagem

- » Modalidade: online
- » Duração: 12 meses
- » Certificado: TECH Universidade Tecnológica
- » Horário: no seu próprio ritmo
- » Provas: online

Acesso ao site: www.techtute.com/br/medicina/mestrado-proprio/mestrado-proprio-inteligencia-artificial-dagnostico-imagem

Índice

01

Apresentação

pág. 4

02

Objetivos

pág. 8

03

Competências

pág. 16

04

Direção do curso

pág. 20

05

Estrutura e conteúdo

pág. 24

06

Metodologia de estudo

pág. 44

07

Certificado

pág. 54

01

Apresentação

A Inteligência Artificial (IA) aplicada ao Diagnóstico por Imagem tem revolucionado o campo da medicina nos últimos anos, permitindo uma análise mais precisa e rápida de várias patologias. Na verdade, eles destacam os avanços nos algoritmos de aprendizagem profunda que permitem a detecção precoce de doenças como câncer, doenças cardíacas e doenças neurológicas. Empresas como o Google Health e *startups* especializadas desenvolveram sistemas que melhoram a precisão do diagnóstico em 90% e reduzem o tempo de análise de horas para minutos. Nesse contexto, a TECH desenvolveu um programa totalmente virtual, que pode ser adaptado aos horários individuais e de trabalho dos alunos. Além disso, emprega uma metodologia de aprendizado inovadora conhecida como *Relearning*, pioneira nessa universidade.





“

Com este Mestrado Próprio 100% online, você atualizará sua capacidade de interpretar imagens médicas com maior precisão e velocidade, liderando projetos de inovação em saúde com Inteligência Artificial”

A Inteligência Artificial (IA) está revolucionando o campo de Diagnóstico por Imagem, facilitando diagnósticos mais rápidos e precisos em áreas como radiologia e medicina nuclear. Na verdade, os algoritmos de aprendizagem profunda têm sido cada vez mais integrados às ferramentas de diagnóstico, permitindo a detecção precoce de doenças como o câncer de mama ou a pneumonia.

Assim nasceu este Mestrado Próprio, graças ao qual os médicos se familiarizarão com as principais ferramentas e plataformas, como o IBM Watson Imaging e o DeepMind AI, que estão transformando a interpretação de imagens médicas. Além disso, serão abordados o projeto experimental e a análise dos resultados, com foco na integração de redes neurais e Processamento de Linguagem Natural, facilitando a documentação médica.

Os profissionais também se beneficiarão do treinamento intensivo em aplicativos avançados de IA em estudos clínicos, projetando e validando modelos de IA para a interpretação precisa de imagens médicas. Essa abordagem prática incluirá a integração de dados de várias fontes biomédicas, bem como o uso de tecnologias emergentes, como a Realidade Virtual e Aumentada.

Por fim, ele se aprofundará na personalização e na automação de diagnósticos médicos por meio da IA, explorando como a medicina de precisão está revolucionando a assistência médica. Além disso, a Inteligência Artificial será aplicada ao sequenciamento genômico e à análise de imagens do microbioma, além de gerenciar dados complexos em estudos clínicos. Essa abordagem abrangente melhorará a precisão do diagnóstico e abordará as questões éticas e legais associadas ao uso da IA na medicina.

Dessa forma, a TECH criou um programa universitário detalhado e totalmente online, que facilita o acesso dos alunos aos materiais educacionais por meio de qualquer dispositivo eletrônico com conexão à Internet. Isso elimina a necessidade de deslocamento para um local físico e de adaptação a um cronograma específico. Além disso, integra a revolucionária metodologia *Relearning*, que se baseia na repetição de conceitos essenciais para melhorar a compreensão do conteúdo.

Este **Mestrado Próprio em Inteligência Artificial em Diagnóstico por Imagem** 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 aplicada ao Diagnóstico por Imagem.
- O conteúdo gráfico, esquemático e eminentemente prático oferece informações científicas e práticas sobre as disciplinas que são essenciais para a prática profissional
- Contém exercícios práticos em que o processo de autoavaliação é realizado para melhorar o aprendizado
- Destaque especial para as metodologias inovadoras
- Aulas 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, seja fixo ou móvel, com conexão à Internet



Você obterá uma compreensão aprofundada do gerenciamento de Big Data, da automação de diagnósticos e dos aspectos éticos e legais do uso da IA, graças a uma extensa biblioteca de recursos multimídia inovadores”

“

Você investigará a precisão do diagnóstico e os benefícios clínicos derivados do uso de IA, com foco no projeto de experimentos e na análise de resultados usando recursos como o Google Cloud Healthcare API”

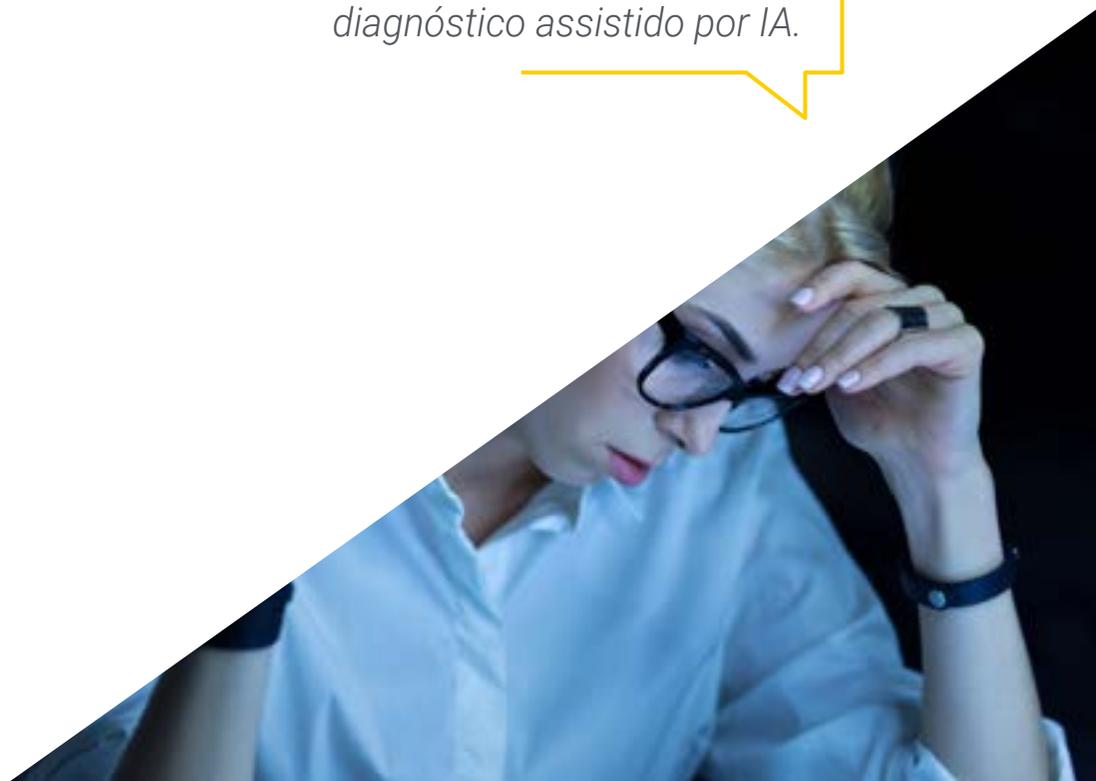
A equipe de professores deste programa inclui profissionais desta área, cuja experiência é somada a esta capacitação, além de reconhecidos especialistas de conceituadas sociedades científicas e universidades de prestígio.

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.

Você abordará as inovações em Realidade Virtual e Aumentada, que estão transformando a maneira como os médicos visualizam e analisam os dados clínicos, melhorando a tomada de decisões. O que você está esperando para se matricular?

Você se aprofundará nas aplicações da IA na correlação entre o sequenciamento genômico, a automação do processamento de imagens e a implementação de técnicas avançadas no diagnóstico assistido por IA.



02 Objetivos

O principal objetivo do programa universitário será treinar médicos no uso de tecnologias de Inteligência Artificial para melhorar a precisão e a eficiência na interpretação de imagens médicas. Assim, os profissionais adquirirão conhecimentos avançados em ferramentas e algoritmos de IA, aplicando-os de forma prática em sua prática clínica para otimizar diagnósticos e tratamentos. Além disso, eles poderão integrar a IA à medicina personalizada, desenvolver novas abordagens de diagnóstico e enfrentar os desafios éticos e legais associados à Inteligência Artificial na área da saúde.



“

Escolha a TECH! Você integrará dados complexos para personalizar tratamentos e obterá uma compreensão profunda das questões éticas e legais relacionadas à Inteligência Artificial na Medicina”



Objetivos gerais

- Compreender os fundamentos teóricos da Inteligência Artificial
- Estudar os diferentes tipos de dados e entender o ciclo de vida dos dados
- Avaliar o papel crucial dos dados no desenvolvimento e na implementação de soluções de Inteligência Artificial
- Aprofundar conhecimentos sobre os algoritmos e a complexidade para resolver problemas específicos
- Explorar a base teórica das redes neurais para o desenvolvimento do *Deep Learning*
- Explorar a computação bioinspirada e sua relevância para o desenvolvimento de sistemas inteligentes
- Desenvolver habilidades para usar e aplicar ferramentas avançadas de Inteligência Artificial na interpretação e análise de imagens médicas, melhorando a precisão do diagnóstico
- Implementar soluções de Inteligência Artificial que permitam a automação de processos e a personalização de diagnósticos
- Aplicar técnicas de mineração de dados e análise preditiva para tomar decisões clínicas baseadas em evidências
- Adquirir habilidades de pesquisa que permitirão que os especialistas contribuam para o avanço da Inteligência Artificial em imagens médicas



Aproveite para se atualizar sobre os mais recentes desenvolvimentos em Doenças Infecciosas Clínicas e Antibioticoterapia Avançada”





Objetivos específicos

Módulo 1. Fundamentos da Inteligência Artificial

- ♦ Analisar a evolução histórica da Inteligência Artificial, desde seus primórdios até o 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

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 as principais etapas
- ♦ 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 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

Módulo 3. Dados em 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.
- ♦ Usar ferramentas específicas e práticas recomendadas no manuseio 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 entender e aplicar métodos estatísticos na mineração de dados
- ♦ Realizar análises exploratórias detalhadas 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 de acordo com 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 *Big Data*

Módulo 5. Algoritmo 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, compreender sua estrutura e aplicações
- ♦ Investigar algoritmos com *Heaps*, analisar 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
- ♦ Pesquisar e aplicar a técnica de *backtracking* para a solução sistemática de problemas, analisando sua eficácia em uma variedade de ambientes

Módulo 6. Sistemas inteligentes

- ♦ Explorar a teoria dos agentes, compreendendo os conceitos fundamentais de como eles funcionam 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 sobre a organização e a recuperação de informações em ambientes digitais
- ♦ Avaliar e comparar diferentes representações do conhecimento, integrando estas para melhorar a eficácia e precisão dos sistemas inteligentes

Módulo 7. Machine learning e mineração de dados

- ♦ Apresentar os processos de descoberta de conhecimento e os conceitos fundamentais de aprendizado de máquina
- ♦ Estudar árvores de decisão como modelos de aprendizagem supervisionada, compreendendo sua estrutura e aplicações
- ♦ Avaliar classificadores usando técnicas específicas para medir seu desempenho e precisão na classificação de dados
- ♦ Estudar redes neurais, compreendendo sua operação e arquitetura para resolver problemas complexos de aprendizado de máquina
- ♦ Explorar os métodos bayesianos e sua aplicação no aprendizado de máquina, incluindo redes bayesianas e classificadores bayesianos
- ♦ Analisar modelos de regressão e de resposta contínua para prever valores numéricos a partir de dados
- ♦ Estudar técnicas de *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 as técnicas de aprendizado de máquina são aplicadas para analisar e compreender o texto

Módulo 8. Redes neurais com base no *Deep Learning*

- ♦ Dominar os fundamentos do Aprendizado Profundo, compreendendo seu papel essencial no *Deep Learning*
- ♦ Analisar as operações fundamentais das redes neurais e entender sua aplicação na criação de modelos
- ♦ Analisar as diferentes camadas usadas em redes neurais e aprender a selecioná-las adequadamente

- ♦ Compreender a união eficaz 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

Módulo 9. Treinamento de Redes Neurais Profundas

- ♦ Resolver problemas relacionados ao gradiente 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 o 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 aplicativos práticos usando *Transfer Learning* para resolver problemas do mundo real

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

- ♦ Dominar os fundamentos de *TensorFlow* e sua integração com o NumPy para o manuseio eficiente de dados e cálculos
- ♦ Personalizar modelos e algoritmos de treinamento usando os recursos avançados do *TensorFlow*
- ♦ Explorar a API *tfdataset* para gerenciar e manipular conjuntos de dados com eficiência
- ♦ Implementar o formato *TFRecord* para armazenar e acessar grandes conjuntos de dados em *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 forma prática todos os conceitos aprendidos na construção e treinamento de modelos personalizados usando *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 os principais recursos das 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 Keras pré-treinados para aproveitar a aprendizagem por transferência para tarefas específicas
- ♦ Aplicar técnicas de classificação e rastreamento em um ambiente de *Deep Computer Vision*
- ♦ Explorar estratégias de detecção e rastreamento de objetos usando Redes Neurais Convolucionais

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 NPL
- ♦ 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 a tarefas específicas
- ♦ Desenvolver um aplicativo prático 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 a operação de codificadores automáticos empilhados
- ♦ Explorar e aplicar autoencoders convolucionais para representações eficientes de dados visuais
- ♦ Analisar e aplicar a eficácia de codificadores automáticos esparsos na representação de dados
- ♦ Gerar imagens de moda a partir do conjunto de dados MNIST usando *Autoencoders*
- ♦ Compreender o conceito de Redes Adversárias Generativas (GANs) e modelos de difusão
- ♦ Implementar e avaliar o desempenho dos modelos de difusão e GANs na geração de dados

Módulo 14. Computação bioinspirada

- ♦ Apresentar os conceitos fundamentais da computação bioinspirada
- ♦ Analisar estratégias de exploração de espaço em algoritmos genéticos
- ♦ Examinar modelos de computação evolutiva no contexto da otimização
- ♦ Continuar a análise detalhada dos modelos de computação evolutiva
- ♦ Aplicar a programação evolutiva a problemas específicos de aprendizagem
- ♦ Abordar a complexidade de problemas com vários objetivos na estrutura da computação bioinspirada
- ♦ Explorar a aplicação de redes neurais no campo da computação bioinspirada
- ♦ Aprofundar a implementação e a utilidade das redes neurais na computação bioinspirada

Módulo 15. Inteligência Artificial: estratégias e aplicativos

- ♦ Desenvolver estratégias para a implementação de inteligência artificial em serviços financeiros
- ♦ Identificar e avaliar os riscos associados ao uso da IA no campo da saúde
- ♦ Avaliar os possíveis riscos associados ao uso da IA no setor
- ♦ Aplicar técnicas de inteligência artificial no setor para melhorar a produtividade
- ♦ Definir 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. Inovação Inteligência Artificial em Diagnóstico por Imagem

- ♦ Domine ferramentas como o IBM Watson Imaging e o NVIDIA Clara para interpretar automaticamente exames clínicos
- ♦ Obter competências para conduzir experimentos clínicos e análise de resultados usando Inteligência Artificial, com foco na melhoria da precisão do diagnóstico

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

- ♦ Realizar estudos observacionais em imagens usando Inteligência Artificial, validando e calibrando modelos de forma eficiente
- ♦ Integrar dados de imagens médicas com outras fontes biomédicas, usando ferramentas como o Enlitic Curie para conduzir pesquisas multidisciplinares

Módulo 18. Personalização e automação em diagnósticos médicos usando inteligência artificial

- ♦ Adquirir habilidades para personalizar diagnósticos usando Inteligência Artificial, correlacionando achados de imagem com dados genômicos e outros biomarcadores
- ♦ Dominar a automação da aquisição e do processamento de imagens médicas, aplicando tecnologias avançadas de Inteligência Artificial

Módulo 19. Big Data e Análise Preditiva em Imagens Médicas

- ♦ Gerenciar grandes volumes de dados usando técnicas de mineração de dados e algoritmos de aprendizado de máquina
- ♦ Criar ferramentas de prognóstico clínico com base na análise de *Big Data* a fim de otimizar as decisões clínicas

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

- ♦ Ter uma compreensão holística dos princípios normativos e deontológicos que regem o uso da inteligência no campo da assistência à saúde, incluindo aspectos como consentimento informado
- ♦ Ser capaz de auditar modelos de Inteligência Artificial usados na prática clínica, garantindo sua transparência e responsabilidade na tomada de decisões médicas

03

Competências

Essa qualificação acadêmica equipará os médicos com competências avançadas para integrar efetivamente a Inteligência Artificial em sua prática clínica diária. Os alunos adquirirão habilidades no uso de plataformas de IA para a interpretação de imagens médicas, a implementação de algoritmos de aprendizagem profunda e a análise preditiva de dados clínicos. Além disso, desenvolverão a capacidade de projetar e executar estudos de pesquisa usando IA, integrando várias fontes de dados biomédicos para melhorar a precisão do diagnóstico e a personalização dos tratamentos.





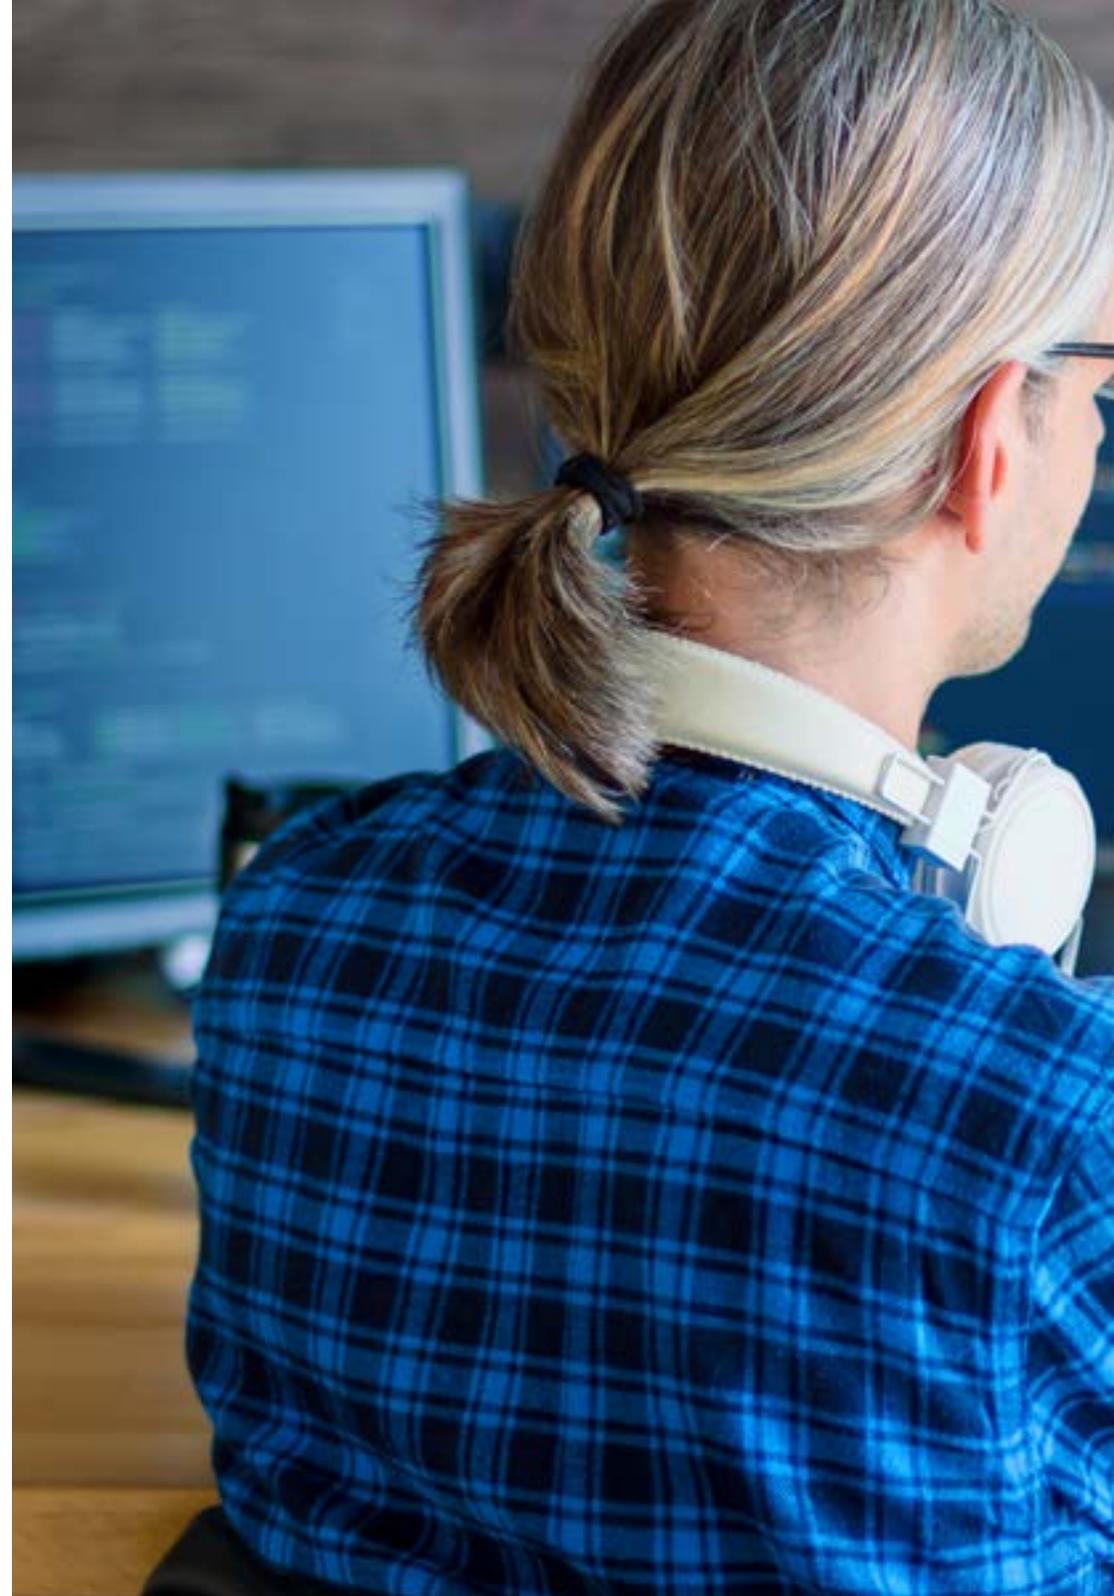
“

Você abordará os desafios éticos e legais associados à aplicação dessas tecnologias no ambiente de saúde, garantindo uma prática clínica segura, eficaz e equitativa”



Competências gerais

- ♦ Aplicar com eficácia as técnicas fundamentais de Inteligência Artificial (*Big Data*, Aprendizagem Profunda, Redes Neurais, etc.) para otimizar a análise de imagens de diagnóstico
- ♦ Interpretar criticamente os resultados gerados pelos sistemas de Inteligência Artificial, garantindo a validade e a relevância clínica das previsões ou classificações
- ♦ Manipular linguagens de programação específicas para Inteligência Artificial, como Python para garantir a qualidade dos dados obtidos
- ♦ Desenvolver habilidades avançadas para identificar oportunidades de melhoria em Diagnóstico por Imagem e projetar novas soluções tecnológicas
- ♦ Personalizar modelos de Inteligência Artificial para o diagnóstico de patologias específicas, como tumores, levando em conta as variações individuais e as características da população
- ♦ Comunicar de forma clara e precisa os resultados das análises clínicas para uma variedade de públicos





Competências específicas

- Treinar redes neurais profundas para classificação, segmentação e detecção de padrões em imagens radiológicas
- Aplicar métodos avançados de processamento de imagens, como filtragem, normalização e aprimoramento de contraste
- Gerenciar software médico que incorpora algoritmos de Inteligência Artificial para a análise automatizada de exames clínicos, garantindo sua usabilidade e conformidade com as normas de saúde
- Conduzir estudos de validação clínica para garantir que as ferramentas de Inteligência Artificial sejam eficazes e tenham aplicabilidade real em ambientes clínicos

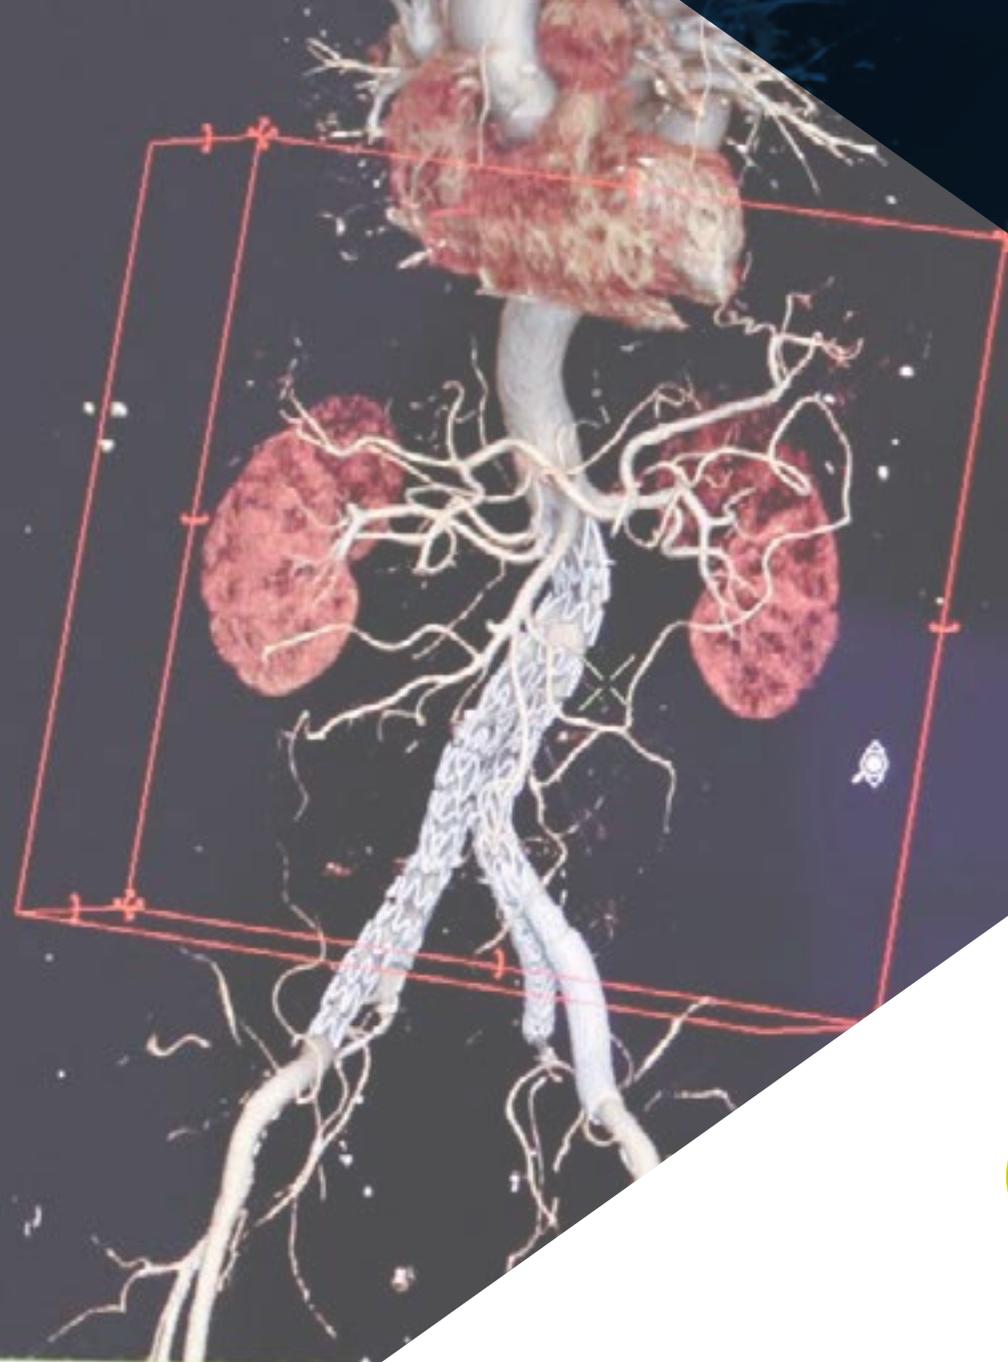


Você se manterá atualizado para liderar projetos de inovação em suas instituições, integrar ferramentas de IA em sua prática diária e participar de pesquisas aplicadas. Com todas as garantias de qualidade da TECH!"

04

Direção do curso

O corpo docente é composto por especialistas internacionais nas áreas de Radiologia e Inteligência Artificial. Na verdade, eles combinam uma sólida formação acadêmica com ampla experiência clínica e de pesquisa, o que lhes permitirá oferecer aos graduados um treinamento prático e atualizado sobre as mais recentes inovações em IA aplicadas ao diagnóstico por imagem. Além disso, eles não apenas fornecerão conhecimento teórico, mas também compartilharão casos clínicos reais e projetos de pesquisa pioneiros, proporcionando uma perspectiva holística que conecta a teoria com a prática diária no ambiente clínico.



do de la aplicación: 2DViewer

“

Os palestrantes fornecerão a você uma compreensão teórica avançada, bem como uma perspectiva prática e aplicada sobre como a IA pode transformar o diagnóstico por imagem e melhorar os resultados na área da saúde”

Direção



Dr. Arturo Peralta Martín-Palomino

- ♦ CEO e CTO em Prometheus Global Solutions
- ♦ CTO em Korporate Technologies
- ♦ CTO em AI Shephers GmbH
- ♦ Consultor e Assessor Estratégico de Negócios da Alliance Medical
- ♦ Diretor de Design e Desenvolvimento da DocPath
- ♦ Doutorado em Engenharia da Computação pela Universidade de Castilla - La Mancha
- ♦ Doutorado em Economia, Negócios e Finanças pela Universidade Camilo José Cela
- ♦ Doutorado em Psicologia pela Universidade de Castilla - La Mancha
- ♦ Mestrado em Executive MBA pela Universidade Isabel I
- ♦ Mestrado em Gestão Comercial e de Marketing pela Universidade Isabel I
- ♦ Mestrado Especialista em Big Data por Formação Hadoop
- ♦ Mestrado em Tecnologia da Informação Avançada pela Universidade de Castilla-La Mancha
- ♦ Membro: Grupo de pesquisa SMILE



Professores

Sr. Daniel Vasile Popescu Radu

- ◆ Especialista independente em Farmacologia, Nutrição e Dietética
- ◆ 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

“

Aproveite a oportunidade para conhecer os últimos avanços nesta área e aplicá-los em sua prática diária”

05

Estrutura e conteúdo

O programa abrangerá tudo, desde as tecnologias mais inovadoras em análise de imagens e plataformas de IA até a aplicação prática de algoritmos de aprendizagem profunda em estudos clínicos complexos. Além disso, o conteúdo incluirá a integração de dados biomédicos com imagens médicas, a personalização e a automação do diagnóstico, bem como o manuseio de grandes volumes de dados por meio de *Big Data* e técnicas de análise preditiva. Também serão abordadas questões éticas e legais essenciais para garantir a implementação segura e eficaz dessas tecnologias na prática clínica.



“

Este Mestrado Próprio em Inteligência Artificial em Diagnóstico por Imagem oferecerá um conteúdo abrangente, projetado para equipá-lo com habilidades avançadas no uso de IA em imagens médicas”

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. Criar 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: descritivas e inferências
 - 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. Qualitativo: 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. Dados em 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. Algoritmo 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 primeira ordem

- 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 C
 - 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. Aprendizagem profunda
 - 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. API *tf.data*
 - 10.6.1. Utilização da API *tf.data* para processamento de dados
 - 10.6.2. Construção de fluxos de dados com *tf.data*
 - 10.6.3. Uso da API *tf.data* 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 *pipelined* 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 de *TensorFlow Datasets* para upload de dados
 - 10.9.2. Pré-processamento de dados com o *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. Aplicação Prática
 - 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 Visão 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 D
 - 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. 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 aplicativos

- 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 na área 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 ao uso de IA na área 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. Implicações 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. Implicações 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. Participação da IA nos 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. Inovação em Inteligência Artificial em Diagnóstico por Imagem

- 16.1. Tecnologias e ferramentas de Inteligência Artificial para Diagnóstico por Imagem com o IBM Watson Imaging Clinical Review
 - 16.1.1. Plataformas de software líderes para análise de imagens médicas
 - 16.1.2. Ferramentas de aprendizagem profunda específicas para radiologia
 - 16.1.3. Inovações de hardware para acelerar o processamento de imagens
 - 16.1.4. Integração de sistemas de Inteligência Artificial nas infraestruturas hospitalares existentes
- 16.2. Métodos estatísticos e algoritmos para interpretação de imagens médicas com DeepMind AI para análise de câncer de mama
 - 16.2.1. Algoritmos de segmentação de imagens
 - 16.2.2. Técnicas de classificação e detecção em imagens médicas
 - 16.2.3. Uso de redes neurais convolucionais em radiologia
 - 16.2.4. Métodos de redução de ruído e melhoria da qualidade da imagem
- 16.3. Projetando experimentos e analisando resultados em diagnóstico por imagem com a API de saúde do Google Cloud
 - 16.3.1. Projeto de protocolos de validação para algoritmos de Inteligência Artificial.
 - 16.3.2. Métodos estatísticos para comparar o desempenho da Inteligência Artificial e dos radiologistas
 - 16.3.3. Estabelecimento de estudos multicêntricos para testes de Inteligência Artificial
 - 16.3.4. Interpretação e apresentação de resultados de estudos de eficácia
- 16.4. Detecção de padrões sutis em imagens de baixa resolução
 - 16.4.1. Inteligência artificial para o diagnóstico precoce de doenças neurodegenerativas
 - 16.4.2. Aplicações de Inteligência Artificial em Cardiologia Intervencionista
 - 16.4.3. Uso de Inteligência Artificial para a otimização de protocolos de imagem
- 16.5. Análise e processamento de imagens biomédicas
 - 16.5.1. Técnicas de pré-processamento para aprimorar a interpretação automática
 - 16.5.2. Análise de textura e padrão em imagens histológicas
 - 16.5.3. Extração de características clínicas de imagens de ultrassom
 - 16.5.4. Métodos para análise de imagens longitudinais em estudos clínicos
- 16.6. Visualização avançada de dados em diagnóstico por imagem com o OsiriX MD
 - 16.6.1. Desenvolvimento de interfaces gráficas para exploração de imagens 3D
 - 16.6.2. Ferramentas para visualização de alterações temporais em imagens médicas
 - 16.6.3. Técnicas de realidade aumentada para o ensino de anatomia
 - 16.6.4. Sistemas de visualização em tempo real para procedimentos cirúrgicos
- 16.7. Processamento de linguagem natural em documentação e relatórios de imagens médicas com o Nuance PowerScribe 360
 - 16.7.1. Geração automática de laudos radiológicos
 - 16.7.2. Extração de informações relevantes de registros médicos eletrônicos
 - 16.7.3. Análise semântica para correlacionar achados clínicos e de imagem
 - 16.7.4. Ferramentas de busca e recuperação de imagens baseadas em descrições textuais
- 16.8. Integração e processamento de dados heterogêneos em imagens médicas
 - 16.8.1. Fusões de modalidades de imagem para diagnósticos abrangentes
 - 16.8.2. Integração de dados laboratoriais e genéticos na análise de imagens
 - 16.8.3. Sistemas para lidar com grandes volumes de dados de imagem
 - 16.8.4. Estratégias para a normalização de *datasets* de várias fontes
- 16.9. Aplicações de redes neurais na interpretação de imagens médicas com a Zebra Medical Vision
 - 16.9.1. Uso de redes generativas para geração de imagens médicas sintéticas
 - 16.9.2. Redes neurais para classificação automática de tumores
 - 16.9.3. *Deep Learning* para análise de séries temporais em imagens funcionais
 - 16.9.4. Ajuste de modelos pré-treinados em conjuntos de dados específicos de imagens médicas

- 16.10. Modelagem preditiva e seu impacto no diagnóstico por imagem com a IBM Watson Oncologia
 - 16.10.1. Modelos preditivos para avaliação de risco em pacientes com câncer
 - 16.10.2. Ferramentas preditivas para monitoramento de doenças crônicas
 - 16.10.3. Análise de sobrevivência usando dados de imagens médicas
 - 16.10.4. Previsão da progressão da doença por meio de *Machine Learning*

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

- 17.1. Projeto e execução de estudos observacionais usando Inteligência Artificial em imagens médicas com a Flatiron Health
 - 17.1.1. Critérios para a seleção de populações em estudos observacionais de Inteligência Artificial
 - 17.1.2. Métodos de controle de variáveis de confusão em estudos de imagem
 - 17.1.3. Estratégias para acompanhamento de longo prazo em estudos observacionais
 - 17.1.4. Análise de resultados e validação de modelos de Inteligência Artificial em contextos clínicos reais
- 17.2. Validação e calibração de modelos de IA na interpretação de imagens com o Arterys Cardio AI
 - 17.2.1. Técnicas de validação cruzada aplicadas a modelos de diagnóstico por imagem
 - 17.2.2. Métodos para calibração de probabilidade em previsões de Inteligência Artificial
 - 17.2.3. Padrões de desempenho e métricas de precisão para avaliação de IA
 - 17.2.4. Implementação de testes de robustez em diferentes populações e condições
- 17.3. Métodos de integração de dados de imagens com outras fontes biomédicas
 - 17.3.1. Técnicas de fusão de dados para melhorar a interpretação de imagens
 - 17.3.2. Análise conjunta de imagens e dados genômicos para diagnósticos precisos
 - 17.3.3. Integração de informações clínicas e laboratoriais em Inteligência Artificial
 - 17.3.4. Desenvolvimento de interfaces de usuário para visualização integrada de dados multidisciplinares
- 17.4. Uso de dados de imagens médicas em pesquisas multidisciplinares com Enlitic Curie
 - 17.4.1. Colaboração interdisciplinar para análise avançada de imagens
 - 17.4.2. Aplicação de técnicas de inteligência artificial de outros campos no diagnóstico por imagem
- 17.4.3. Desafios e soluções no gerenciamento de dados grandes e heterogêneos
- 17.4.4. Estudos de caso de aplicações multidisciplinares bem-sucedidas
- 17.5. Algoritmos de aprendizagem profunda específicos para imagens médicas com AIDOC
 - 17.5.1. Desenvolvimento de arquiteturas de redes neurais para imagens específicas
 - 17.5.2. Otimização de hiperparâmetros para modelos de imagens médicas
 - 17.5.3. Transferência de aprendizado e sua aplicabilidade em radiologia
- 17.6. Desafios na interpretação e visualização de recursos aprendidos por modelos profundos
 - 17.6.1. Otimização da interpretação de imagens médicas por meio da automação com o Viz.ai
 - 17.6.2. Automação de rotinas de diagnóstico para eficiência operacional
 - 17.6.3. Sistemas de alerta antecipado na detecção de anomalias
 - 17.6.4. Reduzindo a carga de trabalho dos radiologistas usando ferramentas de Inteligência Artificial
 - 17.6.5. O impacto da automação na precisão e na velocidade dos diagnósticos
- 17.7. Simulação e modelagem computacional em diagnóstico por imagem
 - 17.7.1. Simulações para treinamento e validação de algoritmos de Inteligência Artificial
 - 17.7.2. Modelagem de doenças e sua representação em imagens sintéticas
 - 17.7.3. Uso de simulações para tratamento e planejamento cirúrgico
 - 17.7.4. Avanços em técnicas computacionais para processamento de imagens em tempo real
- 17.8. Realidade virtual e aumentada na visualização e análise de imagens médicas
 - 17.8.1. Aplicativos de realidade virtual para educação em diagnóstico por imagem
 - 17.8.2. Uso de Realidade Aumentada em procedimentos cirúrgicos guiados por imagem
 - 17.8.3. Ferramentas avançadas de visualização para planejamento terapêutico
 - 17.8.4. Desenvolvimento de interfaces imersivas para a revisão de estudos radiológicos
- 17.9. Ferramentas de mineração de dados aplicadas ao diagnóstico por imagem com Radiômica
 - 17.9.1. Técnicas para extrair dados de grandes repositórios de imagens médicas
 - 17.9.2. Aplicativos de análise de padrões em coleções de dados de imagens

- 17.9.3. Identificação de biomarcadores por meio de mineração de dados de imagens
- 17.9.4. Integração de mineração de dados e aprendizado de máquina para descoberta clínica
- 17.10. Desenvolvimento e validação de biomarcadores usando análise de imagem com a Oncimmune
 - 17.10.1. Estratégias para identificar biomarcadores de imagem em uma variedade de doenças
 - 17.10.2. Validação clínica de biomarcadores de imagem para uso diagnóstico
 - 17.10.3. O impacto dos biomarcadores de imagem na personalização dos tratamentos
 - 17.10.4. Tecnologias emergentes na detecção e análise de biomarcadores usando Inteligência Artificial

Módulo 18. Personalização e automação em diagnósticos médicos usando inteligência artificial

- 18.1. Aplicação de Inteligência Artificial no sequenciamento genômico e correlação com achados de imagem com a Fabric Genomics
 - 18.1.1. Técnicas de Inteligência Artificial para a integração de dados genômicos e de imagem
 - 18.1.2. Modelos preditivos para correlacionar variantes genéticas com patologias visíveis por imagem
 - 18.1.3. Desenvolvimento de algoritmos para a análise automática de sequências e sua representação em imagens
 - 18.1.4. Estudos de caso sobre o impacto clínico da fusão genômica e de imagens
- 18.2. Avanços em Inteligência Artificial para análise detalhada de imagens biomédicas com PathAI
 - 18.2.1. Inovações em técnicas de processamento e análise de imagens em nível celular
 - 18.2.2. Aplicação de Inteligência Artificial para aprimoramento da resolução em imagens de microscopia
 - 18.2.3. Algoritmos de *Deep Learning* especializados na detecção de padrões submicroscópicos
 - 18.2.4. Impacto dos avanços da Inteligência Artificial na pesquisa biomédica e nos diagnósticos clínicos
- 18.3. Automação na aquisição e processamento de imagens médicas com a Butterfly Network
 - 18.3.1. Sistemas automatizados para otimização dos parâmetros de imagem
 - 18.3.2. Inteligência Artificial no gerenciamento e manutenção de equipamentos de imagem
 - 18.3.3. Algoritmos para processamento de imagens em tempo real durante procedimentos médicos
 - 18.3.4. Histórias de sucesso na implementação de sistemas automatizados em hospitais e clínicas
- 18.4. Personalização de diagnósticos por meio de IA e medicina de precisão com a Tempus AI
 - 18.4.1. Modelos de inteligência artificial para diagnósticos personalizados baseados em perfis genéticos e de imagem
 - 18.4.2. Estratégias para a integração de dados clínicos e de imagem no planejamento terapêutico
 - 18.4.3. O impacto da medicina de precisão nos resultados clínicos por meio da IA
 - 18.4.4. Desafios éticos e práticos na implementação da medicina personalizada
- 18.5. Inovações em diagnósticos assistidos por IA com a Caption Health
 - 18.5.1. Desenvolvimento de novas ferramentas de Inteligência Artificial para a detecção precoce de doenças
 - 18.5.2. Avanços em algoritmos de Inteligência Artificial para a interpretação de patologias complexas
 - 18.5.3. Integração de diagnósticos assistidos por IA na prática clínica de rotina
 - 18.5.4. Avaliação da eficácia e aceitação da Inteligência Artificial diagnóstica pelos profissionais de saúde
- 18.6. Aplicativos de Inteligência Artificial na análise de imagens do microbioma com DayTwo AI
 - 18.6.1. Técnicas de Inteligência Artificial para análise de imagens em estudos de microbioma
 - 18.6.2. Correlação de dados de imagem do microbioma com indicadores de saúde
 - 18.6.3. Impacto dos achados do microbioma nas decisões terapêuticas
 - 18.6.4. Desafios na padronização e validação de imagens de microbioma

- 18.7. Uso de *wearables* para melhorar a interpretação das imagens de diagnóstico com o AliveCor
 - 18.7.1. Integração de dados *wearables* com imagens médicas para diagnósticos abrangentes
 - 18.7.2. Algoritmos de IA para análise e representação de dados contínuos em imagens
 - 18.7.3. Inovações tecnológicas em *wearables* para monitoramento da saúde
 - 18.7.4. Estudos de caso sobre a melhoria da qualidade de vida por meio de *wearables* y diagnósticos por imagem
- 18.8. Gerenciamento de dados de diagnóstico por imagem em estudos clínicos por meio de Inteligência artificial
 - 18.8.1. Ferramentas de IA para o gerenciamento eficiente de grandes volumes de dados de imagens
 - 18.8.2. Estratégias para garantir a qualidade e a integridade dos dados em estudos multicêntricos
 - 18.8.3. Aplicativos de Inteligência Artificial para análise preditiva em estudos clínicos
 - 18.8.4. Desafios e oportunidades na padronização de protocolos de imagem em estudos globais
- 18.9. Desenvolvimento de tratamentos e vacinas auxiliados por diagnósticos avançados de Inteligência Artificial
 - 18.9.1. Uso de Inteligência Artificial para projetar tratamentos personalizados com base em imagens e dados clínicos
 - 18.9.2. Modelos de inteligência artificial no desenvolvimento acelerado de vacinas com apoio de diagnóstico por imagem
 - 18.9.3. Avaliação da eficácia dos tratamentos por meio do monitoramento de imagens
 - 18.9.4. Impacto da Inteligência Artificial na redução de tempo e custos no desenvolvimento de novas terapias
- 18.10. Aplicativos de IA em estudos de imunologia e resposta imune com ImmunoMind
 - 18.10.1. Modelos de IA para a interpretação de imagens relacionadas à resposta imune
 - 18.10.2. Integração de dados de imagem e análise imunológica para diagnósticos precisos
 - 18.10.3. Desenvolvimento de biomarcadores de imagem para doenças autoimunes
 - 18.10.4. Avanços na personalização de tratamentos imunológicos por meio do uso da Inteligência Artificial

Módulo 19. *Big Data* e Análise Preditiva em Imagens Médicas

- 19.1. *Big Data* em Diagnóstico por Imagem: Conceitos e Ferramentas com a GE Healthcare Edison
 - 19.1.1. Fundamentos de *Big Data* aplicado à geração de imagens
 - 19.1.2. Ferramentas e plataformas tecnológicas para lidar com grandes volumes de dados de imagem
 - 19.1.3. Desafios na integração e análise de *Big Data* em Imagens
 - 19.1.4. Casos de uso de *Big Data* no diagnóstico por imagem
- 19.2. Mineração de dados de registros de imagens biomédicas com o IBM Watson Imaging
 - 19.2.1. Técnicas avançadas de mineração de dados para identificar padrões em imagens médicas
 - 19.2.2. Estratégias para extrair recursos relevantes de grandes bancos de dados de imagens
 - 19.2.3. Aplicações de técnicas de *clustering* e classificação em registros de imagens
 - 19.2.4. Impacto da mineração de dados no aprimoramento de diagnósticos e tratamentos
- 19.3. Algoritmos de aprendizado de máquina em análise de imagens com o Google DeepMind Health
 - 19.3.1. Desenvolvimento de algoritmos supervisionados e não supervisionados para imagens médicas
 - 19.3.2. Inovações em técnicas de aprendizado de máquina para reconhecimento de padrões de doenças
 - 19.3.3. Aplicativos de aprendizagem profunda na segmentação e classificação de imagens
 - 19.3.4. Avaliação da eficácia e da precisão dos algoritmos de aprendizado de máquina em estudos clínicos
- 19.4. Técnicas analíticas preditivas aplicadas ao diagnóstico por imagem com a Predictive Oncology
 - 19.4.1. Modelos preditivos para a identificação precoce de doenças a partir de imagens
 - 19.4.2. Uso da análise preditiva para monitoramento e avaliação do tratamento
 - 19.4.3. Integração de dados clínicos e de imagem para enriquecer os modelos preditivos
 - 19.4.4. Desafios na implementação de técnicas preditivas na prática clínica

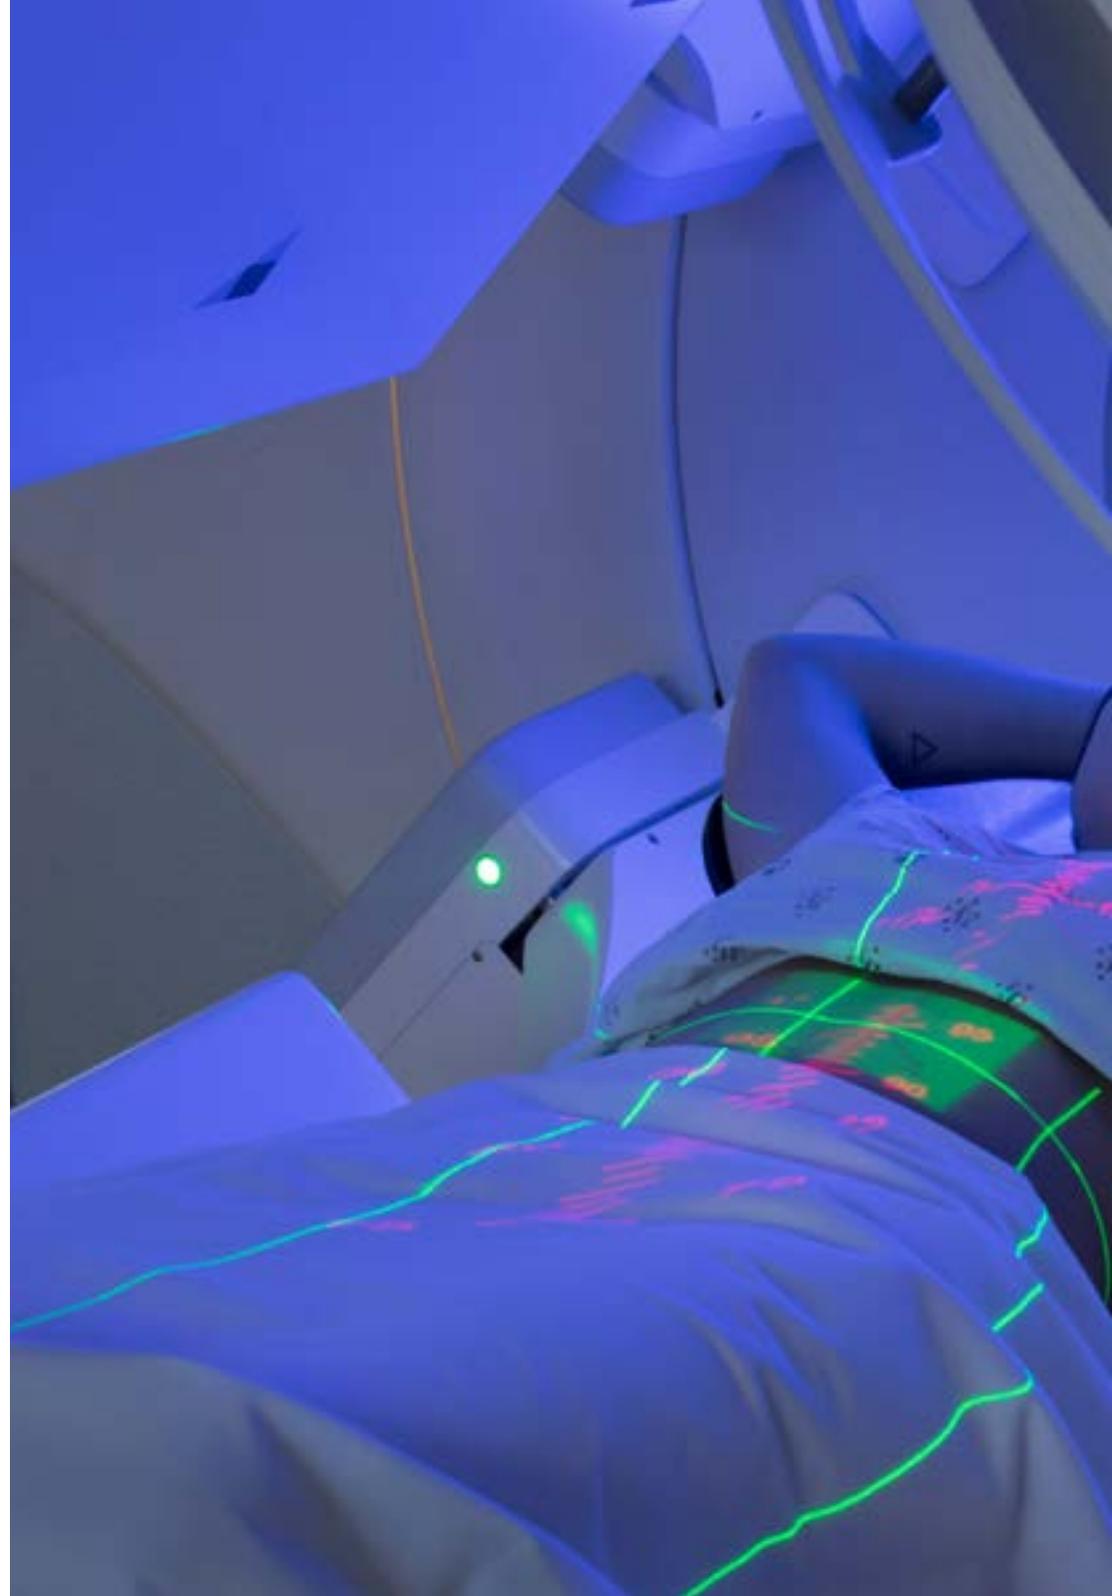
- 19.5. Modelos de Inteligência Artificial baseados em imagens para Epidemiologia com BlueDot
 - 19.5.1. Aplicação de Inteligência Artificial na análise de surtos epidêmicos usando imagens
 - 19.5.2. Modelos de propagação de doenças visualizados por técnicas de imagem
 - 19.5.3. Correlação entre dados epidemiológicos e achados de imagem
 - 19.5.4. Contribuição da Inteligência Artificial para o estudo e o controle de pandemias
- 19.6. Análise de redes biológicas e padrões de doenças a partir de imagens
 - 19.6.1. Aplicação da teoria de rede na análise de imagens para entender as patologias
 - 19.6.2. Modelos computacionais para simular redes biológicas visíveis em imagens
 - 19.6.3. Integração de análise de imagens e dados moleculares para mapear doenças
 - 19.6.4. Impacto dessas análises no desenvolvimento de terapias personalizadas
- 19.7. Desenvolvimento de ferramentas de prognóstico clínico baseadas em imagens
 - 19.7.1. Ferramentas de inteligência artificial para prever resultados clínicos a partir de imagens de diagnóstico
 - 19.7.2. Avanços nos relatórios de previsão automatizados
 - 19.7.3. Integração de modelos de prognóstico em sistemas clínicos
 - 19.7.4. Validação e aceitação clínica de ferramentas de prognóstico baseadas em IA
- 19.8. Visualização e comunicação avançadas de dados complexos com o Tableau
 - 19.8.1. Técnicas de visualização para representação multidimensional de dados de imagem
 - 19.8.2. Ferramentas interativas para a exploração de grandes *datasets* de imagens
 - 19.8.3. Estratégias para a comunicação eficaz de descobertas complexas por meio de visualizações
 - 19.8.4. Impacto da visualização avançada na educação médica e na tomada de decisões

- 19.9. Segurança de dados e desafios de gestão de dados *Big Data*
 - 19.9.1. Medidas de segurança para proteger grandes volumes de dados de imagens médicas
 - 19.9.2. Desafios na privacidade e na ética do gerenciamento de dados de imagem
 - 19.9.3. Soluções tecnológicas para o gerenciamento seguro de *Big Data* na área da saúde
 - 19.9.4. Estudos de caso sobre violações de segurança e como elas foram tratadas
- 19.10. Aplicações práticas e estudos de caso em *Big Data* biomédico
 - 19.10.1. Exemplos de aplicações bem-sucedidas de *Big Data* no diagnóstico e tratamento de doenças
 - 19.10.2. Estudos de caso sobre a integração de *Big Data* em sistemas de saúde
 - 19.10.3. Lições aprendidas com projetos de *Big Data* no campo biomédico
 - 19.10.4. Direções futuras e potencialidades do *Big Data* na medicina

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

- 20.1. Ética na aplicação de inteligência artificial em diagnóstico por imagem com o Ethics and Algorithms Toolkit
 - 20.1.1. Princípios éticos fundamentais no uso da Inteligência Artificial para diagnóstico
 - 20.1.2. Gerenciamento de vieses algorítmicos e seu impacto na imparcialidade do diagnóstico
 - 20.1.3. Consentimento informado na era da Inteligência Artificial de diagnóstico
 - 20.1.4. Desafios éticos na implantação internacional de tecnologias de Inteligência Artificial
- 20.2. Considerações legais e regulatórias sobre Inteligência Artificial aplicadas a imagens médicas com Compliance.ai
 - 20.2.1. Estrutura regulatória atual para Inteligência Artificial em diagnósticos de imagem
 - 20.2.2. Conformidade com as normas de privacidade e proteção de dados
 - 20.2.3. Requisitos de validação e certificação para algoritmos de Inteligência Artificial na área da saúde
 - 20.2.4. Responsabilidade legal em caso de erros de diagnóstico por Inteligência Artificial

- 20.3. Consentimento informado e aspectos éticos no uso de dados clínicos
 - 20.3.1. Revisão dos processos de consentimento informado adaptados à Inteligência Artificial
 - 20.3.2. Educação dos pacientes sobre o uso da Inteligência Artificial em seus cuidados médicos
 - 20.3.3. Transparência no uso de dados clínicos para treinamento de IA
 - 20.3.4. Respeito à autonomia do paciente em decisões baseadas em IA
- 20.4. Inteligência artificial e responsabilidade na pesquisa clínica
 - 20.4.1. Atribuição de responsabilidades no uso da Inteligência Artificial para diagnóstico
 - 20.4.2. Implicações dos bugs de Inteligência Artificial na prática clínica
 - 20.4.3. Seguro e cobertura para riscos associados ao uso da Inteligência Artificial
 - 20.4.4. Estratégias para gerenciamento de incidentes relacionados a Inteligência Artificial
- 20.5. Impacto da Inteligência Artificial na equidade e no acesso à assistência médica com a AI for Good
 - 20.5.1. Avaliação do impacto da Inteligência Artificial na distribuição de serviços médicos
 - 20.5.2. Estratégias para garantir o acesso equitativo à tecnologia de IA
 - 20.5.3. Inteligência Artificial como ferramenta para reduzir as disparidades na saúde
 - 20.5.4. Estudos de caso sobre a implementação da Inteligência Artificial em ambientes com recursos limitados
- 20.6. Privacidade e proteção de dados em projetos de pesquisa com o Duality SecurePlus
 - 20.6.1. Estratégias para garantir a confidencialidade dos dados em projetos de Inteligência Artificial
 - 20.6.2. Técnicas avançadas para a anonimização de dados de pacientes
 - 20.6.3. Desafios legais e éticos na proteção de dados pessoais
 - 20.6.4. Impacto das violações de segurança na confiança do público





- 20.7. Inteligência Artificial e sustentabilidade na pesquisa biomédica com o Green Algorithm
 - 20.7.1. Usando a Inteligência Artificial para melhorar a eficiência e a sustentabilidade na pesquisa
 - 20.7.2. Avaliação do ciclo de vida das tecnologias de Inteligência Artificial no setor de saúde
 - 20.7.3. Impacto ambiental da infraestrutura tecnológica de Inteligência Artificial
 - 20.7.4. Práticas sustentáveis no desenvolvimento e na implantação da Inteligência Artificial
- 20.8. Auditoria e explicabilidade de modelos de Inteligência Artificial no ambiente clínico com o IBM AI Fairness 360
 - 20.8.1. Importância da auditoria regular dos algoritmos de IA
 - 20.8.2. Técnicas para melhorar a explicabilidade dos modelos de Inteligência Artificial
 - 20.8.3. Desafios na comunicação de decisões baseadas em IA para pacientes e médicos
 - 20.8.4. Regulamentos sobre a transparência dos algoritmos de Inteligência Artificial no setor de saúde
- 20.9. Inovação e empreendedorismo no campo da Inteligência Artificial clínica com a Hindsait
 - 20.9.1. Oportunidades para startups em tecnologias de Inteligência Artificial para o setor de saúde
 - 20.9.2. Parcerias público-privadas no desenvolvimento da Inteligência Artificial
 - 20.9.3. Desafios para empreendedores no ambiente regulatório de saúde
 - 20.9.4. Histórias de sucesso e aprendizados no empreendedorismo de IA clínica
- 20.10. Considerações éticas sobre a colaboração internacional em pesquisa clínica com a Aliança Global para Genômica e Saúde com GA4GH
 - 20.10.1. Coordenação ética em projetos internacionais de IA
 - 20.10.2. Gerenciar diferenças culturais e regulatórias em parcerias internacionais
 - 20.10.3. Estratégias para inclusão equitativa em estudos globais
 - 20.10.4. Desafios e soluções no intercâmbio de dados

06

Metodologia de estudo

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

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



“

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

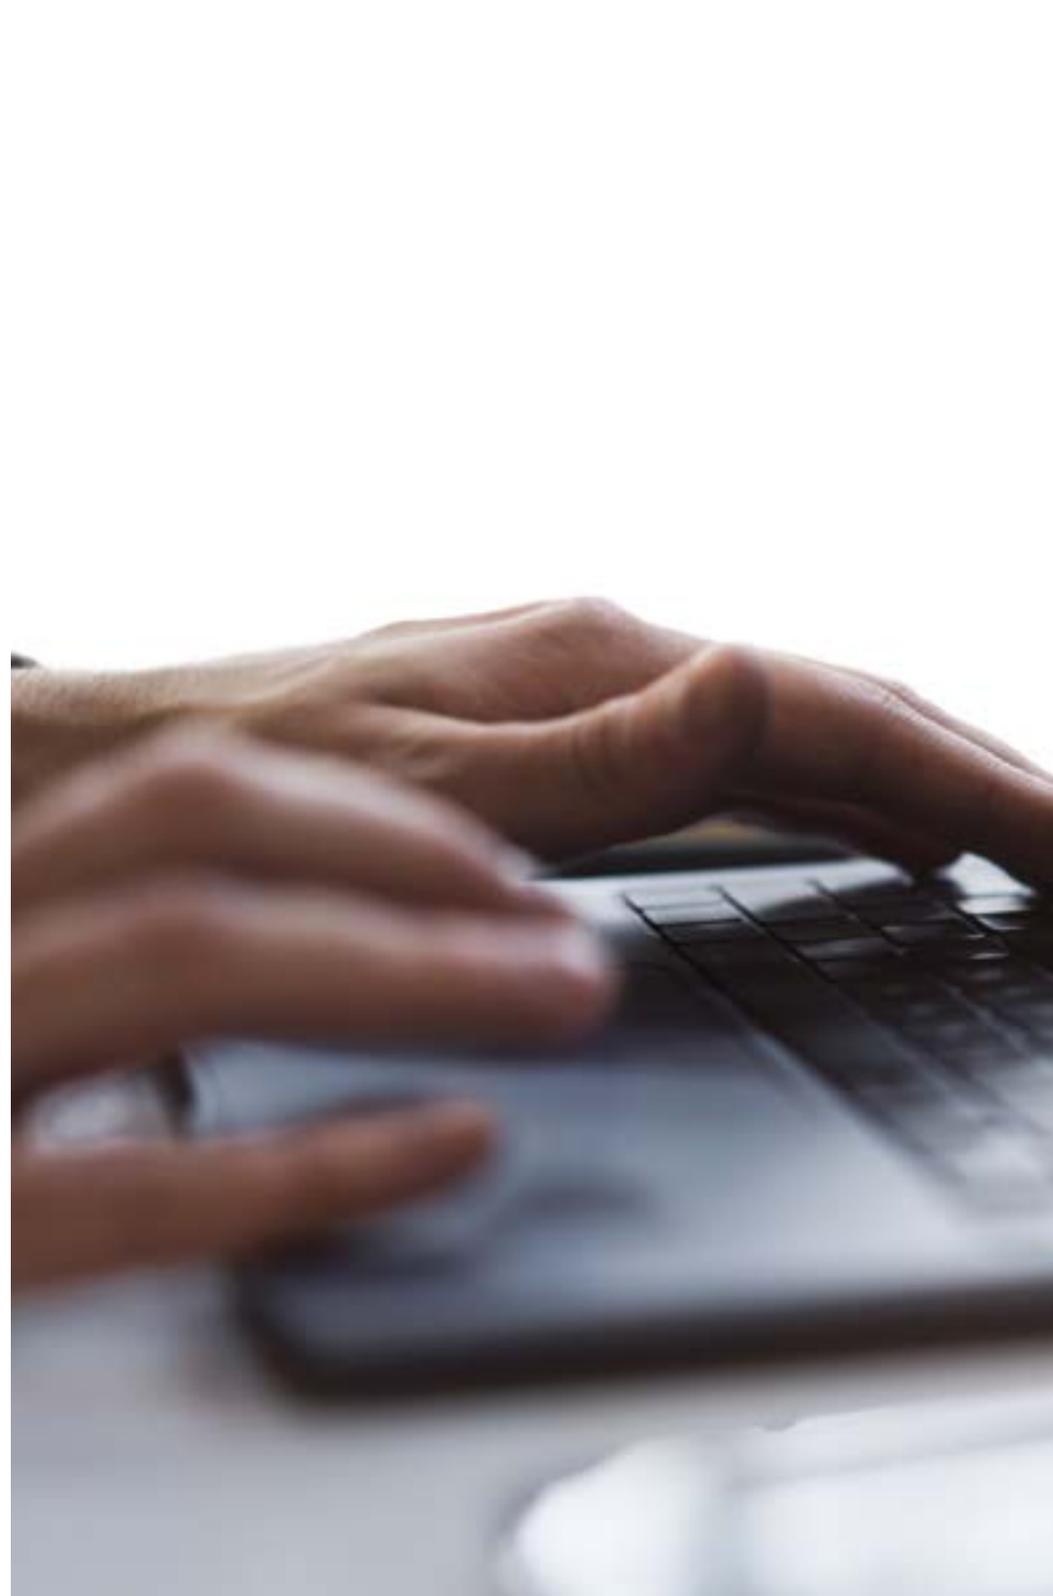
O aluno: a prioridade de todos os programas da TECH

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

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

“

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



Os programas de ensino mais abrangentes do mundo

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

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

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

“

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

Case studies ou Método de caso

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

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

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



Método *Relearning*

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

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

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

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



Um Campus Virtual 100% online com os melhores recursos didáticos

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

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

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

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



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

A eficácia do método é justificada por quatro conquistas fundamentais:

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

A metodologia universitária mais bem avaliada por seus alunos

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

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

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

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



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



Material de estudo

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

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



Práticas de aptidões e competências

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



Resumos interativos

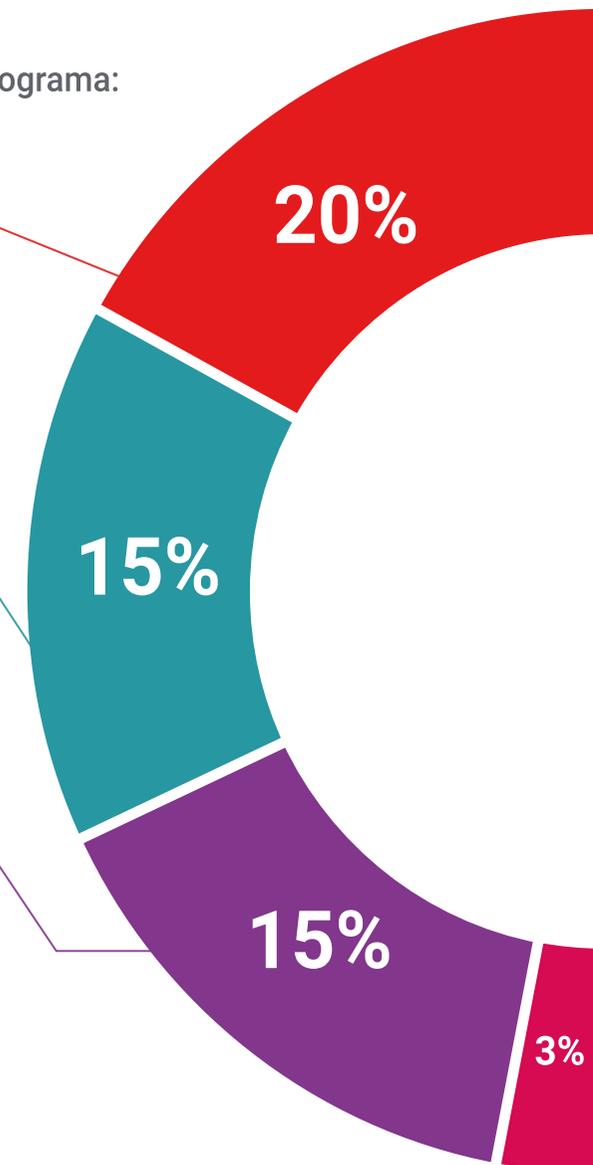
Apresentamos os conteúdos de forma atraente e dinâmica em pílulas multimídia que incluem áudio, vídeos, imagens, diagramas e mapas conceituais com o objetivo de reforçar o conhecimento.

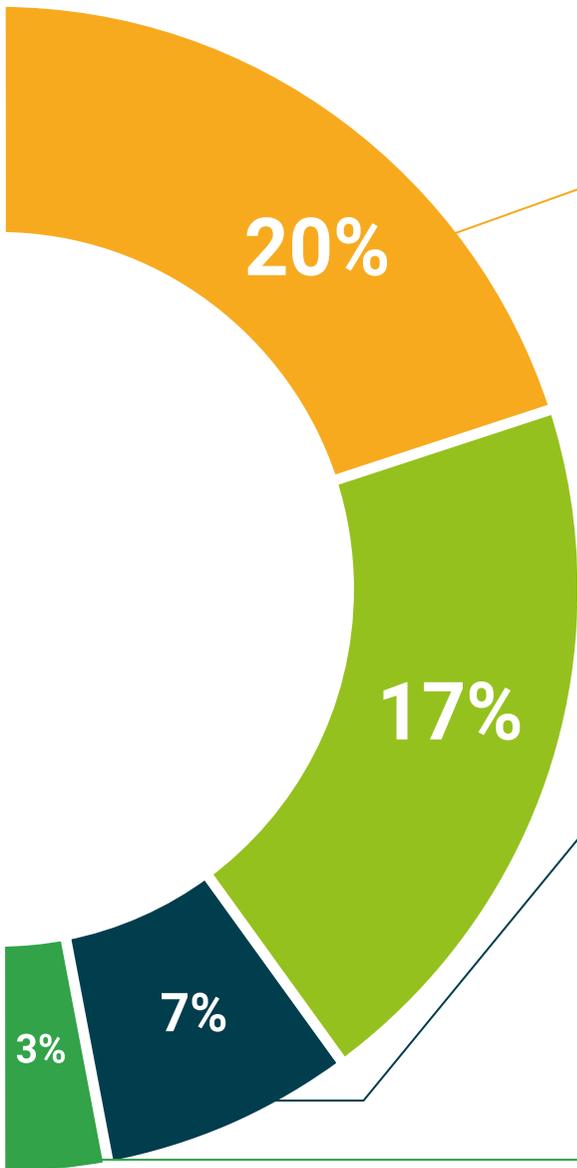
Este sistema exclusivo de capacitação por meio da apresentação de conteúdo multimídia foi premiado pela Microsoft como "Caso de sucesso na Europa"



Leituras complementares

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





Case Studies

Você concluirá uma seleção dos melhores *case studies* da disciplina. Casos apresentados, analisados e orientados pelos melhores especialistas no cenário internacional.



Testing & Retesting

Avaliamos e reavaliamos periodicamente seus conhecimentos ao longo de todo o programa. Fazemos isso em 3 dos 4 níveis da Pirâmide de Miller.



Masterclasses

Há evidências científicas sobre a utilidade da observação de terceiros especialistas.
O *Learning from an expert* fortalece o conhecimento e a memória, e aumenta nossa confiança para tomar decisões difíceis no futuro.



Guias rápidos de ação

A TECH oferece o conteúdo mais relevante do curso em formato de fichas de trabalho ou guias rápidos de ação. Uma forma sintetizada, prática e eficaz de ajudar os alunos a progredirem na aprendizagem.



07

Certificado

O Mestrado Próprio em Inteligência Artificial em Diagnóstico por imagem 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 Diagnóstico por imagem** conta com o conteúdo científico mais completo e atualizado do mercado.

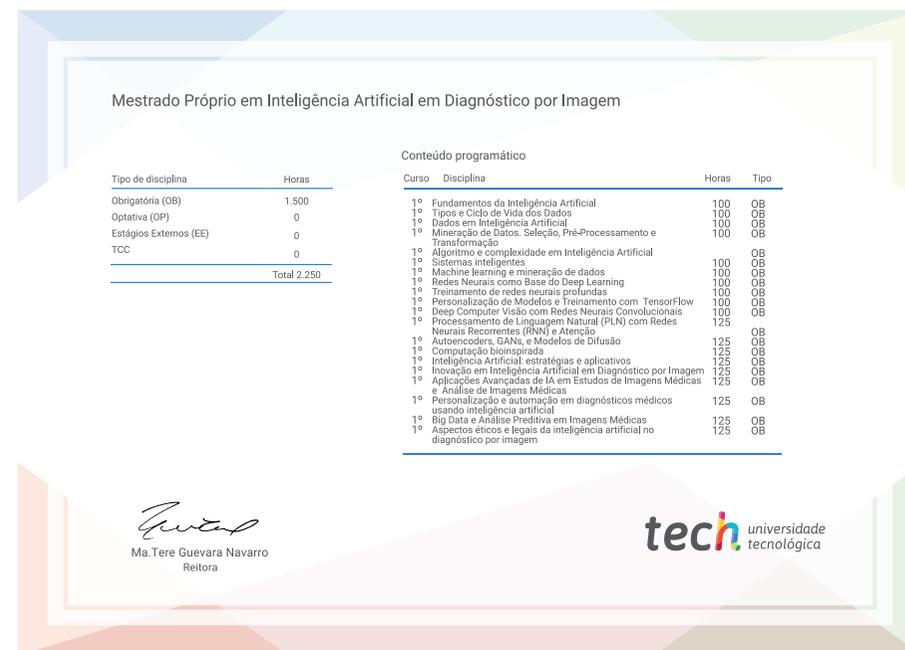
Uma vez aprovadas as avaliações, o aluno receberá por correio o certificado* correspondente ao título de **Mestrado Próprio** emitido pela **TECH Universidade Tecnológica**.

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

Título: **Mestrado Próprio em Inteligência Artificial em Diagnóstico por imagem**

Modalidade: **online**

Duração: **12 meses**



*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 compreensão
atenção personalizada
conhecimento inovação
presente qualidade
desenvolvimento sustentabilidade

tech universidade
tecnológica

Mestrado Próprio
Inteligência Artificial em
Diagnóstico por Imagem

- » Modalidade: online
- » Duração: 12 meses
- » Certificado: TECH Universidade Tecnológica
- » Horário: no seu próprio ritmo
- » Provas: online

Mestrado Próprio

Inteligência Artificial em
Diagnóstico por Imagem