

Mestrado Próprio

Inteligência Artificial no Departamento Financeiro



Mestrado Próprio Inteligência Artificial no Departamento Financeiro

- » Modalidade: online
- » Duração: 7 meses
- » Certificado: TECH Universidade Tecnológica
- » Horário: no seu próprio ritmo
- » Provas: online

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

Índice

01

Apresentação

pág. 4

02

Objetivos

pág. 8

03

Competências

pág. 18

04

Direção do curso

pág. 22

05

Estrutura e conteúdo

pág. 26

06

Metodologia

pág. 44

07

Certificado

pág. 52

01

Apresentação

A Inteligência Artificial está revolucionando o setor financeiro, transformando a maneira como as organizações gerenciam suas operações estratégicas. Essa ferramenta oferece aos profissionais inúmeras vantagens, como a oportunidade de automatizar processos complexos, realizar análises preditivas e otimizar a gestão de riscos. No entanto, a implementação de instrumentos como Redes Neurais Profundas, *Deep Learning* ou Computação Bioinspirada pode representar um grande desafio para os especialistas, devido à sua complexidade técnica. Para facilitar esse processo, a TECH apresenta uma formação inovadora que oferecerá aos diretores financeiros as chaves para liderar essa transformação digital de maneira eficiente. Vale destacar que o curso é oferecido em uma modalidade 100% online, permitindo aos graduados planejar individualmente seus horários.





“

Graças a esse programa 100% online, você aproveitará ao máximo o Big Data e analisará as tendências que influenciam o desempenho dos ativos financeiros”

De acordo com um estudo realizado pela International Finance Association, 70% das entidades que implementaram soluções de Inteligência Artificial conseguiram melhorar a precisão de suas análises econômicas e otimizar a gestão de suas carteiras. Diante dessa realidade, cada vez mais empresas estão exigindo a incorporação de profissionais que possam lidar habilmente com ferramentas emergentes, como *Big Data*, Processamento de Linguagem Natural ou Redes Neurais Convolucionais, para tomar decisões estratégicas mais informadas e melhorar o gerenciamento de riscos financeiros. Para aproveitar essas oportunidades, Laborais, os Profissionais precisam adquirir uma vantagem competitiva que os diferencie de outros candidatos.

Com esse objetivo, a TECH está lançando um programa revolucionário em Inteligência Artificial no Departamento Financeiro. Desenvolvido por especialistas renomados da área, o caminho acadêmico fornecerá aos profissionais habilidades avançadas para lidar com ferramentas avançadas que vão desde a Mineração de Dados ou *Deep Computer Vision* até modelos de Redes Neurais Recorrentes. Assim, os graduados estarão altamente qualificados para usar modelos preditivos no gerenciamento de riscos financeiros, otimizar tarefas tediosas, como o gerenciamento de tesouraria, e até mesmo automatizar outros processos, como auditorias internas. Além disso, os materiais didáticos se aprofundarão nos métodos mais inovadores para otimizar vários portfólios de investimento. Ademais, o programa de estudos oferecerá ferramentas avançadas para projetar visualizações complexas de dados econômicos usando o Google Data Studio.

Além disso, o curso é baseado na revolucionária metodologia *Relearning* promovida pela TECH. Esse é um sistema de aprendizado que consiste na reiteração progressiva de aspectos-chave, o que garante que os conceitos essenciais do programa de estudos permaneçam na memória dos formandos. Além disso, o programa de estudos pode ser planejado individualmente, já que não há horários fixos ou cronogramas de avaliação. Da mesma forma, o Campus Virtual estará disponível 24 horas por dia e permitirá que os profissionais façam o download dos materiais e os consultem sempre que desejarem.

Este **Mestrado Próprio em Inteligência Artificial no Departamento Financeiro** conta com o conteúdo mais completo e atualizado do mercado. Suas principais características são:

- ♦ O desenvolvimento de estudos de caso apresentados por especialistas em Inteligência Artificial
- ♦ O conteúdo gráfico, esquemático e eminentemente prático fornece informações completas e práticas sobre as disciplinas que são essenciais para a prática profissional
- ♦ Exercícios práticos em que o processo de auto-avaliação é realizado para melhorar a aprendizagem
- ♦ 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, fixo ou portátil, com conexão à Internet



Você alcançará todo o seu potencial no campo da Administração Financeira com a ajuda de recursos multimídia em formatos como resumos interativos, vídeos explicativos e leituras especializadas”

“

Deseja incorporar as técnicas mais inovadoras de Processamento de Linguagem Natural em sua prática diária? Conclua esse curso em menos de um ano”

O corpo docente deste curso inclui profissionais da área que transferem a experiência do seu trabalho para esta capacitação, além de especialistas reconhecidos de sociedades científicas de referência e universidades de prestígio.

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

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

Você será capacitado em modelos de Machine Learning com eficiência, o que lhe permitirá prever vários riscos financeiros em potencial.

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



02

Objetivos

Com esse Mestrado Próprio em Aprendizagem Permanente, os profissionais se destacarão por seu sólido conhecimento da implementação da Inteligência Artificial em procedimentos financeiros. Da mesma forma, os graduados adquirirão habilidades avançadas para executar modelos preditivos que permitem o gerenciamento proativo de riscos e um planejamento financeiro mais preciso. Além disso, os profissionais serão capazes de implementar soluções de automação de processos robóticos para otimizar tarefas repetitivas, como contabilidade, gestão de tesouraria e auditorias internas. Além disso, os alunos garantirão que essas ferramentas tecnológicas estejam em conformidade com as normas legais, protegendo assim a segurança dos dados financeiros.



“

Você dominará a técnica emergente de Mineração de Dados e contribuirá para a tomada de decisões financeiras baseadas em evidências”



Objetivos gerais

- ♦ Aplicar técnicas de Inteligência Artificial na tomada de decisões financeiras
- ♦ Desenvolver modelos preditivos para a gestão de riscos financeiros
- ♦ Otimizar a alocação de recursos financeiros por meio de algoritmos de IA
- ♦ Automatizar processos financeiros rotineiros utilizando aprendizado de máquina
- ♦ Implementar ferramentas de processamento de linguagem natural para a análise de dados financeiros
- ♦ Projetar sistemas de recomendação para o setor financeiro
- ♦ Analisar grandes volumes de dados financeiros utilizando técnicas de Big Data
- ♦ Avaliar o impacto da Inteligência Artificial na rentabilidade das empresas
- ♦ Melhorar a detecção de fraudes financeiras com o uso de IA
- ♦ Criar modelos de avaliação de ativos financeiros utilizando Inteligência Artificial
- ♦ Desenvolver ferramentas de simulação financeira baseadas em algoritmos de IA
- ♦ Aplicar técnicas de mineração de dados para identificar padrões financeiros
- ♦ Desenvolver modelos de otimização para o planejamento financeiro
- ♦ Utilizar redes neurais para melhorar a previsão de tendências do mercado
- ♦ Desenvolver soluções baseadas em IA para a personalização de produtos financeiros
- ♦ Implementar sistemas de IA para a tomada de decisões automatizadas em investimentos
- ♦ Desenvolver capacidades analíticas para interpretar os resultados de modelos financeiros de IA
- ♦ Investigar o uso da Inteligência Artificial na regulamentação e conformidade financeira
- ♦ Desenvolver soluções de IA que permitam reduzir custos em processos financeiros
- ♦ Identificar oportunidades de inovação no setor financeiro por meio da IA





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 aprendizagem em Inteligência Artificial
- ♦ Estudar os princípios e as aplicações dos algoritmos genéticos, analisando sua utilidade na solução de problemas complexos
- ♦ Analisar a importância de tesouros, vocabulários e taxonomias na estruturação e no processamento de dados para sistemas de IA
- ♦ Gerenciar soluções de automação por meio de Inteligência Artificial para otimizar a eficiência em tarefas-chave como o processamento de faturas, a conciliação bancária ou a gestão de estoques
- ♦ Utilizar ferramentas como *TensorFlow* e Scikit-Learn para apoiar a tomada de decisões estratégicas
- ♦ Desenvolver competências avançadas em análise exploratória de dados financeiros e criar visualizações utilizando ferramentas como Google Data Studio
- ♦ Liderar a transformação digital nas empresas financeiras para aumentar o desempenho operacional e melhorar a gestão de riscos, como a liquidez

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
- ♦ Conhecer 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* (Data Datawarehouse), com ênfase em seus elementos constituintes e design

Módulo 3. Dados em Inteligência Artificial

- ♦ Dominar os fundamentos da ciência de dados, abrangendo ferramentas, tipos e fontes de 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*, compreender 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 na preparação de dados, incluindo limpeza, integração e formatação de dados para uso em 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 em dados, usando 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 projeto de algoritmos, proporcionando uma sólida compreensão das abordagens fundamentais para a solução de problemas
- ♦ Analisar a eficiência e a complexidade dos algoritmos, aplicando técnicas de análise para avaliar o desempenho em termos de tempo e espaço
- ♦ Estudar e aplicar algoritmos de classificação, compreendendo como eles funcionam 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 gráficos, explorando sua aplicação na representação e solução de problemas que envolvem relações complexas
- ♦ Estudar algoritmos *Greedy*, entendendo sua lógica e aplicações na solução 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 de conhecimento, integrando-as para melhorar a eficiência e a 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 *clustering* 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 como Base do *Deep Learning*

- ♦ Dominar os fundamentos da Aprendizagem Profunda, compreendendo sua função 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 a convergência dos modelos
- ♦ Programar a taxa de aprendizagem para ajustar dinamicamente a velocidade de convergência do modelo
- ♦ Compreender e lidar com o superajuste por meio 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 os 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 aumentar a eficiência no desenvolvimento
- ♦ Desenvolver um aplicativo de *Deep Learning* com *TensorFlow*, integrando o conhecimento adquirido 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. *Visão Computacional Profunda* com Redes Neurais Convolucionais

- ♦ Compreender a arquitetura do córtex visual e sua importância para no *Deep Computer Vision*
- ♦ Explorar e aplicar camadas convolucionais para extrair os principais recursos das imagens
- ♦ Implementar camadas de agrupamento e seu uso em modelos de *Deep Computer Vision* com Keras
- ♦ Analisar várias arquiteturas de Redes Neurais Convolucionais (CNN) e sua aplicabilidade em diferentes contextos
- ♦ Desenvolver e implementar uma CNN ResNet usando a biblioteca Keras para melhorar a eficiência e o 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 na geração de texto usando Redes Neurais Recorrentes (RNN)
- ♦ Aplicar RNN na classificação de opiniões para análise de sentimentos em textos
- ♦ Compreender e aplicar mecanismos de atenção em modelos de processamento de linguagem natural
- ♦ Analisar e utilizar modelos *Transformers* em tarefas específicas de NPL
- ♦ Explorar a aplicação de modelos *Transformers* no contexto do processamento de imagens e da visão computacional
- ♦ Familiarizar-se com a biblioteca de *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 usando um codificador automático linear incompleto para otimizar a representação de dados

- ♦ Implementar e compreender a operação de codificadores automáticos empilhados
- ♦ Explorar e aplicar auto-codificadores 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 Aplicações

- ♦ 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 na agricultura para melhorar a produtividade
- ♦ Otimizar os processos de recursos humanos por meio do uso estratégico da inteligência artificial

Módulo 16. Automação de Processos no Departamento Financeiro com Inteligência Artificial

- ♦ Domine a automatização de processos financeiros usando a Automação de Processos Robóticos para otimizar a precisão de tarefas como o processamento de faturas.
- ♦ Aplique técnicas de *Deep Learning* para melhorar a liquidez e o capital de giro.
- ♦ Desenvolva relatórios financeiros automatizados por meio do Power Bi, aumentando a velocidade da elaboração de relatórios financeiros.
- ♦ Implementar sistemas que minimizem o erro humano no processamento de dados econômicos, aumentando a confiabilidade das informações financeiras.

Módulo 17. Planejamento estratégico e tomada de decisões com Inteligência Artificial

- ♦ Usando o modelo preditivo Scikit-Learn para planejamento estratégico e tomada de decisões financeiras orientadas por dados e tomada de decisões financeiras orientadas por dados.

- ♦ Gerencie o *TensorFlow* para desenvolver estratégias de mercado baseadas em Inteligência Artificial, aumentando a competitividade e a adaptabilidade das empresas em um ambiente financeiro dinâmico

Módulo 18. Técnicas Avançadas de Otimização Financeira com o OR-Tools

- ♦ Dominar as técnicas de otimização de portfólio usando programação linear, não linear e estocástica para melhorar o portfólio financeiro
- ♦ Aplicar algoritmos genéticos na otimização financeira, explorando soluções inovadoras para problemas complexos

Módulo 19. Análise e Visualização de Dados Financeiros com Plotly e Google Data Studio

- ♦ Desenvolver habilidades avançadas para usar ferramentas como o Google Data Studio para desenvolver visualizações interativas que facilitem a comunicação de *insights* financeiras
- ♦ Analisar com precisão séries temporais financeiras e detectar tendências históricas e padrões recorrentes

Módulo 20. Inteligência artificial para gerenciamento de riscos financeiros com TensorFlow e Scikit-learn

- ♦ Implemente modelos de risco de crédito, mercado e liquidez de última geração usando *Machine Learning*
- ♦ Executar técnicas de simulação para avaliar e gerenciar o impacto dos riscos financeiros em diferentes cenários

03

Competências

Após a conclusão desse curso, os profissionais terão obtido habilidades avançadas para aplicar ferramentas de Inteligência Artificial na automação ou otimização de processos financeiros. Nesse sentido, os profissionais usarão modelos preditivos para antecipar tendências, gerenciar riscos e melhorar a administração de recursos econômicos. Por sua vez, os graduados implementarão soluções que reduzem o trabalho manual nas organizações, aumentando o desempenho em aspectos importantes, como contabilidade, gestão financeira e auditoria interna. Os alunos também estarão altamente qualificados para liderar projetos de pesquisa que promovam o avanço de novas metodologias para enriquecer os processos financeiros.



“

Você liderará a transformação digital nas organizações e desenvolverá as estratégias mais eficazes para otimizar significativamente os processos financeiros”



Competências gerais

- Obter habilidades avançadas para integrar técnicas de Inteligência Artificial na automação e otimização de processos financeiros para orientar a tomada de decisões estratégicas
- Analisar grandes volumes de dados financeiros usando algoritmos para gerar previsões, identificar tendências e mitigar riscos financeiros
- Projetar e implementar sistemas de automação para tarefas de rotina, como contabilidade, auditoria ou gerenciamento de riscos
- Garantir que as soluções de Inteligência Artificial estejam em conformidade com as normas atuais e, ao mesmo tempo, gerencie os aspectos éticos e de privacidade do uso de dados financeiros





Competências específicas

- ♦ Capacitar modelos de aprendizado de *Machine Learning* como redes neurais e algoritmos de classificação, para otimizar os investimentos
- ♦ Desenvolver sistemas baseados em Inteligência Artificial que identifiquem padrões incomuns em transações financeiras para evitar fraudes e outras atividades ilícitas em tempo real
- ♦ Aplicar técnicas de análise financeira preditiva para prever fluxos de caixa, valorizar ativos e avaliar a viabilidade de projetos de investimento
- ♦ Aplicar técnicas de análise financeira preditiva para prever fluxos de caixa, valorizar ativos e avaliar a viabilidade de projetos de investimento



Aplicar técnicas de análise financeira preditiva para prever fluxos de caixa, valorizar ativos e avaliar a viabilidade de projetos de investimento”

04

Direção do curso

A principal premissa da TECH é disponibilizar a todos os programas universitários mais completos e atualizados do mercado educacional. Para isso, ela passa por um processo meticuloso de formação de seu corpo docente. Graças a esse esforço, esse Mestrado Próprio em Aprendizagem Permanente conta com a colaboração de especialistas altamente qualificados no uso de Inteligência Artificial em Departamentos Financeiros. Dessa forma, os graduados terão acesso a uma experiência imersiva que lhes permitirá dar um salto significativo de qualidade em suas carreiras profissionais como CFOs.



“

Uma equipe de professores experientes, formada por especialistas em Inteligência Artificial aplicada a contextos financeiros, irá orientá-lo durante todo o processo de aprendizagem e solucionar quaisquer dúvidas que possam surgir”

Direção



Dr. Arturo Peralta Martín-Palomino

- ♦ CEO e CTO em Prometeus 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

Dr. Álvaro Carrasco Aguilar

- ♦ *Sales & Marketing Coordinator* em LionLingo
- ♦ Pesquisador em Gestão de Tecnologia da Informação
- ♦ Doutorado em Pesquisa Sócio-sanitária: Avaliação Técnica e Econômica de Tecnologias, Intervenções e Políticas Aplicadas à Melhoria da Saúde pela Universidade de Castilla La Mancha
- ♦ Mestrado em Investigação Social e em Saúde pela Universidade de Castilla-La Mancha.
- ♦ Graduação em Ciência Política e Administração pela Universidade de Granada.
- ♦ Prémio ao "Melhor Artigo Científico de Inovação Tecnológica para a Eficiência dos Gastos em Saúde".
- ♦ Orador regular em Conferências Científicas internacionais.



Uma experiência de capacitação única, fundamental e decisiva para impulsionar seu crescimento profissional"

05

Estrutura e conteúdo

Através desta formação, os profissionais irão manusear as principais ferramentas da Inteligência Artificial para otimizar os processos financeiros e melhorar a tomada de decisões estratégicas. O programa de estudos abordará aspectos como o ciclo de vida dos dados, os algoritmos e o ensino das Redes Neurais Profundas. Os graduados adquirirão as competências necessárias para utilizar modelos preditivos para gerir riscos financeiros, melhorar o planeamento em tarefas como a gestão de tesouraria e automatizar tarefas de auditoria. O programa de estudos oferecerá também técnicas modernas para otimizar carteiras de investimento e visualizar dados económicos complexos utilizando o Google Data Studio.





“

A sua tarefa consiste em desenvolver soluções de automatização que aumentem a eficácia de tarefas essenciais como a contabilidade, a gestão de tesouraria e a auditoria interna”

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 verossimilhança
 - 4.4.3. Imputação de valores perdidos utilizando a aprendizagem de máquinas
- 4.5. O ruído nos dados
 - 4.5.1. Classes de ruído e seus atributos
 - 4.5.2. Filtragem de ruídos
 - 4.5.3. O efeito do ruído
- 4.6. A maldição da dimensionalidade
 - 4.6.1. *Oversampling*
 - 4.6.2. *Undersampling*
 - 4.6.3. Redução de dados multidimensionais

- 4.7. De atributos contínuos a discretos
 - 4.7.1. Dados contínuos versus discretos
 - 4.7.2. Processo de discretização
- 4.8. Os dados
 - 4.8.1. Seleção de dados
 - 4.8.2. Perspectivas e critérios de seleção
 - 4.8.3. Métodos de seleção
- 4.9. Seleção de Instâncias
 - 4.9.1. Métodos para seleção de instâncias
 - 4.9.2. Seleção de protótipos
 - 4.9.3. Métodos avançados para seleção de instâncias
- 4.10. Pré-processamento de dados em ambientes *Big Data*

Módulo 5. 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 aos conceitos básicos de Aprendizado de Máquina
 - 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 *back propagation*
 - 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 *pipelines* de pré-processamento com Keras
 - 10.8.3. Uso da API de pré-processamento do Keras para treinamento de modelos
- 10.9. Projeto *TensorFlow Datasets*
 - 10.9.1. Utilização do *TensorFlow Datasets* para carregamento de dados
 - 10.9.2. Pré-processamento de dados com o *TensorFlow Datasets*
 - 10.9.3. Uso do *TensorFlow Datasets* para treinamento de modelos
- 10.10. Construção de uma aplicação de *Deep Learning* com *TensorFlow*
 - 10.10.1. 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 Vision* com Redes Neurais Convolucionais

- 11.1. A Arquitetura do *Visual Cortex*
 - 11.1.1. Funções do córtex visual
 - 11.1.2. Teorias da visão computacional
 - 11.1.3. Modelos de processamento de imagens
- 11.2. Camadas convolucionais
 - 11.2.1. Reutilização de pesos na convolução
 - 11.2.2. Convolução 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 Keras
 - 11.5.1. Inicialização de pesos
 - 11.5.2. Definição da camada de entrada
 - 11.5.3. Definição da saída
- 11.6. Uso de modelos pré-treinados do Keras
 - 11.6.1. Características dos modelos pré-treinados
 - 11.6.2. Usos dos modelos pré-treinados
 - 11.6.3. Vantagens dos modelos pré-treinados
- 11.7. Modelos pré-treinados para aprendizado por transferência
 - 11.7.1. Aprendizagem por transferência
 - 11.7.2. Processo de aprendizagem por transferência
 - 11.7.3. Vantagens do aprendizado por transferência
- 11.8. Classificação e localização em *Deep Computer Vision*
 - 11.8.1. Classificação de imagens
 - 11.8.2. Localização de objetos em imagens
 - 11.8.3. Detecção de objetos
- 11.9. Detecção e rastreamento de objetos
 - 11.9.1. Métodos de detecção de objetos
 - 11.9.2. Algoritmos de rastreamento de objetos
 - 11.9.3. Técnicas de rastreamento e localização
- 11.10. Segmentação semântica
 - 11.10.1. Aprendizagem profunda para segmentação semântica
 - 11.10.2. Detecção de bordas
 - 11.10.3. Métodos de segmentação baseados em regras

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

- 12.1. Geração de texto usando RNN
 - 12.1.1. Treinamento de uma RNN para geração de texto
 - 12.1.2. Geração de linguagem natural com RNN
 - 12.1.3. Aplicações de geração de texto com RNN
- 12.2. Criação do conjunto de dados de treinamento
 - 12.2.1. Preparação dos dados para treinamento de uma RNN
 - 12.2.2. Armazenamento do conjunto de dados de treinamento
 - 12.2.3. Limpeza e transformação dos dados
 - 12.2.4. Análise de sentimento
- 12.3. Classificação de opiniões com RNN
 - 12.3.1. Detecção de temas nos comentários
 - 12.3.2. Análise de sentimento com algoritmos de aprendizagem profunda
- 12.4. Rede codificador-decodificador para tradução automática neural
 - 12.4.1. Treinamento de uma RNN para tradução automática
 - 12.4.2. Uso de uma rede *encoder-decoder* para tradução automática
 - 12.4.3. Aumento da precisão da tradução automática com RNN
- 12.5. Mecanismos de atenção
 - 12.5.1. Aplicação de mecanismos de atenção em RNN
 - 12.5.2. Uso de mecanismos de atenção para melhorar a precisão dos modelos
 - 12.5.3. Vantagens dos mecanismos de atenção em redes neurais
- 12.6. Modelos *Transformers*
 - 12.6.1. Uso de modelos *Transformers* para processamento de linguagem natural
 - 12.6.2. Aplicação de modelos *Transformers* para visão
 - 12.6.3. Vantagens dos modelos *Transformers*
- 12.7. *Transformers* para visão
 - 12.7.1. Uso de modelos *Transformers* para visão
 - 12.7.2. Processamento de dados Imagem
 - 12.7.3. Treinamento de modelos *Transformers* para visão
- 12.8. Biblioteca *Transformers* de *Hugging Face*
 - 12.8.1. Uso da Biblioteca *Transformers* de *Hugging Face*
 - 12.8.2. Aplicação da Biblioteca *Transformers* de *Hugging Face*
 - 12.8.3. Vantagens da Biblioteca *Transformers* de *Hugging Face*

- 12.9. Outras bibliotecas *Transformers*. Comparativa
 - 12.9.1. Comparação entre as diferentes bibliotecas *Transformers*
 - 12.9.2. Uso das diferentes bibliotecas *Transformers*
 - 12.9.3. Vantagens das diferentes bibliotecas *Transformers*
- 12.10. Desenvolvimento de um aplicativo de PLN com RNN e atenção. Aplicação Prática
 - 12.10.1. Desenvolvimento de um aplicativo de processamento de linguagem natural com RNN e atenção
 - 12.10.2. Uso de RNN, mecanismos de atenção e modelos *Transformers* no aplicativo
 - 12.10.3. Avaliação da aplicação prática

Módulo 13. Autoencoders, GANs, e Modelos de Difusão

- 13.1. Representação de dados eficientes
 - 13.1.1. Redução da dimensionalidade
 - 13.1.2. Aprendizado profundo
 - 13.1.3. Representações compactas
- 13.2. Realização de PCA com um codificador automático linear incompleto
 - 13.2.1. Processo de treinamento
 - 13.2.2. Implementação em Python
 - 13.2.3. Utilização de dados de teste
- 13.3. Codificadores automáticos empilhados
 - 13.3.1. Redes neurais profundas
 - 13.3.2. Construção de arquiteturas de codificação
 - 13.3.3. Uso da regularização
- 13.4. Autoencoders convolucionais
 - 13.4.1. Design de modelos convolucionais
 - 13.4.2. Treinamento de modelos convolucionais
 - 13.4.3. Avaliação de resultados
- 13.5. Eliminação de ruído de codificadores automáticos
 - 13.5.1. Aplicação de filtros
 - 13.5.2. Design de modelos de codificação
 - 13.5.3. Uso de técnicas de regularização
- 13.6. Codificadores automáticos dispersos
 - 13.6.1. Aumentando a eficiência da codificação
 - 13.6.2. Minimizando o número de parâmetros
 - 13.6.3. Utilização de técnicas de regularização

- 13.7. Codificadores automáticos variacionais
 - 13.7.1. Utilização de otimização variacional
 - 13.7.2. Aprendizagem profunda não supervisionada
 - 13.7.3. Representações latentes profundas
- 13.8. Geração de imagens MNIST de moda
 - 13.8.1. Reconhecimento de padrões
 - 13.8.2. Geração de imagens
 - 13.8.3. Treinamento de redes neurais profundas
- 13.9. Redes adversárias generativas e modelos de difusão
 - 13.9.1. Geração de conteúdo a partir de imagens
 - 13.9.2. Modelagem de distribuições de dados
 - 13.9.3. Uso de redes adversárias
- 13.10. Implementação dos Modelos
 - 13.10.1. Aplicação Prática
 - 13.10.2. Implementação dos modelos
 - 13.10.3. Uso de dados reais
 - 13.10.4. Avaliação de resultados

Módulo 14. Computação Bioinspirada

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

- 14.6. Modelos de computação evolutiva (II)
 - 14.6.1. Modelos de evolução baseados em estimativas de distribuições (EDA)
 - 14.6.2. Programação genética
- 14.7. Programação evolutiva aplicada a dificuldades de aprendizagem
 - 14.7.1. Aprendizagem baseada em regras
 - 14.7.2. Métodos evolutivos em problemas de seleção de instâncias
- 14.8. Problemas multiobjetivo
 - 14.8.1. Conceito de dominância
 - 14.8.2. Aplicação de algoritmos evolutivos a problema multiobjetivo
- 14.9. Redes neurais (I)
 - 14.9.1. Introdução às redes neurais
 - 14.9.2. Exemplo prático com redes neurais
- 14.10. Redes neurais (II)
 - 14.10.1. Casos de uso de redes neurais na pesquisa médica
 - 14.10.2. Casos de uso de redes neurais em economia
 - 14.10.3. Casos de uso de redes neurais em visão artificial

Módulo 15. Inteligência Artificial: Estratégias e Aplicações

- 15.1. Serviços financeiros
 - 15.1.1. As implicações da Inteligência Artificial (IA) nos serviços financeiros Oportunidades e desafios
 - 15.1.2. Casos de uso
 - 15.1.3. Riscos potenciais relacionados ao uso de IA
 - 15.1.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.2. Implicações da Inteligência Artificial 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 *Retail*. 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. Automação de Processos no Departamento Financeiro com Inteligência Artificial

- 16.1. Automação de Processos Financeiros com IA e Automação robótica de processos (RPA)
 - 16.1.1. Automação de Processos Financeiros com IA e automação de processos robóticos (RPA)
 - 16.1.2. Plataformas de RPA para processos financeiros: UiPath, Blue Prism, y Automation Anywhere
 - 16.1.3. Avaliação de casos de uso de RPA em finanças e ROI esperado
- 16.2. Processamento automático de faturas com IA usando Kofax
 - 16.2.1. Configuração de soluções de IA para o processamento de faturas com Kofax
 - 16.2.2. Aplicação de técnicas de *Machine Learning* para a classificação de faturas
 - 16.2.3. Automação do ciclo de contas a pagar com tecnologias de IA
- 16.3. Automação de pagamentos com plataformas de IA
 - 16.3.1. Implementação de sistemas de pagamentos automáticos com Stripe Radar e IA
 - 16.3.2. Uso de modelos preditivos de IA para a gestão eficiente da tesouraria
 - 16.3.3. Segurança dos sistemas de pagamentos automáticos: Prevenção de fraudes com IA
- 16.4. Conciliação bancária com IA e *Machine Learning*
 - 16.4.1. Automação da conciliação bancária usando IA com plataformas como Xero
 - 16.4.2. Implementação de algoritmos de *Machine Learning* para melhorar a precisão
 - 16.4.3. Estudos de caso Melhorias na eficiência e redução de erros
- 16.5. Gestão de fluxos de caixa com *Deep Learning* e *TensorFlow*
 - 16.5.1. Modelagem preditiva de fluxos de caixa com redes LSTM usando *TensorFlow*
 - 16.5.2. Implementação de modelos LSTM em Python para previsões financeiras
 - 16.5.3. Integração de modelos preditivos em ferramentas de planejamento financeiro
- 16.6. Automação do inventário com Predictive Analytics
 - 16.6.1. Uso de técnicas preditivas para otimizar a gestão de inventário
 - 16.6.2. Aplicação de modelos preditivos com Microsoft Azure *Machine Learning*
 - 16.6.3. Integração de sistemas de gestão de inventário com ERP
- 16.7. Desenvolvimentos de relatórios financeiros automatizados com Power BI
 - 16.7.1. Automação da geração de relatórios financeiros utilizando Power BI
 - 16.7.2. Desenvolvimento de *dashboards* dinâmicos para análise financeira em tempo real

- 16.7.3. Casos práticos de melhorias na tomada de decisões financeiras com relatórios automatizados
- 16.8. Otimização de compras com IBM Watson
 - 16.8.1. Análise preditiva para otimização da compra com IBM Watson
 - 16.8.2. Modelos de IA para negociações e definição de preços
 - 16.8.3. Integração de recomendações de IA em plataformas de compras
- 16.9. Atendimento ao cliente com chatbots financeiros e Google Dialogflow
 - 16.9.1. Implementação de chatbots financeiros com Google Dialogflow
 - 16.9.2. Integração de chatbots em plataformas CRM para suporte financeiro
 - 16.9.3. Melhoria contínua de chatbots baseada no *feedback* dos usuários
- 16.10. Auditoria Financeira Assistida por IA
 - 16.10.1. Aplicativos de IA em auditorias internas: Análise das transações
 - 16.10.2. Implementação de IA para auditoria de conformidade e detecção de discrepâncias
 - 16.10.3. Melhorar a eficiência da auditoria com tecnologias de IA

Módulo 17. Planejamento estratégico e Tomada de Decisões com Inteligência Artificial

- 17.1. Modelos preditivos para planejamento estratégico com Scikit-Learn
 - 17.1.1. Construir modelos preditivos com Python e Scikit-Learn
 - 17.1.2. Aplicação da análise de regressão na avaliação de projetos
 - 17.1.3. Validação de modelos preditivos utilizando técnicas de validação cruzada em Python
- 17.2. Análise de cenários com simulações de Monte Carlo
 - 17.2.1. Implementação de simulações de Monte Carlo com Python para análise de risco
 - 17.2.2. Utilização de IA para automatizar e melhorar as simulações de cenários
 - 17.2.3. Interpretação e aplicação dos resultados para a tomada de decisões estratégicas
- 17.3. Avaliação de investimentos com recurso à IA
 - 17.3.1. Técnicas de AI para avaliação de ativos e empresas
 - 17.3.2. Modelos de *Machine Learning* para estimativa de valor com Python
 - 17.3.3. Análisis de caso: Utilização de IA na avaliação de startups tecnológicas
- 17.4. Otimização de fusões e aquisições com *Machine Learning* e *TensorFlow*
 - 17.4.1. Modelos preditivos para avaliar sinergias de M&A e aquisições com *TensorFlow*
 - 17.4.2. Simulação de integrações pós-fusões e aquisições com modelos de AI
 - 17.4.3. Utilização de PNL para análise automatizada da diligência devida



- 17.5. Gestão de carteiras com algoritmos genéticos
 - 17.5.1. Utilização de algoritmos genéticos para a otimização da carteira
 - 17.5.2. Implementação de estratégias de seleção e de atribuição com Python
 - 17.5.3. Análise da eficácia das carteiras otimizadas por IA
- 17.6. Inteligência artificial para o planejamento das sucessões
 - 17.6.1. Utilizar a IA para a identificação e o desenvolvimento de talentos
 - 17.6.2. Modelos preditivos para o planejamento das sucessões utilizando Python
 - 17.6.3. Melhorias na gestão da mudança através da integração da IA
- 17.7. Desenvolver estratégias de mercado com IA e *TensorFlow*
 - 17.7.1. Aplicação de técnicas de *Deep Learning* para análise do mercado
 - 17.7.2. Utilização do *TensorFlow* e do *Keras* para modelizar as tendências do mercado
 - 17.7.3. Desenvolver estratégias de entrada no mercado com base em *insights* de IA
- 17.8. Competitividade e análise da concorrência com a IA e o IBM Watson
 - 17.8.1. Monitorização das competências utilizando PNL e *Machine Learning*
 - 17.8.2. Análise automatizada da concorrência com o IBM Watson
 - 17.8.3. Implementação de estratégias competitivas derivadas da análise da IA
- 17.9. Negociações estratégicas assistidas por IA
 - 17.9.1. Aplicação de modelos de IA na preparação de negociações
 - 17.9.2. Utilização de simuladores de negociação baseados em IA para formação
 - 17.9.3. Avaliação do impacto da AI nos resultados da negociação
- 17.10. Implementação de projetos de AI na estratégia financeira
 - 17.10.1. Planejamento e Gestão de Projetos de AI
 - 17.10.2. Utilização de ferramentas de gestão de projetos, como o Microsoft Project
 - 17.10.3. Apresentação de estudos de casos e análise do sucesso e da aprendizagem

Módulo 18. Técnicas Avançadas de Otimização Financeira com o OR-Tools

- 18.1. Introdução à otimização financeira
 - 18.1.1. Conceitos básicos de otimização
 - 18.1.2. Ferramentas e técnicas de otimização financeira
 - 18.1.3. Aplicações de otimização no domínio financeiro
- 18.2. Otimização de carteiras de investimento
 - 18.2.1. Modelos de Markowitz para otimização de carteiras
 - 18.2.2. Otimização da carteira com restrições
 - 18.2.3. Implementação de modelos de otimização com OR-Tools em Python

- 18.3. Algoritmos genéticos em finanças
 - 18.3.1. Introdução aos algoritmos genéticos
 - 18.3.2. Aplicação de algoritmos genéticos na otimização financeira
 - 18.3.3. Exemplos práticos e estudos de casos
- 18.4. Programação linear e não linear em finanças
 - 18.4.1. Fundamentos da programação linear e não linear
 - 18.4.2. Aplicações na gestão de carteiras e na otimização de recursos
 - 18.4.3. Ferramentas para resolver problemas de programação linear
- 18.5. Otimização estocástica em finanças
 - 18.5.1. Conceitos de otimização estocástica
 - 18.5.2. Aplicações na gestão de riscos e derivativos financeiros
 - 18.5.3. Modelos e técnicas de otimização estocástica
- 18.6. Otimização robusta e sua aplicação em finanças
 - 18.6.1. Fundamentos da otimização robusta
 - 18.6.2. Aplicações em ambientes financeiros incertos
 - 18.6.3. Casos práticos e exemplos de otimização robusta
- 18.7. Otimização multiobjetivo em finanças
 - 18.7.1. Introdução à otimização multiobjetivo
 - 18.7.2. Aplicações na diversificação e alocação de ativos
 - 18.7.3. Técnicas e ferramentas para otimização multiobjetivo
- 18.8. *Machine Learning* para otimização financeira
 - 18.8.1.1. Aplicação de técnicas de *Machine Learning* na otimização
 - 18.8.1.2. Algoritmos de otimização baseados em *Machine Learning*
 - 18.8.1.3. Implementação e casos de estudo
- 18.9. Bibliotecas e ferramentas de otimização em Python (SciPy, OR-Tools)
 - 18.9.1. Bibliotecas e ferramentas de otimização em Python (SciPy, OR-Tools)
 - 18.9.2. Implementação prática de problemas de otimização
 - 18.9.3. Exemplos de aplicações financeiras

- 18.10. Projetos e aplicações práticas de otimização financeira
 - 18.10.1. Desenvolvimento de projetos de otimização financeira
 - 18.10.2. Implementação de soluções de otimização no setor financeiro
 - 18.10.3. Avaliação e apresentação de resultados de projetos

Módulo 19. Análise e Visualização de Dados Financeiros com Plotly e Google Data Studio

- 19.1. Fundamentos da análise de dados financeiros
 - 19.1.1. Introdução à análise de dados
 - 19.1.2. Ferramentas e técnicas para a análise de dados financeiros
 - 19.1.3. Importância do análise de dados em Recursos
- 19.2. Técnicas de análise exploratória de dados financeiros
 - 19.2.1. Análise descritiva de dados financeiros
 - 19.2.2. Visualização de dados financeiros com Python e R
 - 19.2.3. Identificação de padrões e tendências em dados financeiros
- 19.3. Análise de séries temporais financeiras
 - 19.3.1. Fundamentos de séries temporais
 - 19.3.2. Modelos de séries temporais para dados financeiros
 - 19.3.3. Análise e previsão de séries cronológicas
- 19.4. Análise de correlação e causalidade em finanças
 - 19.4.1. Métodos de análise de correlação
 - 19.4.2. Técnicas para identificar relações causais
 - 19.4.3. Aplicações na análise financeira
- 19.5. Visualização avançada de dados financeiros
 - 19.5.1. Técnicas avançadas de visualização de dados
 - 19.5.2. Ferramentas para visualização interativa (Plotly, Dash)
 - 19.5.3. Casos de uso e exemplos práticos
- 19.6. Análise de cluster em dados financeiros
 - 19.6.1. Introdução à análise de cluster
 - 19.6.2. Aplicações em o mercado e a segmentação de clientes

- 19.6.3. Ferramentas e técnicas para a análise de cluster
- 19.7. Análise de Redes e Grafos em finanças
 - 19.7.1. Fundamentos da análise de redes
 - 19.7.2. Aplicações da análise de grafos em finanças
 - 19.7.3. Ferramentas para análise de redes (NetworkX, Gephi)
- 19.8. Análise de Texto e Sentimento em finanças
 - 19.8.1. Processamento de linguagem natural (PNL) em Finanças
 - 19.8.2. Análise de sentimento em notícias e redes sociais
 - 19.8.3. Ferramentas e técnicas para a análise de Texto
- 19.9. Ferramentas de análise e visualização de dados financeiros com IA
 - 19.9.1. Bibliotecas de análise de dados em Python (Pandas, NumPy)
 - 19.9.2. Ferramentas de visualização em R (ggplot2, Shiny)
 - 19.9.3. Implementação prática de análise e visualização
- 19.10. Projetos e aplicações práticas de análise e visualização
 - 19.10.1. Desenvolvimento de projetos de análise de dados financeiros
 - 19.10.2. Implementação de soluções de visualização interativa
 - 19.10.3. Avaliação e apresentação de resultados de projetos


Módulo 20. Inteligência Artificial para Gerenciamento de Riscos Financeiros com *TensorFlow* e *Scikit-learn*

- 20.1. Fundamentos da gestão de riscos financeiros
 - 20.1.1. Noções básicas de gestão de riscos
 - 20.1.2. Tipos de riscos financeiros
 - 20.1.3. Importância da gestão do risco nas finanças
- 20.2. Modelos de risco de crédito com IA
 - 20.2.1. Técnicas de *machine learning* para avaliação do risco de crédito
 - 20.2.2. Modelos de *scoring* de crédito (*scikit-learn*)
 - 20.2.3. Implementação de Modelos de risco de crédito com Python
- 20.3. Modelos de risco de mercado com IA
 - 20.3.1. Análise e gestão de risco de mercado
 - 20.3.2. Aplicação da modelação preditiva ao risco de mercado
 - 20.3.3. Implementação de modelos de risco de mercado
- 20.4. Risco operacional e sua gestão com IA
 - 20.4.1. Conceitos e tipos de risco operacional
 - 20.4.2. Aplicação de técnicas de IA para melhoria da usabilidade
 - 20.4.3. Ferramentas e exemplos práticos
- 20.5. Modelos de risco de Liquidez com IA
 - 20.5.1. Fundamentos do risco de liquidez
 - 20.5.2. Técnicas de *Machine Learning* para a análise de risco de liquidez
 - 20.5.3. Implementação prática de modelos de risco de liquidez
- 20.6. Análise de risco sistêmico com IA
 - 20.6.1. Conceitos de risco sistêmico
 - 20.6.2. Aplicações de IA na avaliação do risco sistêmico
 - 20.6.3. Casos de estudo e exemplos práticos
- 20.7. Otimização de portfólios com considerações de risco
 - 20.7.1. Técnicas de otimização de portfólio
 - 20.7.2. Incorporação de medidas de risco na otimização
 - 20.7.3. Ferramentas para a otimização de portfólios
- 20.8. Simulação de riscos financeiros
 - 20.8.1. Métodos de simulação para a gestão de riscos
 - 20.8.2. Aplicação de simulações Monte Carlo em finanças
 - 20.8.3. Implementação de simulações com Python
- 20.9. Avaliação e monitoramento contínuo do risco
 - 20.9.1. Técnicas de avaliação contínua do risco
 - 20.9.2. Ferramentas para o monitoramento e reporte de riscos
 - 20.9.3. Implementação de sistemas de monitoramento contínuo
- 20.10. Projetos e aplicações práticas em gestão de riscos
 - 20.10.1. Desenvolvimento de projetos de gestão de riscos financeiros
 - 20.10.2. Implementação de soluções de IA para a gestão de riscos
 - 20.10.3. Avaliação e apresentação de resultados de projetos

06

Metodologia

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





“

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

Estudo de caso para contextualizar todo o conteúdo

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

“

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



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



Um método de aprendizagem inovador e diferente

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

“

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

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

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

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

Metodologia Relearning

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

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

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

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

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



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

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

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

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



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



Material de estudo

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

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



Masterclasses

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

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




Práticas de habilidades e competências

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



Leituras complementares

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





Estudos de caso

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



Resumos interativos

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

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



Testing & Retesting

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



07

Certificado

O Mestrado Próprio em Inteligência Artificial no Departamento Financeiro 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 seu certificado sem sair de casa e sem burocracias”

Este **Mestrado Próprio em Inteligência Artificial no Departamento Financeiro** conta com o conteúdo mais completo e atualizado do mercado

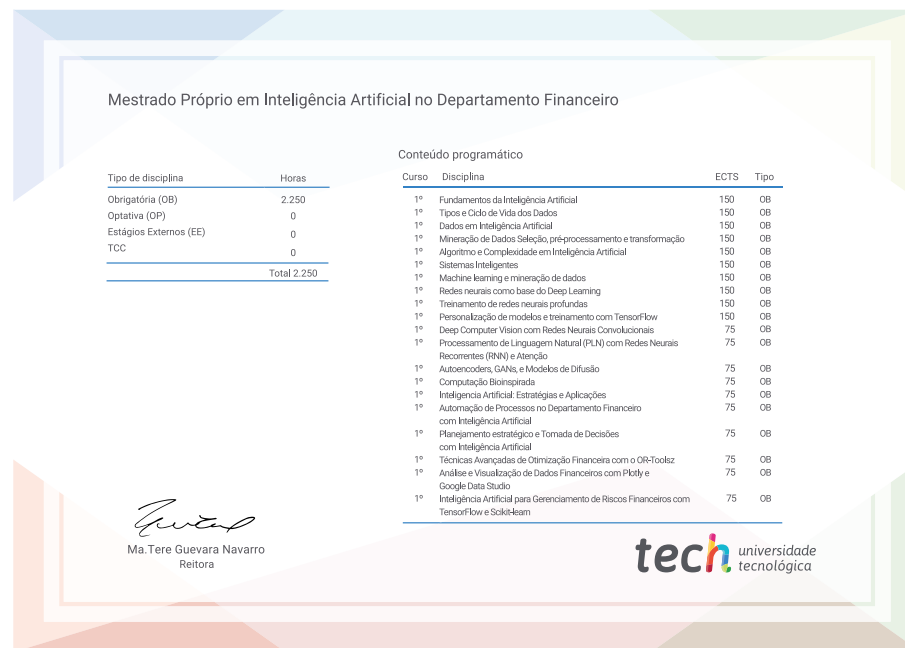
Uma vez aprovadas as avaliações, o aluno receberá por correio o certificado* correspondente ao título de **Mestrado Próprio** emitido pela **TECH Universidade Tecnológica**

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

Título: **Mestrado Próprio em Inteligência Artificial no Departamento Financeiro**

Modalidade: **online**

Duração: **7 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 comunidade
atenção personalizada
conhecimento
presente
desenvolvimento

tech universidade
tecnológica

Mestrado Próprio
Inteligência Artificial no
Departamento Financeiro

- » Modalidade: online
- » Duração: 7 meses
- » Certificado: TECH Universidade Tecnológica
- » Horário: no seu próprio ritmo
- » Provas: online

Mestrado Próprio

Inteligência Artificial no Departamento Financeiro