

Mestrado Próprio

Inteligência Artificial no Departamento Financeiro



Mestrado Próprio Inteligência Artificial no Departamento Financeiro

- » Modalidade: Online
- » Duração: 7 meses
- » Certificação: TECH Global University
- » Acreditação: 90 ECTS
- » Horário: Ao seu próprio ritmo
- » Exames: Online

Acesso ao site: www.techtute.com/pt/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

Certificação

pág. 52

01

Apresentação

A Inteligência Artificial está a revolucionar o sector financeiro, transformando a forma como as organizações gerem as suas operações estratégicas. Esta 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 ferramentas como as Redes Neurais Profundas, *Deep Learning* ou computação bio-inspirada pode ser um desafio para os especialistas devido à sua complexidade técnica. Para facilitar esta tarefa, a TECH apresenta um programa universitário de vanguarda que fornecerá aos responsáveis financeiros as chaves para liderar esta transformação digital de forma eficiente. É de salientar que é ministrado num modo conveniente 100% online, o que permite aos alunos planearem os seus horários individualmente.





“

Graças a este programa 100% online, poderá tirar o máximo partido do Big Data e analisar as tendências que influenciam o desempenho dos activos financeiros”

De acordo com um estudo realizado pela Associação Financeira Internacional, 70% das instituições que implementaram soluções de Inteligência Artificial melhoraram a precisão das suas análises económicas e optimizaram a gestão das suas carteiras. Perante esta realidade, cada vez mais empresas exigem a incorporação de profissionais capazes de manusear habilmente ferramentas emergentes como o *Big Data*, o Processamento de Linguagem Natural ou as Redes Neurais Convolucionais para tomar decisões estratégicas mais informadas e melhorar a gestão do risco financeiro. Para tirar partido destas oportunidades de emprego, os especialistas precisam de ter uma vantagem competitiva que os diferencie dos outros candidatos.

Com este objetivo em mente, a TECH está a lançar um programa revolucionário de Inteligência Artificial no Departamento Financeiro. Concebido por especialistas de renome na área, o programa académico proporcionará aos profissionais competências avançadas para lidar com ferramentas avançadas que vão desde a extração de dados, o *Deep Computer Vision* até os modelos de Redes Neurais Recorrentes. Os alunos formados estarão, assim, altamente qualificados para utilizar modelos preditivos na gestão do risco financeiro, otimizar tarefas fastidiosas como a gestão da tesouraria e até automatizar outros processos, como as auditorias internas. Além disso, o material didático abordará os métodos mais inovadores para otimizar as diferentes carteiras de investimento. Além disso, o programa de estudos oferecerá ferramentas avançadas para a conceção de visualizações complexas de dados económicos utilizando o Google Data Studio.

Além disso, a qualificação baseia-se numa metodologia revolucionária, o *Relearning* alimentada pela TECH. É um sistema de aprendizagem que consiste na reiteração progressiva de aspectos-chave, o que garante que os conceitos essenciais do programa de estudos permaneçam na mente dos licenciados. Além disso, o plano de estudos pode ser planeado numa base individual, uma vez que não existem calendários fixos ou calendários de avaliação. Na mesma linha, o Campus Virtual estará disponível 24 horas por dia e permitirá aos profissionais descarregar os materiais para consulta sempre que desejarem.

Este **Mestrado Próprio de Formação Contínua em Inteligência Artificial no Departamento Financeiro** conta com o conteúdo educativo mais completo e atualizado do mercado. As suas principais características são:

- O desenvolvimento de casos práticos apresentados por especialistas em Inteligência Artificial
- O conteúdo gráfico, esquemático e eminentemente prático com o qual está concebido fornece informações completas e práticas sobre as disciplinas que são essenciais para a prática profissional
- Os exercícios práticos onde o processo de autoavaliação pode ser efetuado a fim de melhorar a aprendizagem
- O seu foco especial em metodologias inovadoras
- As aulas teóricas, perguntas ao especialista, fóruns de discussão sobre questões controversas e atividades de reflexão individual
- A disponibilidade de acesso aos conteúdos a partir de qualquer dispositivo fixo ou portátil com ligação à Internet



O estudante atingirá o seu pleno potencial no domínio da gestão financeira com a ajuda de recursos multimédia em formatos como resumos interactivos, vídeos explicativos e leituras especializadas”

“

Pretende incorporar as técnicas mais inovadoras de Processamento de Linguagem Natural na sua prática diária? Conclua este curso universitário em menos de um ano”

Irá treinar eficazmente modelos de aprendizagem automática, que lhe permitirão prever vários riscos financeiros potenciais.

Terá acesso a um sistema de aprendizagem baseado na repetição, com um ensino natural e progressivo ao longo de todo o plano de estudos.

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

Os seus conteúdos multimédia, desenvolvidos com a mais recente tecnologia educativa, permitirão ao profissional uma aprendizagem situada e contextual, ou seja, um ambiente simulado que proporcionará uma formação imersiva programada para treinar em situações reais.

O design deste programa foca-se na Aprendizagem Baseada em Problemas, através da qual o profissional deverá tentar resolver as diferentes situações da atividade profissional que surgem ao longo do curso. Para tal, contará com a ajuda de um sistema inovador de vídeo interativo desenvolvido por especialistas reconhecidos.



02

Objetivos

Através deste Mestrado Próprio em Formação Contínua, os profissionais destacar-se-ão pelos seus sólidos conhecimentos sobre a implementação da Inteligência Artificial nos procedimentos financeiros. Os alunos formados também adquirem competências avançadas para executar modelos preditivos para uma gestão proactiva dos riscos e um planeamento financeiro mais preciso. Além disso, os especialistas poderão implementar soluções de automatização de processos robóticos para otimizar tarefas repetitivas como a contabilidade, a gestão de tesouraria e as auditorias internas. Além disso, os estudantes garantirão que estas ferramentas tecnológicas cumprem os regulamentos legais, protegendo assim a segurança dos dados financeiros.



“

Irá dominar a técnica emergente de extração de dados e contribuir para a tomada de decisões financeiras baseadas em dados concretos”



Objetivos gerais

- ♦ Aplicar técnicas de Inteligência Artificial na tomada de decisões financeiras
- ♦ Desenvolver modelos preditivos para a gestão do risco financeiro
- ♦ Otimizar a afetação de recursos financeiros utilizando algoritmos de IA
- ♦ Automatizar processos financeiros de rotina utilizando a aprendizagem automática
- ♦ Implementar ferramentas de processamento de linguagem natural para a análise de dados financeiros
- ♦ Desenvolver sistemas de recomendação para o sector financeiro
- ♦ Analisar grandes volumes de dados financeiros utilizando técnicas de Big Data
- ♦ Avaliar o impacto da Inteligência Artificial na rentabilidade das empresas
- ♦ Melhorar a deteção de fraudes financeiras com a utilização da IA
- ♦ Criar modelos de avaliação de activos financeiros utilizando Inteligência Artificial
- ♦ Desenvolver ferramentas de simulação financeira baseadas em algoritmos de IA
- ♦ Aplicar técnicas de extração de dados para identificar padrões financeiros
- ♦ Desenvolver modelos de otimização para o planeamento financeiro
- ♦ Utilizar redes neurais para melhorar a previsão das tendências do mercado
- ♦ Desenvolver soluções baseadas em IA para a personalização de produtos financeiros
- ♦ Implementar sistemas de IA para a tomada de decisões de investimento automatizadas
- ♦ Desenvolver competências analíticas para interpretar os resultados dos modelos financeiros de IA
- ♦ Investigar a utilização da Inteligência Artificial na regulamentação e conformidade financeiras
- ♦ Desenvolver soluções de IA para reduzir os custos dos processos financeiros
- ♦ Identificar oportunidades de inovação no sector financeiro através da IA





Objetivos específicos

Módulo 1. Fundamentos da Inteligência Artificial

- ♦ Analisar a evolução histórica da Inteligência Artificial, desde o seu início até ao seu estado atual, identificando os principais marcos e desenvolvimentos
- ♦ Compreender o funcionamento das redes neuronais e a sua aplicação em modelos de aprendizagem em Inteligência Artificial
- ♦ Estudar os princípios e aplicações dos algoritmos genéticos, analisando a sua utilidade na resolução de problemas complexos
- ♦ Analisar a importância dos thesauri, vocabulários e taxonomias na estruturação e processamento de dados para sistemas de IA
- ♦ Gerir soluções de automatização utilizando Inteligência Artificial para otimizar a eficiência em tarefas-chave como o processamento de facturas, a reconciliação bancária ou a gestão de inventário
- ♦ Gerir ferramentas como *TensorFlow* e *Scikit-Learn* para apoiar a tomada de decisões estratégicas
- ♦ Desenvolver competências avançadas na análise exploratória de dados financeiros e na criação de visualizações utilizando ferramentas como o 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 do Dado

- ♦ Compreender os conceitos fundamentais da estatística e a sua aplicação na análise de dados
- ♦ Identificar e classificar os diferentes tipos de dados estatísticos, desde os quantitativos aos qualitativos
- ♦ Analisar o ciclo de vida dos dados, desde a sua geração até à sua eliminação, identificando as principais etapas
- ♦ Explorar as fases iniciais do ciclo de vida dos dados, destacando a importância do planeamento e da estrutura dos dados
- ♦ Estudar os processos de recolha de dados, incluindo a metodologia, as ferramentas e os canais de recolha
- ♦ Explorar o conceito de *Datawarehouse* (Armazém de Dados), com ênfase nos elementos que o integram e na sua conceção

Módulo 3. O dado na Inteligência Artificial

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

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

- ♦ Dominar técnicas de inferência estatística para compreender e aplicar métodos estatísticos na mineração de dados
- ♦ Realizar análises exploratórias pormenorizadas de conjuntos de dados para identificar padrões, anomalias e tendências relevantes
- ♦ Desenvolver competências para a preparação de dados, incluindo a sua limpeza, integração e formatação para utilização na mineração de dados
- ♦ Implementar estratégias eficazes para tratar valores em falta em conjuntos de dados, aplicando métodos de imputação ou eliminação sensíveis ao contexto
- ♦ Identificar e atenuar o ruído nos dados, utilizando técnicas de filtragem e suavização para melhorar a qualidade do conjunto de dados
- ♦ Abordar o pré-processamento de dados em ambientes *Big Data*

Módulo 5. Algoritmo e complexidade na Inteligência Artificial

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

Módulo 6. Sistemas inteligentes

- ♦ Explorar a teoria dos agentes, compreendendo os conceitos fundamentais do seu funcionamento e a sua aplicação na Inteligência Artificial e na engenharia de Software
- ♦ Estudar a representação do conhecimento, incluindo a análise de ontologias e a sua aplicação na organização de informação estruturada

- ♦ Analisar o conceito de web semântica e o seu impacto na organização e recuperação de informação em ambientes digitais
- ♦ Avaliar e comparar diferentes representações do conhecimento, integrando-as para melhorar a eficiência e a precisão dos sistemas inteligentes

Módulo 7. Aprendizagem automática e mineração de dados

- ♦ Introduzir processos de descoberta de conhecimentos e os conceitos fundamentais da aprendizagem automática
- ♦ Estudar árvores de decisão como modelos de aprendizagem supervisionada, compreendendo a sua estrutura e aplicações
- ♦ Avaliar classificadores utilizando técnicas específicas para medir o seu desempenho e exatidão na classificação de dados
- ♦ Estudar as redes neuronais, compreendendo o seu funcionamento e arquitetura para resolver problemas complexos de aprendizagem automática
- ♦ Explorar os métodos bayesianos e a sua aplicação na aprendizagem automática, incluindo redes bayesianas e classificadores bayesianos
- ♦ Analisar modelos de regressão e de resposta contínua para prever valores numéricos a partir de dados
- ♦ Estudar técnicas de *clustering* para identificar padrões e estruturas em conjuntos de dados não rotulados
- ♦ Explorar a extração de texto e o processamento de linguagem natural (PLN), compreendendo como as técnicas de aprendizagem automática são aplicadas para analisar e compreender texto

Módulo 8. As redes neuronais, a base da *Deep Learning*

- ♦ Dominar os fundamentos da Aprendizagem Profunda, compreendendo o seu papel essencial na *Deep Learning*
- ♦ Explorar as operações fundamentais nas redes neuronais e compreender a sua aplicação na construção de modelos
- ♦ Analisar as diferentes camadas utilizadas nas redes neuronais e aprender a selecioná-las adequadamente
- ♦ Compreender a ligação eficaz de camadas e operações para conceber arquiteturas de redes neuronais complexas e eficientes
- ♦ Utilizar treinadores e otimizadores para ajustar e melhorar o desempenho das redes neuronais
- ♦ Explorar a ligação entre neurónios biológicos e artificiais para uma compreensão mais profunda da conceção de modelos

Módulo 9. Treino de redes neuronais profundas

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

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

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

- ♦ Dominar os fundamentos do *TensorFlow* e a sua integração com o NumPy para um tratamento e computação eficientes dos dados
- ♦ Personalizar modelos e algoritmos de treino utilizando as capacidades avançadas do *TensorFlow*
- ♦ Explorar a API *tf.data* para gerir e manipular eficientemente conjuntos de dados
- ♦ Implementar o formato *TFRecord* para armazenar e aceder a grandes conjuntos de dados *TensorFlow*
- ♦ Utilizar camadas de pré-processamento do Keras para facilitar a construção de modelos personalizados
- ♦ Explore o projeto *TensorFlow Datasets* para acessar conjuntos de dados predefinidos e melhorar a eficiência do desenvolvimento

- ♦ Desenvolver uma aplicação de *Deep Learning* com *TensorFlow*, integrando os conhecimentos adquiridos no módulo
- ♦ Aplicar de forma prática todos os conceitos aprendidos na construção e treino de modelos personalizados com *TensorFlow* em situações do mundo real

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

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

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

- ♦ Desenvolver competências na geração de textos utilizando Redes Neurais Recorrentes (RNN)
- ♦ Aplicar RNN na classificação de opiniões para análise de sentimentos em textos
- ♦ Compreender e aplicar mecanismos de atenção em modelos de processamento de linguagem natural
- ♦ Analisar e utilizar modelos *Transformers* em tarefas específicas de PNL
- ♦ Explorando a aplicação de modelos *Transformers* no contexto do processamento de imagens e da visão computacional
- ♦ Familiarizar-se com a biblioteca *Transformers* de *Hugging Face* para a implementação eficiente de modelos avançados
- ♦ Comparar diferentes bibliotecas de *Transformers* para avaliar a sua adequação a tarefas específicas
- ♦ Desenvolver uma aplicação prática de PLN que integre RNN e mecanismos de atenção para resolver problemas do mundo real

Módulo 13. Autoencoders, GANs, e modelos de difusão

- ♦ Desenvolver representações de dados eficientes utilizando *Autoencoders*, *GANs* e Modelos de Difusão
- ♦ Realizar PCA utilizando um codificador automático linear incompleto para otimizar a representação dos dados
- ♦ Implementar e compreender o funcionamento de codificadores automáticos empilhados

- ♦ Explorar e aplicar codificadores automáticos convolucionais para representações visuais eficientes de dados
- ♦ Analisar e aplicar a eficácia dos codificadores automáticos esparsos na representação de dados
- ♦ Gerar imagens de moda a partir do conjunto de dados MNIST utilizando *Autoencoders*
- ♦ Compreender o conceito de Redes Generativas Antagônicas (*GANs*) e Modelos de Difusão
- ♦ Implementar e comparar o desempenho de modelos de difusão e *GANs* na geração de dados

Módulo 14. Computação bioinspirada

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

Módulo 15. Inteligência Artificial: estratégias e aplicações

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

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

Módulo 16. Automação dos processos no departamento financeiro com Inteligência Artificial

- ♦ Dominar a automação de processos financeiros utilizando a automação de processos robóticos para otimizar a precisão de tarefas como o processamento de facturas
- ♦ Aplicar técnicas de *Deep Learning* a fim de melhorar a liquidez e o fundo de manio
- ♦ Criar relatórios financeiros automatizados através do Power Bi, aumentando a velocidade da redação de relatórios financeiros
- ♦ Implementar sistemas que minimizem o erro humano no processamento de dados económicos, aumentando a fiabilidade da informação financeira

Módulo 17. Planeamento estratégico e tomada de decisões com inteligência artificial

- ♦ Utilizar o modelo preditivo Scikit-Learn para o planeamento estratégico e a tomada de decisões financeiras baseadas em dados
- ♦ Gerir o *TensorFlow* para desenvolver estratégias de mercado baseadas em Inteligência Artificial, aumentando a competitividade e a adaptabilidade das empresas num ambiente financeiro dinâmico





Módulo 18. Técnicas avançadas de otimização financeira com OR-Tools

- ♦ Dominar técnicas de otimização de carteiras utilizando programação linear, não linear e estocástica para melhorar a carteira financeira
- ♦ 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 competências avançadas para utilizar ferramentas como o Google Data Studio para criar visualizações interactivas que facilitem a comunicação de *insights* financeiros
- ♦ Analisar com exatidão séries cronológicas financeiras e detetar tendências históricas e padrões recorrentes

Módulo 20. Inteligência Artificial para a gestão do risco financeiro com TensorFlow e Scikit-learn

- ♦ Implementar modelos avançados de risco de crédito, de mercado e de liquidez utilizando *Machine Learning*
- ♦ Efetuar técnicas de simulação para avaliar e gerir o impacto dos riscos financeiros em diferentes cenários

03

Competências

Após a conclusão deste programa, os especialistas terão obtido competências avançadas para aplicar ferramentas de Inteligência Artificial na automatização ou otimização de processos financeiros. Neste sentido, os profissionais utilizarão modelos preditivos para antecipar tendências, gerir riscos e melhorar a gestão dos recursos económicos. Por sua vez, os alunos implementarão soluções que reduzem o trabalho manual nas organizações, aumentando simultaneamente o desempenho em áreas-chave como a contabilidade, a gestão financeira ou a auditoria interna. Os estudantes estarão também altamente qualificados para liderar projectos de investigação que promovam o avanço de novas metodologias para enriquecer os processos financeiros.



“

Irá liderar a transformação digital nas organizações e criar as estratégias mais eficazes para otimizar significativamente os processos financeiros”



Competências gerais

- Obter competências avançadas para integrar técnicas de Inteligência Artificial na automatização e otimização de processos financeiros para orientar a tomada de decisões estratégicas
- Analisar grandes volumes de dados financeiros utilizando algoritmos para gerar previsões, identificar tendências e atenuar os riscos financeiros
- Conceber e implementar sistemas de automatização para tarefas de rotina como a contabilidade, a auditoria ou a gestão de riscos
- Garantir que as soluções de Inteligência Artificial cumprem a regulamentação atual, gerindo simultaneamente os aspectos éticos e de privacidade da utilização de dados financeiros





Competências específicas

- ♦ Treinar modelos de *Machine Learning* como redes neurais e algoritmos de classificação para otimizar significativamente os investimentos
- ♦ Criar sistemas baseados na inteligência artificial que identifiquem padrões invulgares nas transacções financeiras, a fim de evitar fraudes e outras actividades ilícitas em tempo real
- ♦ Aplicar técnicas de análise financeira preditiva para prever fluxos de caixa, valorizar activos e avaliar a viabilidade de projectos de investimento
- ♦ Integrar tecnologias de automatização emergentes para uma gestão optimizada das facturas



As leituras especializadas que encontrará no Campus Virtual permitir-lhe-ão aprofundar ainda mais a informação rigorosa fornecida nesta proposta académica exclusiva"

04

Direção do curso

A principal premissa da TECH é colocar à disposição de todos os interessados os programas universitários mais completos e actualizados do mercado educativo. Para o conseguir, passa por um processo minucioso de constituição do seu corpo docente. Graças a este esforço, este Mestrado Próprio de Formação Contínua conta com a colaboração de especialistas altamente qualificados na utilização da Inteligência Artificial em departamentos financeiros. Desta forma, os alunos terão acesso a uma experiência imersiva que lhes permitirá dar um salto de qualidade significativo na sua carreira profissional como diretores financeiros.



“

Uma equipa pedagógica experiente, constituída por especialistas em Inteligência Artificial aplicada a contextos financeiros, irá acompanhá-lo ao longo de todo o processo de aprendizagem e resolver todas as dúvidas que possam surgir”

Direção



Dr .Arturo Peralta Martín-Palomino

- CEO e CTO, Prometeus Global Solutions
- CTO em Korporate Technologies
- CTO em AI Shephers GmbH
- Consultor e Assessor Empresarial Estratégico na Alliance Medical
- Diretor de Design e Desenvolvimento na DocPath
- Doutorado em Engenharia Informática pela Universidade de Castilla-La Mancha
- Doutorado em Economia, Empresas 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 pela Formação Hadoop
- Mestrado em Tecnologias Avançadas de Informação da Universidade de Castilla - la Mancha
- Membro de: Grupo de Investigação SMILE

Professores

Dr. Álvaro Carrasco Aguilar

- ♦ *Sales & Marketing Coordinator* na LionLingo
- ♦ Pesquisadora em Gestão de Tecnologia da Informação
- ♦ Doutorado em Investigação Social e Saúde: Avaliação técnica e económica de Tecnologias, Intervenções e Políticas Aplicadas à Melhoria da Saúde pela Universidade de Castilla La Mancha
- ♦ Mestrado em Investigação Social e Sanitária na Universidade de Castilla - La Mancha
- ♦ Formado em Ciências Políticas e Administração pela Universidade de Granada
- ♦ Prémio para o "Melhor Artigo Científico de Inovação Tecnológica para a Eficiência das Despesas em Cuidados de Saúde".
- ♦ Palestrante regular em conferências científicas internacionais.



Uma experiência de aprendizagem única, fundamental e decisiva para impulsionar o seu desenvolvimento profissional"

05

Estrutura e conteúdo

Através deste programa, os profissionais irão manusear as principais ferramentas da Inteligência Artificial para otimizar os processos financeiros e melhorar a tomada de decisões estratégicas. O plano de estudos abordará aspectos como o ciclo de vida dos dados, os algoritmos e a formação de redes neurais profundas. Os alunos 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 curso também oferecerá técnicas modernas para otimizar carteiras de investimento e visualizar dados económicos complexos utilizando o Google Data Studio.





“

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



- 1.7. Sistemas periciais e DSS
 - 1.7.1. Sistemas periciais
 - 1.7.2. Sistema de apoio à decisão
- 1.8. *Chatbots* e assistentes virtuais
 - 1.8.1. Tipos de assistentes: assistentes 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 dos assistentes: *Dialog Flow*, *Watson Assistant*
- 1.9. Estratégia de implementação de IA
- 1.10. Futuro da inteligência artificial
 - 1.10.1. Compreendemos como detetar as emoções através de algoritmos
 - 1.10.2. Criação de uma personalidade: linguagem, expressões e conteúdo
 - 1.10.3. Tendências da Inteligência Artificial
 - 1.10.4. Reflexão

Módulo 2. Tipos e Ciclo de Vida do Dado

- 2.1. A Estatística
 - 2.1.1. Estatística: estatística descritiva, inferências estatísticas
 - 2.1.2. População, amostra indivíduo
 - 2.1.3. Variáveis: Definição 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 a sua forma
 - 2.2.2.1. Numérico
 - 2.2.2.2. Texto
 - 2.2.2.3. Lógico
 - 2.2.3. De acordo com a sua fonte
 - 2.2.3.1. Primários
 - 2.2.3.2. Secundários
- 2.3. Ciclo de vida dos dados
 - 2.3.1. Etapas do ciclo
 - 2.3.2. Marcos do ciclo
 - 2.3.3. Princípios FAIR
- 2.4. Etapas iniciais do ciclo
 - 2.4.1. Definição de metas
 - 2.4.2. Determinação de recursos necessários
 - 2.4.3. Diagrama de Gantt
 - 2.4.4. Estrutura de dados
- 2.5. Recolha de dados
 - 2.5.1. Metodologia de recolha
 - 2.5.2. Ferramentas de recolha
 - 2.5.3. Canais de recolha
- 2.6. Limpeza de dados
 - 2.6.1. Fases de limpeza de dados
 - 2.6.2. Qualidade dos dados
 - 2.6.3. Manipulação de dados (com R)
- 2.7. Análise de dados, interpretação e avaliação dos resultados
 - 2.7.1. Medidas estatísticas
 - 2.7.2. Indicadores de relação
 - 2.7.3. Extração de dados
- 2.8. Armazém de dados (*Datawarehouse*)
 - 2.8.1. Elementos incluídos
 - 2.8.2. Design
 - 2.8.3. Aspetos a considerar
- 2.9. Disponibilidade dos dados
 - 2.9.1. Acesso
 - 2.9.2. Utilidade
 - 2.9.3. Segurança
- 2.10. Aspetos regulamentares
 - 2.10.1. Lei da Proteção de Dados
 - 2.10.2. Boas práticas
 - 2.10.3. Outros aspetos regulamentares

Módulo 3. O dado na Inteligência Artificial

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

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

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

- 4.1. A inferência estatística
 - 4.1.1. Estatística descritiva vs Inferência estatística
 - 4.1.2. Procedimentos paramétricos
 - 4.1.3. Procedimentos não paramétricos
- 4.2. Análise exploratória
 - 4.2.1. Análise descritiva
 - 4.2.2. Visualização
 - 4.2.3. Preparação de dados
- 4.3. Preparação de dados
 - 4.3.1. Integração e limpeza de dados
 - 4.3.2. Normalização de dados
 - 4.3.3. Transformando atributos
- 4.4. Os valores perdidos
 - 4.4.1. Tratamento de valores perdidos
 - 4.4.2. Métodos de imputação de máxima verosimilhança
 - 4.4.3. Imputação de valores perdidos utilizando a aprendizagem automática
- 4.5. O ruído dos dados
 - 4.5.1. Classes de ruído e atributos
 - 4.5.2. Filtragem de ruído
 - 4.5.3. O efeito do ruído
- 4.6. A maldição da dimensionalidade
 - 4.6.1. *Oversampling*
 - 4.6.2. *Undersampling*
 - 4.6.3. Redução de dados multidimensionais

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

Módulo 5. Algoritmo e complexidade na Inteligência Artificial

- 5.1. Introdução às estratégias de desenho do algoritmos
 - 5.1.1. Recursividade
 - 5.1.2. Divide e conquista
 - 5.1.3. Outras estratégias
- 5.2. Eficiência e análise dos algoritmos
 - 5.2.1. Medidas de eficiência
 - 5.2.2. Medir o tamanho da entrada
 - 5.2.3. Medir o tempo de execução
 - 5.2.4. Caso pior, melhor e médio
 - 5.2.5. Notação assintótica
 - 5.2.6. Critérios de Análise matemática de algoritmos não recursivos
 - 5.2.7. Análise matemática de algoritmos recursivos
 - 5.2.8. Análise empírica de algoritmos
- 5.3. Algoritmos de ordenação
 - 5.3.1. Conceito de ordenação
 - 5.3.2. Ordenação da bolha
 - 5.3.3. Ordenação por seleção
 - 5.3.4. Ordenação por inserção
 - 5.3.5. Ordenação por mistura (*Merge_Sort*)
 - 5.3.6. Ordenação rápida (*Quicksort*)
- 5.4. Algoritmos com árvores
 - 5.4.1. Conceito de árvore
 - 5.4.2. Árvores binários
 - 5.4.3. Caminhos de árvore
 - 5.4.4. Representar expressões
 - 5.4.5. Árvores binárias ordenadas
 - 5.4.6. Árvores binárias equilibradas
- 5.5. Algoritmos com *Heaps*
 - 5.5.1. Os *Heaps*
 - 5.5.2. O algoritmo *Heapsort*
 - 5.5.3. As filas de prioridade
- 5.6. Algoritmos com Grafos
 - 5.6.1. Representação
 - 5.6.2. Caminho de largura
 - 5.6.3. Caminho de profundidade
 - 5.6.4. Ordenação topológica
- 5.7. Algoritmos *Greedy*
 - 5.7.1. A estratégia *Greedy*
 - 5.7.2. Elementos da estratégia *Greedy*
 - 5.7.3. Câmbio de moedas
 - 5.7.4. Problema do viajante
 - 5.7.5. Problema da mochila
- 5.8. Pesquisa de caminhos mínimos
 - 5.8.1. O problema do caminho mínimo
 - 5.8.2. Arcos negativos e ciclos
 - 5.8.3. Algoritmo de Dijkstra
- 5.9. Algoritmos *Greedy* sobre Grafos
 - 5.9.1. A árvore de extensão mínima
 - 5.9.2. O algoritmo de Prim
 - 5.9.3. O algoritmo Kruskal
 - 5.9.4. Análise de complexidade
- 5.10. *Backtracking*
 - 5.10.1. O *Backtracking*
 - 5.10.2. Técnicas alternativas

Módulo 6. Sistemas inteligentes

- 6.1. Teoria dos agentes
 - 6.1.1. História do conceito
 - 6.1.2. Definição de agente
 - 6.1.3. Agentes na Inteligência Artificial
 - 6.1.4. Agentes em Engenharia de Software
- 6.2. Arquiteturas de agentes
 - 6.2.1. O processo de argumentação de um agente
 - 6.2.2. Agentes reativos
 - 6.2.3. Agentes dedutivos
 - 6.2.4. Agentes híbridos
 - 6.2.5. Comparativo
- 6.3. Informação e conhecimento
 - 6.3.1. Distinção entre dados, informação e conhecimento
 - 6.3.2. Avaliação qualidade dos dados
 - 6.3.3. Métodos de recolha de dados
 - 6.3.4. Métodos de aquisição de dados
 - 6.3.5. Métodos de aquisição de conhecimento
- 6.4. Representação do conhecimento
 - 6.4.1. A importância da representação do conhecimento
 - 6.4.2. Definição da representação do conhecimento através das suas funções
 - 6.4.3. Características de uma representação do conhecimento
- 6.5. Ontologias
 - 6.5.1. Introdução aos metadados
 - 6.5.2. Conceito filosófico de ontologia
 - 6.5.3. Conceito informático de ontologia
 - 6.5.4. Ontologias de domínio e ontologias de nível superior
 - 6.5.5. Como construir uma ontologia?
- 6.6. Linguagens para ontologias e Software para a criação de ontologias
 - 6.6.1. Triples RDF, *Turtle* e N
 - 6.6.2. RDF *Schema*
 - 6.6.3. OWL
 - 6.6.4. SPARQL
 - 6.6.5. Introdução às diferentes ferramentas de criação de ontologias
 - 6.6.6. Instalação e utilização do *Protégé*
- 6.7. A web semântica
 - 6.7.1. O estado atual e futuro da web semântica
 - 6.7.2. Aplicações da web semântica
- 6.8. Outros modelos representação do conhecimento
 - 6.8.1. Vocabulários
 - 6.8.2. Visão global
 - 6.8.3. Taxonomias
 - 6.8.4. Tesauros
 - 6.8.5. Folksonomias
 - 6.8.6. Comparativo
 - 6.8.7. Mapas mentais
- 6.9. Avaliação e integração das representações do conhecimento
 - 6.9.1. Lógica de ordem zero
 - 6.9.2. Lógica de primeira ordem
 - 6.9.3. Lógica descritiva
 - 6.9.4. Relação entre diferentes tipos de lógica
 - 6.9.5. *Prolog*: programação baseada na lógica de primeira ordem
- 6.10. Raciocinadores semânticos, sistemas baseados no conhecimento e Sistemas Periciais
 - 6.10.1. Conceito de raciocinador
 - 6.10.2. Aplicações de um raciocinador
 - 6.10.3. Sistemas baseados no conhecimento
 - 6.10.4. MYCIN, história dos Sistemas Periciais
 - 6.10.5. Elementos e Arquitetura dos Sistemas Periciais
 - 6.10.6. Criação de Sistemas Periciais



Módulo 7. Aprendizagem automática e mineração de dados

- 7.1. Introdução aos processos de descoberta de conhecimentos e aos conceitos básicos da aprendizagem automática
 - 7.1.1. Conceitos-chave dos processos de descoberta do conhecimento
 - 7.1.2. Perspetiva histórica dos processos de descoberta do conhecimento
 - 7.1.3. Etapas dos processos de descoberta do conhecimento
 - 7.1.4. Técnicas utilizadas nos processos de descoberta do conhecimento
 - 7.1.5. Características dos bons modelos de aprendizagem automática
 - 7.1.6. Tipos de informação sobre aprendizagem automática
 - 7.1.7. Conceitos básicos de aprendizagem
 - 7.1.8. Conceitos básicos de aprendizagem não supervisionado
- 7.2. Exploração e pré-processamento de dados
 - 7.2.1. Tratamento de dados
 - 7.2.2. Tratamento de dados no fluxo de análise de dados
 - 7.2.3. Tipos de dados
 - 7.2.4. Transformação de dados
 - 7.2.5. Visualização e exploração de variáveis contínuas
 - 7.2.6. Visualização e exploração de variáveis categóricas
 - 7.2.7. Medidas de correlação
 - 7.2.8. Representações gráficas mais comuns
 - 7.2.9. Introdução à análise multivariada e à redução da dimensionalidade
- 7.3. Árvore de decisão
 - 7.3.1. Algoritmo ID
 - 7.3.2. Algoritmo C
 - 7.3.3. Excesso de treino e poda
 - 7.3.4. Análise dos resultados
- 7.4. Avaliação dos classificadores
 - 7.4.1. Matrizes de confusão
 - 7.4.2. Matrizes de avaliação numérica
 - 7.4.3. Estatística Kappa
 - 7.4.4. A curva ROC

- 7.5. Regras de classificação
 - 7.5.1. Medidas de avaliação das regras
 - 7.5.2. Introdução à representação gráfica
 - 7.5.3. Algoritmo de sobreposição sequencial
- 7.6. Redes neurais
 - 7.6.1. Conceitos básicos
 - 7.6.2. Redes neuronais simples
 - 7.6.3. Algoritmo de *Backpropagation*
 - 7.6.4. Introdução às redes neuronais recorrentes
- 7.7. Métodos bayesianos
 - 7.7.1. Conceitos básicos de probabilidade
 - 7.7.2. Teorema de Bayes
 - 7.7.3. Naive Bayes
 - 7.7.4. Introdução às redes bayesianas
- 7.8. Modelos de regressão e modelos de resposta contínua
 - 7.8.1. Regressão linear simples
 - 7.8.2. Regressão linear múltipla
 - 7.8.3. Regressão logística
 - 7.8.4. Árvores de regressão
 - 7.8.5. Introdução às máquinas de suporte vetorial (SVM)
 - 7.8.6. Medidas de adequação
- 7.9. *Clustering*
 - 7.9.1. Conceitos básicos
 - 7.9.2. *Clustering* hierárquico
 - 7.9.3. Métodos probabilísticos
 - 7.9.4. Algoritmo EM
 - 7.9.5. Método *B-Cubed*
 - 7.9.6. Métodos implícitos
- 7.10. Mineração de texto e processamento linguagem natural(PLN)
 - 7.10.1. Conceitos básicos
 - 7.10.2. Criação do corpus
 - 7.10.3. Análise descritiva
 - 7.10.4. Introdução à análise de sentimentos

Módulo 8. As redes neuronais, a base da *Deep Learning*

- 8.1. Aprendizagem Profunda
 - 8.1.1. Tipos de aprendizagem profunda
 - 8.1.2. Aplicações da aprendizagem profunda
 - 8.1.3. Vantagens e desvantagens da aprendizagem profunda
- 8.2. Operações
 - 8.2.1. Adição
 - 8.2.2. Produto
 - 8.2.3. Transferência
- 8.3. Camadas
 - 8.3.1. Camada de entrada
 - 8.3.2. Camada oculta
 - 8.3.3. Camada de saída
- 8.4. Ligação de Camadas e Operações
 - 8.4.1. Design de arquiteturas
 - 8.4.2. Conexão entre camadas
 - 8.4.3. Propagação para a frente
- 8.5. Construção da primeira rede neuronal
 - 8.5.1. Design da rede
 - 8.5.2. Estabelecer os pesos
 - 8.5.3. Treino da rede
- 8.6. Treinador e Otimizador
 - 8.6.1. Seleção do otimizador
 - 8.6.2. Estabelecimento de uma função de perda
 - 8.6.3. Estabelecimento de uma métrica
- 8.7. Aplicação dos Princípios das Redes Neuronais
 - 8.7.1. Funções de ativação
 - 8.7.2. Propagação para trás
 - 8.7.3. Ajuste dos parâmetros
- 8.8. Dos neurónios biológicos aos neurónios artificiais
 - 8.8.1. Funcionamento de um neurónio biológico
 - 8.8.2. Transferência de conhecimentos para os neurónios artificiais
 - 8.8.3. Estabelecer de relações entre os dois

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

Módulo 9. Treino de redes neurais profundas

- 9.1. Problemas de Gradientes
 - 9.1.1. Técnicas de otimização de gradiente
 - 9.1.2. Gradientes Estocásticos
 - 9.1.3. Técnicas de inicialização de pesos
- 9.2. Reutilização de camadas pré-treinadas
 - 9.2.1. Treino de transferência de aprendizagem
 - 9.2.2. Extração de características
 - 9.2.3. Aprendizagem profunda
- 9.3. Otimizadores
 - 9.3.1. Otimizadores estocásticos de gradiente descendente
 - 9.3.2. Otimizadores Adam e *RMSprop*
 - 9.3.3. Otimizadores de momento
- 9.4. Programação da taxa de aprendizagem
 - 9.4.1. Controle de taxa sobre aprendizagem automática
 - 9.4.2. Ciclos de aprendizagem
 - 9.4.3. Termos de suavização
- 9.5. Sobreajuste
 - 9.5.1. Validação cruzada
 - 9.5.2. Regularização
 - 9.5.3. Métricas de avaliação
- 9.6. Orientações práticas
 - 9.6.1. Design do modelo
 - 9.6.2. Seleção de métricas e parâmetros de avaliação
 - 9.6.3. Teste de hipóteses

- 9.7. *Transfer Learning*
 - 9.7.1. Treino de transferência de aprendizagem
 - 9.7.2. Extração de características
 - 9.7.3. Aprendizagem profunda
- 9.8. *Data Augmentation*
 - 9.8.1. Transformações de imagem
 - 9.8.2. Geração de dados sintéticos
 - 9.8.3. Transformação de texto
- 9.9. Aplicação Prática de *Transfer Learning*
 - 9.9.1. Treino de transferência de aprendizagem
 - 9.9.2. Extração de características
 - 9.9.3. Aprendizagem profunda
- 9.10. Regularização
 - 9.10.1. L e L
 - 9.10.2. Regularização por entropia máxima
 - 9.10.3. *Dropout*

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

- 10.1. *TensorFlow*
 - 10.1.1. Uso da biblioteca *TensorFlow*
 - 10.1.2. Treino de modelos com o *TensorFlow*
 - 10.1.3. Operações de gráfico no *TensorFlow*
- 10.2. *TensorFlow* e NumPy
 - 10.2.1. Ambiente computacional NumPy para *TensorFlow*
 - 10.2.2. Utilização das arrays NumPy com o *TensorFlow*
 - 10.2.3. Operações NumPy para o *TensorFlow* gráficos do *TensorFlow*
- 10.3. Personalização de modelos e algoritmos de treino
 - 10.3.1. Construir modelos personalizados com o *TensorFlow*
 - 10.3.2. Gestão dos parâmetros de treino
 - 10.3.3. Utilização de técnicas de otimização para o treino
- 10.4. Funções e gráficos do *TensorFlow*
 - 10.4.1. Funções com o *TensorFlow*
 - 10.4.2. Utilização de gráficos para treino de modelos
 - 10.4.3. Otimização de gráficos com operações do *TensorFlow*

- 10.5. Carga de conjuntos de dados com o *TensorFlow*
 - 10.5.1. Carga de conjuntos de dados com o *TensorFlow*
 - 10.5.2. Pré-processamento de dados com o *TensorFlow*
 - 10.5.3. Utilização de ferramentas do *TensorFlow* para a manipulação de dados
- 10.6. A API *tfddata*
 - 10.6.1. Utilização da API *tfddata* para o processamento de dados
 - 10.6.2. Construção de fluxo de dados com *tfddata*
 - 10.6.3. Utilização da API *tfddata* para o treino de modelos
- 10.7. O formato *TFRecord*
 - 10.7.1. Utilização da API *TFRecord* para a serialização de dados
 - 10.7.2. Carregar arquivos *TFRecord* com *TensorFlow*
 - 10.7.3. Utilização de arquivos *TFRecord* para o treino de modelos
- 10.8. Camadas de pré-processamento do Keras
 - 10.8.1. Utilização da API de pré-processamento do Keras
 - 10.8.2. Construção de *pipelined* de pré-processamento com o Keras
 - 10.8.3. Utilização da API de pré-processamento do Keras para o treino de modelos
- 10.9. O projeto *TensorFlow Datasets*
 - 10.9.1. Utilização de *TensorFlow Datasets* para o carregamento de dados
 - 10.9.2. Pré-processamento de dados com o *TensorFlow Datasets*
 - 10.9.3. Utilização de *TensorFlow Datasets* para o treino de modelos
- 10.10. Construção de uma Aplicação de *Deep Learning* com *TensorFlow*
 - 10.10.1. Aplicação Prática
 - 10.10.2. Construção de uma aplicação de *Deep Learning* com *TensorFlow*
 - 10.10.3. Treino de um modelo com o *TensorFlow*
 - 10.10.4. Utilizar a aplicação para previsão de resultados

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

- 11.1. A Arquitetura *Visual Cortex*
 - 11.1.1. Funções do córtex visual
 - 11.1.2. Teoria da visão computacional
 - 11.1.3. Modelos de processamento de imagens
- 11.2. Camadas convolucionais
 - 11.2.1. Reutilização de pesos na convolução
 - 11.2.2. Convolução D
 - 11.2.3. Funções de ativação



- 11.3. Camadas de agrupamento e implementação de camadas de agrupamento
 - 11.3.1. *Pooling e Striding*
 - 11.3.2. *Flattening*
 - 11.3.3. Tipos de *Pooling*
- 11.4. Arquitetura CNN
 - 11.4.1. Arquitetura VGG
 - 11.4.2. Arquitetura *AlexNet*
 - 11.4.3. Arquitetura *ResNet*
- 11.5. Implementação de uma CNN ResNet- usando Keras
 - 11.5.1. Inicialização de pesos
 - 11.5.2. Definição da camada de entrada
 - 11.5.3. Definição da saída
- 11.6. Utilização de modelos pré-treinados do Keras
 - 11.6.1. Características dos modelos pré-treinados
 - 11.6.2. Usos dos modelos pré-treinados
 - 11.6.3. Vantagens dos modelos pré-treinados
- 11.7. Modelos pré-treinados para a aprendizagem por transferência
 - 11.7.1. A Aprendizagem por transferência
 - 11.7.2. Processo de aprendizagem por transferência
 - 11.7.3. Vantagens do aprendizagem por transferência
- 11.8. Classificação e Localização em *Deep Computer Vision*
 - 11.8.1. Classificação de imagens
 - 11.8.2. Localização de objetos em imagens
 - 11.8.3. Detecção de objetos
- 11.9. Detecção e seguimento de objetos
 - 11.9.1. Métodos de detecção de objetos
 - 11.9.2. Algoritmos de seguimento de objetos
 - 11.9.3. Técnicas de seguimento e localização
- 11.10. Segmentação semântica
 - 11.10.1. Aprendizagem profunda para a segmentação semântica
 - 11.10.2. Detecção de bordas
 - 11.10.3. Métodos de segmentação baseado sem regras

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

- 12.1. Geração de texto utilizando RNN
 - 12.1.1. Treino de uma RNN para geração de texto
 - 12.1.2. Geração de linguagem natural com RNN
 - 12.1.3. Aplicações de geração de texto com RNN
- 12.2. Criação de conjuntos de dados de treino
 - 12.2.1. Preparação dos dados para o treino de uma RNN
 - 12.2.2. Armazenamento do conjunto de dados de treino
 - 12.2.3. Limpeza e transformação dos dados
 - 12.2.4. Análise de Sentimento
- 12.3. Classificação da opiniões com RNN
 - 12.3.1. Detecção de temas nos comentários
 - 12.3.2. Análise de sentimento com algoritmos de aprendizagem profunda
- 12.4. Rede codificadora-descodificadora para a tradução automática neural
 - 12.4.1. Treino de uma RNN para a tradução automática
 - 12.4.2. Utilização de uma rede *encoder-decoder* para a tradução automática
 - 12.4.3. Melhoria da precisão da tradução automática com RNNs
- 12.5. Mecanismos de atenção
 - 12.5.1. Implementação de mecanismos de atenção em RNN
 - 12.5.2. Utilização de mecanismos de atenção para melhorar a precisão dos modelos
 - 12.5.3. Vantagens dos mecanismos de atenção nas redes neuronais
- 12.6. Modelos *Transformers*
 - 12.6.1. Uso de modelos *Transformers* no processamento de linguagem natural
 - 12.6.2. Aplicação de modelos *Transformers* na visão
 - 12.6.3. Vantagens dos modelos *Transformers*
- 12.7. *Transformers* para a visão
 - 12.7.1. Utilização de modelos *Transformers* para a visão
 - 12.7.2. Pré-processamento de dados de imagem
 - 12.7.3. Treino de modelos *Transformers* para visão
- 12.8. Biblioteca de *Transformers* de *Hugging Face*
 - 12.8.1. Utilização da biblioteca *Transformers* de *Hugging Face*
 - 12.8.2. Aplicação da biblioteca de *Transformers* de *Hugging Face*
 - 12.8.3. Vantagens da biblioteca *Transformers* de *Hugging Face*

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

Módulo 13. Autoencoders, GANs, e Modelos de Difusão

- 13.1. Representação de dados eficientes
 - 13.1.1. Redução da dimensionalidade
 - 13.1.2. Aprendizagem profunda
 - 13.1.3. Representações compactas
- 13.2. Realização da PCA com um codificador automático linear incompleto
 - 13.2.1. Processo de treino
 - 13.2.2. Implementação em Python
 - 13.2.3. Utilização de dados de teste
- 13.3. Codificadores automáticos empilhados
 - 13.3.1. Redes neurais profundas
 - 13.3.2. Construção de arquiteturas de codificação
 - 13.3.3. Utilização da regularização
- 13.4. Autoencodificadores convolucionais
 - 13.4.1. Design do modelo convolucionais
 - 13.4.2. Treino do modelo convolucionais
 - 13.4.3. Avaliação dos resultados
- 13.5. Redução do ruído dos codificadores automáticos
 - 13.5.1. Aplicação de filtros
 - 13.5.2. Design de modelos de codificação
 - 13.5.3. Utilização de técnicas de regularização
- 13.6. Codificadores automáticos dispersos
 - 13.6.1. Aumento da eficiência da codificação
 - 13.6.2. Minimizar o número de parâmetros
 - 13.6.3. Utilização de técnicas de regularização

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

Módulo 14. Computação bioinspirada

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

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

Módulo 15. Inteligência Artificial: estratégias e aplicações

- 15.1. Serviços financeiros
 - 15.1.1. As implicações da Inteligência Artificial (IA) nos serviços financeiros Oportunidades e desafios
 - 15.1.2. Casos de utilização
 - 15.1.3. Potenciais riscos relacionados com a utilização de IA
 - 15.1.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.2. Implicações da inteligência artificial no serviço de saúde
 - 15.2.1. Implicações da IA no setor da saúde Oportunidades e desafios
 - 15.2.2. Casos de utilização
- 15.3. Riscos relacionados com a utilização de IA no serviço de saúde
 - 15.3.1. Potenciais riscos relacionados com a utilização de IA
 - 15.3.2. Potenciais desenvolvimentos/utilizações futuras da IA

- 15.4. *Retail*
 - 15.4.1. Implicações da IA no *Retail* Oportunidades e desafios
 - 15.4.2. Casos de utilização
 - 15.4.3. Potenciais riscos relacionados com a utilização de IA
 - 15.4.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.5. Indústrias
 - 15.5.1. Implicações da IA na Indústria. Oportunidades e desafios
 - 15.5.2. Casos de utilização
- 15.6. Potenciais riscos relacionados com a utilização de IA na Indústria
 - 15.6.1. Casos de utilização
 - 15.6.2. Potenciais riscos relacionados com a utilização de IA
 - 15.6.3. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.7. Administração pública
 - 15.7.1. Implicações da IA na Administração pública. Oportunidades e desafios
 - 15.7.2. Casos de utilização
 - 15.7.3. Potenciais riscos relacionados com a utilização de IA
 - 15.7.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.8. Educação
 - 15.8.1. Implicações da IA na educação. Oportunidades e desafios
 - 15.8.2. Casos de utilização
 - 15.8.3. Potenciais riscos relacionados com a utilização de IA
 - 15.8.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.9. Silvicultura e agricultura
 - 15.9.1. Implicações da IA na Indústria 4.0 Oportunidades e desafios
 - 15.9.2. Casos de utilização
 - 15.9.3. Potenciais riscos relacionados com a utilização de IA
 - 15.9.4. Potenciais desenvolvimentos/utilizações futuras da IA
- 15.10. Recursos Humanos
 - 15.10.1. Implicações da IA nos Recursos Humanos Oportunidades e desafios
 - 15.10.2. Casos de utilização
 - 15.10.3. Potenciais riscos relacionados com a utilização de IA
 - 15.10.4. Potenciais desenvolvimentos/utilizações futuras da IA

Módulo 16. Automação dos processos no departamento financeiro com Inteligência Artificial

- 16.1. Automação de processos financeiros com IA e Robotic Process Automation (RPA)
 - 16.1.1. IA e RPA para automação e robotização de processos
 - 16.1.2. Plataformas RPA para processos financeiros: UiPath, Blue Prism, e Automation Anywhere
 - 16.1.3. Avaliação dos casos de utilização da RPA nas finanças e ROI esperado
- 16.2. Processamento automatizado de facturas com IA com a Kofax
 - 16.2.1. Configurar soluções de IA para processamento de facturas com a Kofax
 - 16.2.2. Aplicação de técnicas de *Machine Learning* para a classificação das facturas
 - 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 pagamento automatizados com Stripe Radar e IA
 - 16.3.2. Utilizar modelos preditivos de IA para uma gestão eficiente do dinheiro
 - 16.3.3. Segurança nos sistemas de pagamento automático: Prevenção de fraudes com a AI
- 16.4. Reconciliação bancária com AI e *Machine Learning*
 - 16.4.1. Automação da reconciliação bancária utilizando IA com plataformas como o Xero
 - 16.4.2. Implementação de Algoritmos de *Machine Learning* para melhorar a precisão
 - 16.4.3. Estudos de casos: Melhorias de eficiência e redução de erros
- 16.5. Gestão do fluxo de caixa com *Deep Learning* e *TensorFlow*
 - 16.5.1. Modelação preditiva de fluxos de caixa com redes LSTM utilizando *TensorFlow*
 - 16.5.2. Implementação de modelos LSTM em Python para previsão financeira
 - 16.5.3. Integração de modelos preditivos em ferramentas de planeamento financeiro
- 16.6. Automação do inventário com análise preditiva
 - 16.6.1. Utilização de técnicas de previsão para otimizar a gestão do inventário
 - 16.6.2. Aplicação de modelação preditiva com o Microsoft Azure *Machine Learning*
 - 16.6.3. Integração de sistemas de gestão de inventário com ERPs
- 16.7. Relatórios financeiros automatizados com o Power BI
 - 16.7.1. Automação de relatórios financeiros utilizando o Power BI
 - 16.7.2. Desenvolvimento de *dashboards* dinâmicos para análise financeira em tempo real
 - 16.7.3. Estudos de casos de melhorias na tomada de decisões financeiras com relatórios automatizados

- 16.8. Otimização de compras com o IBM Watson
 - 16.8.1. Análise preditiva para otimização de compras com o IBM Watson
 - 16.8.2. Modelos de AI para negociações e fixação de preços
 - 16.8.3. Integração de recomendações de IA nas plataformas de compras
- 16.9. Apoio ao cliente com chatbots financeiros e Google DialogFlow
 - 16.9.1. Implementação de chatbots financeiros com o Google Dialogflow
 - 16.9.2. Integração de chatbots em plataformas de CRM para apoio financeiro
 - 16.9.3. Melhoria contínua dos chatbots com base no *feedback* dos utilizadores
- 16.10. Auditoria financeira assistida pela AI
 - 16.10.1. Aplicações de AI em auditorias internas: Análise das transacções
 - 16.10.2. Implementação da AI para auditoria de conformidade e deteção de discrepâncias
 - 16.10.3. Melhorar a eficiência da auditoria com tecnologias de IA

Módulo 17. Planeamento estratégico e tomada de decisões com inteligência artificial

- 17.1. Modelação preditiva para planeamento estratégico com Scikit-Learn
 - 17.1.1. Modelação preditiva com Python e Scikit-Learn
 - 17.1.2. Aplicação da análise de regressão na avaliação de projectos
 - 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 riscos
 - 17.2.2. Utilizar a 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 do investimento com recurso à AI
 - 17.3.1. Técnicas de AI para avaliação de activos e empresas
 - 17.3.2. Modelos de *Machine Learning* para estimativa de valores com Python
 - 17.3.3. Análise de casos: Utilização da IA na avaliação de startups tecnológicas
- 17.4. Otimização das fusões e aquisições com *Machine Learning* e *TensorFlow*
 - 17.4.1. Modelação preditiva para avaliar sinergias de fusões e aquisições com *TensorFlow*
 - 17.4.2. Simulação de integrações pós-fusões e aquisições com modelos de AI
 - 17.4.3. Utilização da PNL para análise automatizada de diligências devidas



- 17.5. Gestão de carteiras com algoritmos genéticos
 - 17.5.1. Utilização de algoritmos genéticos para a otimização de carteiras
 - 17.5.2. Implementação de estratégias de seleção e atribuição com Python
 - 17.5.3. Analisar a eficácia das carteiras optimizadas por IA
- 17.6. Inteligência artificial para o planeamento das sucessões
 - 17.6.1. Utilizar a IA para identificar e desenvolver talentos
 - 17.6.2. Modelos preditivos para planeamento de sucessões utilizando Python
 - 17.6.3. Melhoria da gestão da mudança através da integração da AI
- 17.7. Desenvolvimento de estratégias de mercado com IA e *TensorFlow*
 - 17.7.1. Aplicação de técnicas de *Deep Learning* para análise de mercado
 - 17.7.2. Uso de *TensorFlow* e Keras para modelar as tendências do mercado
 - 17.7.3. Desenvolvimento de estratégias de entrada no mercado com base em *insights* de AI
- 17.8. Competitividade e análise da concorrência com IA e IBM Watson
 - 17.8.1. Controlo das competências através da PNL e *Machine Learning*
 - 17.8.2. Análise competitiva automatizada com o IBM Watson
 - 17.8.3. Implementação de estratégias competitivas derivadas da análise da AI
- 17.9. Negociações estratégicas assistidas por IA
 - 17.9.1. Aplicação de modelos de AI 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 das negociações
- 17.10. Implementação de projectos de AI na estratégia financeira
 - 17.10.1. Planeamento e gestão de projectos de AI
 - 17.10.2. Utilização de ferramentas de gestão de projectos, 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 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 financeira
- 18.2. Otimização das 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 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 em gestão de riscos e derivados 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. Estudos de casos e exemplos de otimização robusta
- 18.7. Otimização multiobjectivo em finanças
 - 18.7.1. Introdução à otimização multiobjectivo
 - 18.7.2. Aplicações em diversificação e afetação de activos
 - 18.7.3. Técnicas e ferramentas para a otimização multi-objetivo
- 18.8. *Machine Learning* para a 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 estudos de casos
- 18.9. Ferramentas de otimização Python e OR-Tools
 - 18.9.1. Bibliotecas e ferramentas de otimização Python (SciPy, OR-Tools)
 - 18.9.2. Aplicação prática de problemas de otimização
 - 18.9.3. Exemplos de aplicações financeiras
- 18.10. Projectos e aplicações práticas de otimização financeira
 - 18.10.1. Desenvolvimento de projectos de otimização financeira
 - 18.10.2. Implementação de soluções de otimização no sector financeiro
 - 18.10.3. Avaliação e apresentação dos resultados do projeto

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 de análise de dados financeiros
 - 19.1.3. Importância da análise de dados em finanças
- 19.2. Técnicas de análise exploratória de dados financeiros
 - 19.2.1. Análise descritiva dos dados financeiros
 - 19.2.2. Visualizar 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 cronológicas 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 de identificação de relações causais
 - 19.4.3. Aplicações em análise financeira
- 19.5. Visualização avançada de dados financeiros
 - 19.5.1. Técnicas avançadas de visualização de dados
 - 19.5.2. Ferramentas de visualização interactiva (Plotly, Dash)
 - 19.5.3. Casos de utilização e exemplos práticos
- 19.6. Análise de clusters em dados financeiros
 - 19.6.1. Introdução à análise de agrupamentos
 - 19.6.2. Aplicações na segmentação de mercados e clientes
 - 19.6.3. Ferramentas e técnicas para análise de agrupamentos
- 19.7. Redes e análise de redes em finanças
 - 19.7.1. Fundamentos da análise de redes
 - 19.7.2. Aplicações da análise gráfica em finanças
 - 19.7.3. Ferramentas de análise de redes (NetworkX, Gephi)

- 19.8. Análise de texto e de sentimentos em finanças
 - 19.8.1. Processamento de linguagem natural (PNL) em finanças
 - 19.8.2. Análise de sentimentos nas notícias e nas redes sociais
 - 19.8.3. Ferramentas e técnicas de análise de texto
- 19.9. Ferramentas de visualização e análise de dados financeiros com IA
 - 19.9.1. Bibliotecas de análise de dados Python (Pandas, NumPy)
 - 19.9.2. Ferramentas de visualização em R (ggplot2, Shiny)
 - 19.9.3. Aplicação prática da análise e da visualização
- 19.10. Projectos e aplicações práticas de análise e visualização
 - 19.10.1. Desenvolvimento de projectos de análise de dados financeiros
 - 19.10.2. Implementação de soluções de visualização interactiva
 - 19.10.3. Avaliação e apresentação dos resultados do projeto

Módulo 20. Inteligência Artificial para a gestão do risco financeiro com *TensorFlow* e Scikit-learn


- 20.1. Fundamentos da gestão do 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 a 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 do 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 a IA
 - 20.4.1. Conceitos e tipos de risco operacional
 - 20.4.2. Aplicação de técnicas de IA para a gestão do risco operacional
 - 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 do risco de liquidez
 - 20.5.3. Implementação prática de modelos de risco de liquidez
- 20.6. Análise de risco sistémico com AI
 - 20.6.1. Conceitos de risco sistémico
 - 20.6.2. Aplicações de IA na avaliação do risco sistémico
 - 20.6.3. Estudos de casos e exemplos práticos
- 20.7. Otimização da carteira com considerações de risco
 - 20.7.1. Técnicas de otimização da carteira
 - 20.7.2. Incorporação de medidas de risco na otimização
 - 20.7.3. Ferramentas de otimização da carteira
- 20.8. Simulação de riscos financeiros
 - 20.8.1. Métodos de simulação para a gestão do risco
 - 20.8.2. Aplicação de simulações de Monte Carlo em finanças
 - 20.8.3. Implementação de simulações com Python
- 20.9. Avaliação e controlo contínuos dos riscos
 - 20.9.1. Técnicas de avaliação contínua dos riscos
 - 20.9.2. Ferramentas de monitorização e comunicação de riscos
 - 20.9.3. Implementação de sistemas de monitorização contínua
- 20.10. Projectos e aplicações práticas na gestão do risco
 - 20.10.1. Desenvolvimento de projectos de gestão do risco financeiro
 - 20.10.2. Implementar soluções de IA para a gestão do risco
 - 20.10.3. Avaliação e apresentação dos resultados do projeto

06

Metodologia

Esta certificação oferece um método diferente de aprendizagem. A nossa metodologia foi desenvolvida através de um modo de aprendizagem cíclica: **o Relearning**.

Este método de ensino é utilizado, por exemplo, nas faculdades de medicina mais prestigiadas do mundo e tem sido considerado um dos mais eficazes por publicações líderes, tais como o ***New England Journal of Medicine***.



“

Descubra o Relearning, um sistema que renuncia à aprendizagem linear convencional para o guiar por meio de métodos de ensino cíclicos: uma forma de aprendizagem que provou ser extremamente eficaz, especialmente em disciplinas que requerem memorização”

Estudo de Caso para contextualizar todo o conteúdo

O nosso Curso oferece um método revolucionário de desenvolvimento de competências e conhecimentos. O nosso objetivo é reforçar as competências num contexto de mudança, competitivo e altamente exigente.

“

Com a TECH poderá experimentar uma forma de aprendizagem que abala as bases das universidades tradicionais em todo o mundo”



Terá acesso a um sistema de aprendizagem baseado na repetição, com ensino natural e progressivo ao longo de todo o plano de estudos.



Um método de aprendizagem inovador e diferente

Este Curso da TECH é um programa de ensino intensivo, criado de raiz, que propõe os desafios e decisões mais exigentes neste campo, tanto a nível nacional como internacional. Graças a esta metodologia, o crescimento pessoal e profissional é impulsionado, dando um passo decisivo para o sucesso. O método do caso, técnica que constitui a base deste conteúdo, assegura que a realidade económica, social e profissional mais atual seja seguida.

“ *O nosso Curso de Especialização prepara-o para enfrentar novos desafios em ambientes incertos e alcançar o sucesso na sua carreira”*

O aluno aprenderá, através de atividades de colaboração e casos reais, a resolução de situações complexas em ambientes empresariais reais.

O método do caso tem sido o sistema de aprendizagem mais amplamente utilizado nas melhores escolas de Informática do mundo desde que estas existem. Desenvolvido em 1912 para que os estudantes de Direito não aprendessem apenas o direito com base no conteúdo teórico, o método do caso consistia em apresentar-lhes situações verdadeiramente complexas, a fim de tomarem decisões informadas e valorizarem juízos sobre a forma de as resolver. Em 1924 foi estabelecido como um método de ensino padrão em Harvard.

Numa dada situação, o que deve fazer um profissional? Esta é a questão que enfrentamos no método do caso, um método de aprendizagem orientado para a ação.

Ao longo do Curso, os estudantes serão confrontados com múltiplos casos da vida real. Terão de integrar todo o seu conhecimento, investigar, argumentar e defender as suas ideias e decisões.

Relearning Methodology

A TECH combina eficazmente a metodologia do Estudo de Caso com um sistema de aprendizagem 100% online baseado na repetição, que combina elementos didáticos diferentes em cada lição.

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

Em 2019 alcançámos os melhores resultados de aprendizagem de todas as universidades online de língua espanhola do mundo.

Na TECH aprenderá com uma metodologia de vanguarda concebida para formar os gestores do futuro. Este método, pioneiro na pedagogia mundial, chama-se Relearning.

A nossa universidade é a única licenciada para utilizar este método de sucesso. Em 2019, conseguimos melhorar os níveis globais de satisfação dos nossos estudantes (qualidade de ensino, qualidade dos materiais, estrutura dos cursos, objetivos...) no que diz respeito aos indicadores da melhor universidade online em espanhol.



No nosso Curso, a aprendizagem não é um processo linear, mas acontece numa espiral (aprender, desaprender, esquecer e reaprender). Por isso, combinamos cada um destes elementos de forma concêntrica. Com esta metodologia formamos mais de 650.000 alunos com um sucesso sem precedentes em áreas tão diversas como Bioquímica, Genética, Cirurgia, Direito Internacional, Competências de Gestão, Ciências Desportivas, Filosofia, Direito, Engenharias, Jornalismo, História ou Mercados e Instrumentos Financeiros. Tudo isto num ambiente altamente exigente, com um corpo estudantil universitário com um elevado perfil socioeconómico e uma idade média de 43,5 anos.

O Relearning permitir-lhe-á aprender com menos esforço e mais desempenho, envolvendo-o mais na sua capacitação, desenvolvendo um espírito crítico, defendendo argumentos e opiniões contrastantes: uma equação direta ao sucesso.

A partir da última evidência científica no campo da neurociência, não só sabemos como organizar informação, ideias, imagens e memórias, mas sabemos que o lugar e o contexto em que aprendemos algo é fundamental para a nossa capacidade de o recordar e armazenar no hipocampo, para o reter na nossa memória a longo prazo.

Desta forma, e no que se chama Neurocognitive context-dependent e-learning, os diferentes elementos da nossa capacitação estão ligados ao contexto em que o participante desenvolve a sua prática profissional.

Este Curso de Especialização oferece o melhor material didático, cuidadosamente preparado para os profissionais:



Material de estudo

Todos os conteúdos didáticos são criados especificamente para o Curso, pelos especialistas que o irão lecionar, de modo a que o desenvolvimento didático seja realmente específico e concreto.

Estes conteúdos são depois colocados em formato audiovisual, para criar o método de trabalho online da TECH. Tudo isto, com as mais recentes técnicas, que oferecem componentes de alta-qualidade em cada um dos materiais colocados à disposição do aluno.



Masterclasses

Existe evidência científica acerca da utilidade da observação por especialistas terceiros.

O que se designa de Learning from an Expert fortalece o conhecimento e a recordação, e constrói a confiança em futuras decisões difíceis.




Estágios de aptidões e competências


Exercerão atividades para desenvolver competências e aptidões específicas em cada área temática. Práticas e dinâmicas para adquirir e desenvolver as competências e capacidades que um especialista deve desenvolver no quadro da globalização em que vivemos.



Leituras complementares

Artigos recentes, documentos de consenso e guias internacionais, entre outros. Na biblioteca virtual da TECH, o aluno terá acesso a tudo o que precisa para completar a sua especialização.



**Case studies**

Completarão uma seleção dos melhores estudos de caso escolhidos especificamente para esta certificação. Casos apresentados, analisados e instruídos pelos melhores especialistas do panorama internacional.

**Resumos interativos**

A equipa da TECH apresenta os conteúdos, de forma atrativa e dinâmica, em formato multimédia, que incluem áudios, vídeos, imagens, diagramas e mapas conceituais, a fim de reforçar o conhecimento.

Este sistema educativo único para a apresentação de conteúdos multimédia foi premiado pela Microsoft como um "Caso de Sucesso Europeu".

**Testing & Retesting**

Os conhecimentos do aluno são periodicamente avaliados e reavaliados ao longo do Curso, por meio de atividades e exercícios de avaliação e autoavaliação, para que o aluno possa verificar o cumprimento dos seus objetivos.



07

Certificação

O Mestrado Próprio em Formação Contínua Inteligência Artificial no Departamento Financeiro garante, para além de um conteúdo mais rigoroso e atualizado, o acesso a um grau de de Formação Contínua emitido pela TECH Global University.



“

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

Este programa permitirá a obtenção do certificado do **Mestrado Próprio em Formação Contínua Inteligência Artificial no Departamento Financeiro** reconhecido pela **TECH Global University**, a maior universidade digital do mundo

A **TECH Global University**, é uma Universidade Europeia Oficial reconhecida publicamente pelo Governo de Andorra ([boletim oficial](#)). Andorra faz parte do Espaço Europeu de Educação Superior (EEES) desde 2003. O EEES é uma iniciativa promovida pela União Europeia com o objetivo de organizar o modelo de formação internacional e harmonizar os sistemas de ensino superior dos países membros desse espaço. O projeto promove valores comuns, a implementação de ferramentas conjuntas e o fortalecimento de seus mecanismos de garantia de qualidade para fomentar a colaboração e a mobilidade entre alunos, pesquisadores e académicos.


Esse título próprio da **TECH Global University**, é um programa europeu de formação contínua e atualização profissional que garante a aquisição de competências na sua área de conhecimento, conferindo um alto valor curricular ao aluno que conclui o programa.

Certificação: **Mestrado Próprio em Formação Contínua Inteligência Artificial no Departamento Financeiro**

Modalidade: **online**

Duração: **7 meses**

Créditos: **90 ECTS**



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



Mestrado Próprio
Inteligência Artificial no
Departamento Financeiro

- » Modalidade: Online
- » Duração: 7 meses
- » Certificação: TECH Global University
- » Acreditação: 90 ECTS
- » Horário: Ao seu próprio ritmo
- » Exames: Online

Mestrado Próprio

Inteligência Artificial no Departamento Financeiro