

Mestrado

Inteligência Artificial na Bolsa e Mercados Financeiros



Mestrado

Inteligência Artificial na Bolsa e Mercados Financeiros

- » Modalidade: Online
- » Duração: 12 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/mestrado-inteligencia-artificial-bolsa-mercados-financeiros

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 (IA) está a transformar radicalmente o mundo da bolsa e os mercados financeiros, introduzindo novas formas de análise e de tomada de decisões. De facto, os algoritmos de IA, impulsionados pela aprendizagem automática e pelo processamento de grandes volumes de dados, permitem aos investidores fazer previsões mais exactas sobre as tendências do mercado e detetar oportunidades que poderiam passar despercebidas aos analistas humanos. Neste contexto, a TECH desenvolveu um programa completamente virtual, que se adapta aos horários individuais e de trabalho dos alunos. Também utiliza uma metodologia de aprendizagem inovadora conhecida como *Relearning*, que é único nesta universidade.



“

Com este Mestrado 100% online, compreenderá como a IA pode transformar a análise técnica e fundamental, otimizando as decisões de investimento com uma precisão que desafia a intuição humana”

A utilização da Inteligência Artificial (IA) nas finanças intensificou-se com o desenvolvimento de algoritmos avançados de *Machine Learning*, que optimizam as estratégias de investimento e a análise de risco. As instituições financeiras estão a adotar a IA para automatizar operações, detetar fraudes em tempo real e personalizar recomendações de investimento para os seus clientes.

Assim nasceu este Mestrado, que permitirá compreender de forma sólida a aplicação de técnicas avançadas de Inteligência Artificial para a análise técnica dos mercados. Assim, os profissionais poderão utilizar ferramentas modernas para a visualização e automatização de indicadores técnicos, bem como implementar modelos sofisticados, tais como redes neurais convolucionais para o reconhecimento de padrões financeiros.

Além disso, os especialistas familiarizar-se-ão com técnicas de *Machine Learning* e *Deep Learning*, bem como com o processamento de linguagem natural (PLN) para analisar demonstrações financeiras e outros documentos relevantes. Serão igualmente abordadas as metodologias de avaliação do risco e do crédito, a análise da sustentabilidade ESG e a deteção de fraudes financeiras.

Por último, será abordado o tratamento de grandes volumes de dados financeiros, a manipulação e a análise do *Big Data* com ferramentas avançadas, como o Hadoop e Spark. Além disso, serão exploradas a integração, a limpeza e a visualização de dados, bem como a segurança e a privacidade no tratamento de informações financeiras. Serão analisadas estratégias de *trading* algorítmico, incluindo a conceção e otimização de sistemas automatizados e a gestão de riscos.

Desta forma, a TECH criou um programa universitário pormenorizado e totalmente online, que facilita o acesso dos alunos aos materiais didáticos através de qualquer dispositivo eletrónico com ligação à Internet. Isto elimina a necessidade de se deslocar a um local físico e de se adaptar a um horário específico. Além disso, integra a revolucionária metodologia *Relearning*, que se baseia na repetição de conceitos essenciais para melhorar a compreensão dos conteúdos.

Este **Mestrado em Inteligência Artificial na Bolsa e Mercados Financeiros** conta com o conteúdo educativo mais completo e atualizado do mercado. As suas principais características são:

- ♦ O desenvolvimento de estudos de caso apresentados por especialistas em Inteligência Artificial centrados na Bolsa de Valores e nos Mercados Financeiros
- ♦ Os conteúdos gráficos, esquemáticos e predominantemente práticos com que está concebido fornecem informações práticas sobre as disciplinas que são essenciais para a atividade 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 ao conteúdo a partir de qualquer dispositivo fixo ou portátil com ligação à Internet



Será capaz de lidar e analisar grandes volumes de dados financeiros, conceber estratégias de negociação algorítmicas eficazes e lidar com questões éticas e regulamentares complexas.

“

Irá explorar métodos avançados como a aprendizagem por reforço para a negociação algorítmica e a modelização de séries temporais com LSTM, graças a uma extensa biblioteca de recursos multimédia inovadores”

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.

Terá a capacidade de realizar análises precisas e eficientes num ambiente de crescente complexidade e dinâmica dos mercados financeiros, através dos melhores materiais didácticos, na vanguarda da tecnologia e da educação.

Abordará a ética e a regulamentação na utilização da IA nas finanças, preparando-o para enfrentar os desafios éticos e regulamentares, bem como para desenvolver tecnologias de forma responsável no sector financeiro.



02

Objetivos

O programa dotará os profissionais das competências necessárias para aplicar técnicas avançadas de *Machine Learning* e *Deep Learning* na análise técnica e fundamental, otimizando as estratégias de investimento e *trading*. Centrar-se-á também no desenvolvimento de competências para tratar e processar grandes volumes de dados financeiros, conceber e avaliar sistemas de *trading* algorítmico e abordar questões éticas e regulamentares relacionadas com a aplicação da IA nas finanças. Neste contexto, os especialistas estarão preparados para enfrentar os desafios e tirar partido das oportunidades oferecidas pela IA num ambiente financeiro em constante mudança.



“

O principal objetivo deste Mestrado é formar profissionais altamente qualificados para integrar a Inteligência Artificial na análise e gestão dos mercados financeiros. Do que está à espera para se inscrever?"



Objetivos gerais

- ♦ Compreender os fundamentos teóricos da Inteligência Artificial
- ♦ Estudar os diferentes tipos de dados e compreender o ciclo de vida dos dados
- ♦ Avaliar o papel crucial dos dados no desenvolvimento e implementação de soluções de Inteligência Artificial
- ♦ Aprofundar a compreensão dos algoritmos e da complexidade para resolver problemas específicos
- ♦ Explorar a base teórica das redes neurais para o desenvolvimento da *Deep Learning*
- ♦ Explorar a computação bioinspirada e a sua relevância para o desenvolvimento de sistemas inteligentes
- ♦ Desenvolver competências para aplicar técnicas avançadas de Inteligência Artificial na análise técnica e fundamental dos mercados financeiros incluindo a utilização de *Machine Learning*, *Deep Learning* e NLP
- ♦ Permitir aos estudantes conceber, implementar e otimizar estratégias de trading algorítmico, utilizando técnicas de *Reinforcement Learning* e *Machine Learning* para melhorar a eficiência e a rentabilidade dos mercados financeiros
- ♦ Adquirir competências no domínio do tratamento e análise de grandes volumes de dados financeiros utilizando tecnologias de *Big Data*, como Hadoop e Spark
- ♦ Fomentar a capacidade de criar e aplicar modelos de IA que sejam explicáveis e transparentes, garantindo que as decisões financeiras baseadas na IA são compreensíveis e justificáveis
- ♦ Desenvolver uma compreensão aprofundada dos desafios éticos e regulamentares associados à utilização da Inteligência Artificial nas finanças
- ♦ Dotar os estudantes das ferramentas e dos conhecimentos necessários para desenvolver soluções financeiras inovadoras que integrem a Inteligência Artificial
- ♦ Criar modelos preditivos utilizando *Machine Learning*, como LSTMs e modelos de séries temporais, para antecipar os movimentos do mercado e melhorar a tomada de decisões de investimento
- ♦ Desenvolver competências na otimização de carteiras e na gestão de riscos financeiros utilizando algoritmos genéticos e outras técnicas avançadas de Inteligência Artificial, para maximizar o rendimento e minimizar o risco nos investimentos
- ♦ Fornecer as ferramentas e técnicas necessárias para implementar e otimizar estratégias de negociação de alta frequência utilizando modelos de aprendizagem automática para melhorar a velocidade e a precisão da execução de ordens
- ♦ Aplicar as tecnologias de IA nas finanças de uma forma ética e responsável, incorporando considerações de equidade, transparência e privacidade nas suas soluções



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 neurais 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

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 seleccioná-las adequadamente

- ♦ Compreender a ligação eficaz de camadas e operações para conceber arquiteturas de redes neuronais complexas e eficientes
- ♦ Utilizar treinadores e optimizadores 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 optimizadores 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 neuronais 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 treino 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 tfdata 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
- ♦ Explorar 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
- ♦ Explorar 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. Análise técnica dos mercados financeiros com IA

- Desenvolver a capacidade de visualizar e otimizar indicadores técnicos utilizando ferramentas como Plotly, Dash e Scikit-learn, permitindo uma tomada de decisão mais informada na análise técnica dos mercados financeiros
- Implementar Redes Neurais Convolucionais (CNN) para reconhecimento de padrões em dados financeiros, melhorando a precisão na identificação de oportunidades de *trading*
- Adquirir competências na conceção e optimização de estratégias de *Reinforcement Learning* com *TensorFlow*, centradas na maximização da rentabilidade

Módulo 17. Análise fundamental dos mercados financeiros com IA

- ♦ Aprender a modelar e a prever o desempenho financeiro das empresas utilizando técnicas de *Machine Learning* e *Deep Learning*, facilitando decisões de investimento baseadas em dados
- ♦ Aplicar técnicas de Processamento de Linguagem Natural (PNL), como o ChatGPT, para analisar e extrair informações relevantes das demonstrações financeiras, melhorando a avaliação da saúde financeira das empresas
- ♦ Desenvolver competências em matéria de deteção de fraudes financeiras e de avaliação dos riscos através da utilização de *Machine Learning*, garantindo maior segurança e exatidão nas decisões financeiras

Módulo 18. Processamento de dados financeiros em grande escala

- ♦ Dominar a utilização das tecnologias de *Big Data*, como o Hadoop e o Spark, para o armazenamento e processamento de grandes volumes de dados financeiros, otimizando a análise e a tomada de decisões
- ♦ Implementar ferramentas e técnicas para o processamento em tempo real de dados financeiros, permitindo respostas rápidas e eficazes às flutuações do mercado
- ♦ Aplicar as melhores práticas para garantir a segurança e a privacidade dos dados financeiros, assegurando a conformidade com os regulamentos do sector



Módulo 19. Estratégias de *Trading* Algorítmico

- ♦ Adquirir as competências necessárias para conceber e desenvolver sistemas de trading automatizados, integrando técnicas de *Machine Learning* para melhorar a eficiência e a eficácia das operações
- ♦ Aprender a avaliar e otimizar estratégias de *trading* utilizando técnicas avançadas como o *backtesting* e *Machine Learning*, com o objetivo de maximizar o desempenho nos mercados financeiros
- ♦ Desenvolver um conhecimento profundo das técnicas de gestão do risco aplicadas ao trading algorítmico, garantindo que as estratégias são rentáveis e seguras.

Módulo 20. Aspectos éticos e regulamentares da IA nas finanças

- ♦ Explorar os desafios éticos associados à utilização da Inteligência Artificial nas finanças, incluindo a transparência, a explicabilidade e a equidade nos modelos financeiros
- ♦ Compreender as regulamentações globais que afectam a utilização da IA nos mercados financeiros e saiba como desenvolver soluções que cumpram estes requisitos.
- ♦ Promover uma cultura de desenvolvimento responsável, integrando práticas que garantam que as tecnologias de IA são utilizadas de forma ética, segura e em benefício do bem-estar económico e social

03

Competências

Os profissionais irão adquirir competências avançadas na análise e visualização de dados utilizando ferramentas de Inteligência Artificial, interpretando grandes volumes de informação financeira de forma precisa e eficiente. Serão também especializados na concepção e implementação de estratégias de negociação algorítmicas, otimizando as decisões de investimento através de *Machine Learning* e *Deep Learning*. Além disso, será reforçada a capacidade de avaliar os riscos e as oportunidades no contexto da análise fundamental, bem como de enfrentar os desafios éticos e regulamentares relacionados com a utilização da IA.




“


Estará equipado para liderar a transformação digital nos mercados financeiros, fornecendo soluções inovadoras e estratégicas num ambiente altamente competitivo. Com todas as garantias de qualidade da TECH!



Competências gerais

- Dominar as técnicas de mineração de dados, incluindo a seleção, o pré-processamento e a transformação de dados complexos
- Conceber e desenvolver sistemas inteligentes capazes de aprender e de se adaptar a ambientes em mudança
- Controlar as ferramentas de aprendizagem automática e a sua aplicação na mineração de dados para a tomada de decisões
- Utilizar *Autoencoders*, *GANs* e Modelos de Difusão para resolver desafios específicos em Inteligência Artificial
- Implementar uma rede codificadora-descodificadora para tradução automática neuronal
- Aplicar os princípios fundamentais das redes neuronais na resolução de problemas específicos
- Conceber e aplicar estratégias de *trading* algorítmico utilizando *Machine Learning* e *Deep Learning*
- Efetuar análises preditivas de séries cronológicas financeiras utilizando modelos LSTM e técnicas avançadas de IA
- Otimizar as carteiras de investimento através da aplicação de algoritmos genéticos para equilibrar o risco e o rendimento
- Detetar e prevenir fraudes financeiras através da utilização de modelos de Inteligência Artificial, melhorando a segurança das transacções





Competências específicas

- Aplicação de técnicas e estratégias de IA para melhorar a eficiência no setor do retalho
- Aprofundar a compreensão e a aplicação dos algoritmos genéticos
- Implementar técnicas de redução de ruído utilizando codificadores automáticos
- Criar eficazmente conjuntos de dados de treino para tarefas de processamento de linguagem natural (PLN)
- Executar camadas de agrupamento e a sua utilização em modelos de *Deep Computer Vision* com o Keras
- Utilizar funções e gráficos TensorFlow para otimizar o desempenho de modelos personalizados
- Melhorar o desenvolvimento e a aplicação de *chatbots* e assistentes virtuais, compreendendo o seu funcionamento e potenciais aplicações
- Dominar a reutilização de camadas pré-treinadas para otimizar e acelerar o processo de treino
- Construir a primeira rede neural, aplicando na prática os conceitos aprendidos
- Ativar o Perceptron Multicamadas (MLP) usando a biblioteca Keras
- Aplicar técnicas de exploração e pré-processamento de dados, identificando e preparando os dados para uma utilização efectiva em modelos de aprendizagem automática
- Implementar estratégias eficazes para tratar valores em falta em conjuntos de dados, aplicando métodos de imputação ou eliminação sensíveis ao contexto
- Investigar linguagens e software para a criação de ontologias, utilizando ferramentas específicas para o desenvolvimento de modelos semânticos
- Desenvolver técnicas de limpeza de dados para garantir a qualidade e a exatidão da informação utilizada nas análises posteriores
- Analisar demonstrações financeiras com Processamento de Linguagem Natural (PNL) para extrair informações valiosas e efetuar avaliações precisas das empresas
- Gerir e processar grandes volumes de dados financeiros utilizando ferramentas de *Big Data* como Hadoop e Spark
- Desenvolver e avaliar estratégias para *Trading* de alta frequência (HFT), otimizando a velocidade e a rapidez e precisão na execução dos comandos
- Aplicar técnicas de Inteligência Artificial Explicável (XAI) para garantir a transparência e a compreensão dos modelos utilizados nas finanças
- Cumprir as normas éticas e regulamentares na implementação da IA no sector financeiro, assegurando práticas responsáveis e conformes com a lei
- Visualizar dados financeiros de forma avançada com ferramentas como Plotly e Dash, facilitando a tomada de decisões informadas



Aposte na TECH! Adquirirá competências no tratamento de grandes volumes de dados, utilizando tecnologias como o Hadoop e o Spark para processar e visualizar informações de forma eficiente”

04

Direção do curso

O corpo docente deste programa universitário é composto por profissionais de renome no domínio das finanças e da tecnologia. De facto, são especialistas com uma vasta experiência na utilização da Inteligência Artificial aplicada aos mercados financeiros, combinando experiência prática e académica. Assim, os seus conhecimentos aprofundados vão da análise técnica e fundamental ao desenvolvimento de estratégias de negociação algorítmicas e à gestão de *Big Data*. Além disso, estão a par das últimas tendências e desenvolvimentos no sector, o que garantirá que os alunos recebam uma formação relevante e pertinente.



“

A experiência e os conhecimentos dos professores enriquecerão a aprendizagem, proporcionando aos alunos perspectivas e ligações valiosas no âmbito do sector financeiro mundial”

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. Rodrigo Sánchez Mansilla

- ♦ *Digital Advisor* na AI Shepherds GmbH
- ♦ *Digital Account Manager* na Kill Draper
- ♦ *Head of Digital* na Kuarere
- ♦ *Digital Marketing Manager* na Arconi Solutions, Deltoid Energy e Brinergy Tech
- ♦ *Founder and National Sales and Marketing Manager*
- ♦ Mestrado em Marketing Digital (MDM) pela The Power Business School
- ♦ Licenciado em Administração de Empresas (BBA) pela Universidade de Buenos Aires

“Aproveite a oportunidade para conhecer os últimos desenvolvimentos neste domínio e aplicá-los à sua prática quotidiana”

05

Estrutura e conteúdo

Esta capacitação acadêmica oferecerá um conteúdo abrangente, concebido para abordar as complexidades do ambiente financeiro moderno através da utilização avançada de tecnologias de IA. Os especialistas irão explorar a análise técnica e fundamental dos mercados financeiros, aplicando ferramentas de *Machine Learning* e *Deep Learning* para otimizar as decisões de investimento e as estratégias de negociação. Serão também abordadas técnicas de processamento e visualização de grandes volumes de dados, bem como o desenvolvimento e implementação de sistemas algorítmicos de alta frequência.



“

Centrar-se-á em questões críticas como a ética e a regulamentação na utilização da IA nas finanças, preparando-o para gerir desafios éticos e regulamentares, com a melhor universidade digital do mundo, de acordo com a Forbes: a TECH”

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 Neurais
 - 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. Controlo 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. Utilizar de ferramentas do *TensorFlow* para a manipulação de dados
- 10.6. A API *tfdata*
 - 10.6.1. Utilização da API *tfdata* para o processamento de dados
 - 10.6.2. Construção de fluxo de dados com *tfdata*
 - 10.6.3. Utilização da API *tfdata* 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 *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 neurais
- 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 neuronais 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 neuronais 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

- 15.2. 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. Análise técnica dos mercados financeiros com IA

- 16.1. Análise e visualização de indicadores técnicos com Plotly e Dash
 - 16.1.1. Implementação de gráficos interactivos com Plotly
 - 16.1.2. Visualização avançada de séries cronológicas com Matplotlib
 - 16.1.3. Criação de *dashboards* dinâmica em tempo real com o Dash
- 16.2. Otimização e automatização de indicadores técnicos com Scikit-learn
 - 16.2.1. Automatização de indicadores com Scikit-learn
 - 16.2.2. Otimização dos indicadores técnicos
 - 16.2.3. Criar indicadores personalizados com o Keras
- 16.3. Reconhecimento de padrões financeiros com CNN
 - 16.3.1. Utilizar a CNN no TensorFlow para identificar padrões em grafos
 - 16.3.2. Melhora de modelos de reconhecimento com *Transfer Learning*
 - 16.3.3. Validação de modelos de reconhecimento em mercados em tempo real
- 16.4. Estratégias para *trading* quantitativo com o QuantConnect
 - 16.4.1. Construção de sistemas de *trading* algorítmicos com QuantConnect
 - 16.4.2. *Backtesting* de estratégias com o QuantConnect
 - 16.4.3. Integração de *Machine Learning* em estratégias para *trading* com QuantConnect
- 16.5. Trading algorítmico com *Reinforcement Learning* usando TensorFlow
 - 16.5.1. Aprendizagem por reforço para *trading*
 - 16.5.2. Criação de agentes de *trading* com TensorFlow *Reinforcement Learning*
 - 16.5.3. Simulação e ajustamento de agentes no OpenAI Gym
- 16.6. Modelação de séries temporais com LSTM em Keras para previsão de preços
 - 16.6.1. Aplicação de LSTM para previsão de preços
 - 16.6.2. Implementação de modelos LSTM para séries cronológicas financeiras em Keras
 - 16.6.3. Otimização e ajuste de parâmetros em modelos de séries temporais

- 16.7. Aplicação da Inteligência Artificial Explicável (XAI) nas finanças
 - 16.7.1. Aplicação da XAI no sector financeiro
 - 16.7.2. Aplicação do LIME a modelos de *trading*
 - 16.7.3. Utilização do SHAP para análise da contribuição de características em decisões de IA
- 16.8. *High-Frequency Trading* (HFT) optimizado com modelos de *Machine Learning*
 - 16.8.1. Desenvolvimento de modelos ML para HFT
 - 16.8.2. Implementação de estratégias HFT com TensorFlow
 - 16.8.3. Simulação e avaliação de HFT em ambientes controlados
- 16.9. Análise de volatilidade utilizando *Machine Learning*
 - 16.9.1. Aplicação de modelos inteligentes para prever a volatilidade
 - 16.9.2. Implementação de modelos de volatilidade com PyTorch
 - 16.9.3. Integração da análise da volatilidade na gestão do risco da carteira
- 16.10. Otimização de carteiras com algoritmos genéticos
 - 16.10.1. Fundamentos dos algoritmos genéticos para a otimização dos investimentos nos mercados
 - 16.10.2. Implementação de algoritmos genéticos para a seleção de carteiras
 - 16.10.3. Avaliação das estratégias de otimização da carteira

Módulo 17. Análise fundamental dos mercados financeiros com IA

- 17.1. Modelação preditiva do desempenho financeiro com Scikit-Learn
 - 17.1.1. Regressão linear e logística para previsões financeiras com Scikit-Learn
 - 17.1.2. Utilizar redes neuronais com o TensorFlow para prever receitas e lucros
 - 17.1.3. Validação de modelos de previsão com *cross-validation* utilizando Scikit-Learn
- 17.2. Avaliação de empresas com *deep learning*
 - 17.2.1. Automatização do modelo de fluxo de caixa descontado (DCF) com TensorFlow
 - 17.2.2. Modelos de avaliação avançados utilizando PyTorch
 - 17.2.3. Integração e análise de modelos de avaliação múltipla com Pandas
- 17.3. Análise de demonstrações financeiras com PNL via ChatGPT
 - 17.3.1. Extração de informações essenciais dos relatórios anuais com o ChatGPT
 - 17.3.2. Análise de sentimento em relatórios de analistas e notícias financeiras com ChatGPT
 - 17.3.3. Implementação de modelos de PNL com Chat GPT para a interpretação de textos financeiros

- 17.4. Análise de risco e de crédito com *Machine Learning*
 - 17.4.1. Modelos de pontuação de crédito utilizando SVM e árvores de decisão no Scikit-Learn
 - 17.4.2. Análise do risco de crédito de empresas e obrigações com TensorFlow
 - 17.4.3. Visualizar dados de risco com o Tableau
- 17.5. Análise de crédito com Scikit-Learn
 - 17.5.1. Implementação de modelos de *Scoring* de créditos
 - 17.5.2. Análise do risco de crédito com RandomForest em Scikit-Learn
 - 17.5.3. Visualização avançada dos resultados do crédito com o Tableau
- 17.6. Avaliação da sustentabilidade ESG utilizando *Data Mining*
 - 17.6.1. Métodos de extração de dados ESG
 - 17.6.2. Modelação do impacto ESG com técnicas de regressão
 - 17.6.3. Aplicações da análise ESG nas decisões de investimento
- 17.7. Avaliação comparativa do sector com Inteligência Artificial utilizando TensorFlow e Power BI
 - 17.7.1. Avaliação comparativa das empresas que utilizam a AI
 - 17.7.2. Modelação preditiva do desempenho setorial com TensorFlow
 - 17.7.3. Implementação de *dashboards* sectoriais com o Power BI
- 17.8. Gestão de carteiras com otimização por IA
 - 17.8.1. Otimização da carteira
 - 17.8.2. Uso de técnicas de *Machine Learning* para otimização de carteiras com Scikit-Optimize
 - 17.8.3. Implementação e avaliação da eficácia dos algoritmos na gestão de carteiras
- 17.9. Detecção de fraudes financeiras com IA utilizando TensorFlow e Keras
 - 17.9.1. Conceitos e técnicas básicos de deteção de fraudes com IA
 - 17.9.2. Construir modelos de deteção com redes neurais no TensorFlow
 - 17.9.3. Aplicação prática de sistemas de deteção de fraudes em transacções financeiras
- 17.10. Análise e modelação de fusões e aquisições com IA
 - 17.10.1. Utilizar modelos preditivos de IA para avaliar fusões e aquisições
 - 17.10.2. Simulação de cenários pós-fusão utilizando *Machine Learning*
 - 17.10.3. Avaliar o impacto financeiro das fusões e aquisições com modelos inteligentes

Módulo 18. Processamento de dados financeiros em grande escala

- 18.1. *Big Data* no contexto financeiro
 - 18.1.1. Principais características do *Big Data* em finanças
 - 18.1.2. Importância dos 5 Vs (Volume, Velocidade, Variedade, Veracidade, Valor) nos dados financeiros
 - 18.1.3. Casos de uso de *Big Data* em análise de risco e conformidade
- 18.2. Tecnologias de armazenamento e gestão de grandes volumes de dados financeiros
 - 18.2.1. Sistemas de bases de dados NoSQL para armazenamento financeiro
 - 18.2.2. Uso de *Data Warehouses* e *Data Lakes* no setor financeiro
 - 18.2.3. Comparativa entre soluções *on-premise* e baseadas na nuvem
- 18.3. Ferramentas de processamento em tempo real para dados financeiros
 - 18.3.1. Introdução a ferramentas como o Apache Kafka e o Apache Storm
 - 18.3.2. Aplicações de processamento em tempo real para deteção de fraudes
 - 18.3.3. Vantagens do processamento em tempo real em *trading* algorítmico
- 18.4. Integração e limpeza de dados nas finanças
 - 18.4.1. Métodos e ferramentas para integrar dados de várias fontes
 - 18.4.2. Técnicas de limpeza de dados para garantir a qualidade e a exatidão
 - 18.4.3. Desafios na normalização dos dados financeiros
- 18.5. Técnicas de extração de dados aplicadas aos mercados financeiros
 - 18.5.1. Algoritmos de classificação e previsão em dados de mercado
 - 18.5.2. Análise do sentimento nas redes sociais para prever os movimentos do mercado
 - 18.5.3. Extração de dados para identificar padrões de *trading* e o comportamento dos investidores
- 18.6. Visualização avançada de dados para análise financeira
 - 18.6.1. Ferramentas e software de visualização de dados financeiros
 - 18.6.2. Conceção de painéis de controlo interactivos para acompanhar os mercados
 - 18.6.3. O papel da visualização na comunicação da análise de risco
- 18.7. Utilização do Hadoop e dos ecossistemas conexos no sector financeiro
 - 18.7.1. Principais componentes do ecossistema Hadoop e sua aplicação no sector financeiro
 - 18.7.2. Casos de utilização do Hadoop para análise de transacções de grande volume
 - 18.7.3. Benefícios e desafios da integração do Hadoop nas infra-estruturas financeiras existentes

- 18.8. Aplicações Spark na análise financeira
 - 18.8.1. Spark para análise de dados em tempo real e em lote
 - 18.8.2. Criação de modelos preditivos utilizando Spark MLlib
 - 18.8.3. Integração do Spark com outras ferramentas de Big Data no sector financeiro
- 18.9. Segurança e privacidade dos dados no sector financeiro
 - 18.9.1. Regras e regulamentos de proteção de dados (RGPD, CCPA)
 - 18.9.2. Estratégias de encriptação e gestão de acesso para dados sensíveis
 - 18.9.3. Impacto das violações de dados nas instituições financeiras
- 18.10. O impacto da computação em nuvem na análise financeira em grande escala
 - 18.10.1. Vantagens da nuvem para a escalabilidade e eficiência da análise financeira
 - 18.10.2. Comparação de fornecedores de serviços em nuvem e dos seus serviços específicos para o sector financeiro
 - 18.10.3. Estudos de caso sobre a migração para a nuvem em grandes instituições financeiras

Módulo 19. Estratégias de *Trading* Algorítmico

- 19.1. Fundamentos do *trading* algorítmico
 - 19.1.1. Estratégias de *trading* algorítmico
 - 19.1.2. Tecnologias e plataformas essenciais para o desenvolvimento de *trading*
 - 19.1.3. Vantagens e desafios do *trading* automatizado versus negociação manual
- 19.2. Conceção de sistemas para *trading* automatizado
 - 19.2.1. Estrutura e componentes de um sistema de negociação automatizado
 - 19.2.2. Programação de algoritmos: da ideia à implementação
 - 19.2.3. Considerações sobre latência e hardware em sistemas de negociação
- 19.3. Backtesting e avaliação de *trading*
 - 19.3.1. Metodologias para um *backtesting* eficaz de estratégias algorítmicas
 - 19.3.2. A importância dos dados históricos de qualidade no *backtesting*
 - 19.3.3. Indicadores-chave de desempenho a avaliar estratégias de *trading*
- 19.4. Otimização de estratégias com *Machine Learning*
 - 19.4.1. Aplicação de técnicas de aprendizagem supervisionada na melhoria das estratégias
 - 19.4.2. Utilização da otimização por enxame de partículas e de algoritmos genéticos
 - 19.4.3. Desafios do sobreajuste na otimização de *trading*

- 19.5. *Trading* de Alta Frequência (HFT)
 - 19.5.1. Princípios e tecnologias subjacentes aos HFT
 - 19.5.2. Impacto das HFT na liquidez e volatilidade do mercado
 - 19.5.3. Estratégias comuns de HFT e sua eficácia
- 19.6. Algoritmos de execução de ordens
 - 19.6.1. Tipos de algoritmos de implementação e sua aplicação prática
 - 19.6.2. Algoritmos para minimizar o impacto no mercado
 - 19.6.3. Utilização de simulações para melhorar a execução das ordens
- 19.7. Estratégias de arbitragem nos mercados financeiros
 - 19.7.1. Arbitragem estatística e fixação do preço das concentrações nos mercados
 - 19.7.2. Arbitragem de índices e ETFs
 - 19.7.3. Desafios técnicos e jurídicos da arbitragem no *trading* moderno
- 19.8. Gestão do risco na negociação algorítmica
 - 19.8.1. Medidas de risco na *negociação* algorítmica
 - 19.8.2. Integração de limites de risco e de stop-loss nos algoritmos
 - 19.8.3. Riscos específicos do *trading* algorítmico e como mitigá-los
- 19.9. Aspectos regulamentares e conformidade em *trading* algorítmico
 - 19.9.1. Regulamentos globais que afectam o *trading* algorítmico
 - 19.9.2. Conformidade regulamentar e elaboração de relatórios num ambiente automatizado
 - 19.9.3. Implicações éticas do *trading* automatizado
- 19.10. Futuro do *trading* algorítmico e tendências emergentes
 - 19.10.1. O impacto da Inteligência Artificial no desenvolvimento futuro do *trading* algorítmico
 - 19.10.2. Novas tecnologias *Blockchain* e sua aplicação no *trading* algorítmico
 - 19.10.3. Tendências na adaptabilidade e personalização de algoritmos de *trading*

Módulo 20. Aspectos éticos e regulamentares da IA nas finanças

- 20.1. Ética na Inteligência Artificial aplicada às finanças
 - 20.1.1. Princípios éticos fundamentais para o desenvolvimento e utilização da IA nas finanças
 - 20.1.2. Estudos de caso sobre dilemas éticos em aplicações de IA financeira
 - 20.1.3. Desenvolver códigos de conduta éticos para os profissionais das tecnologias financeiras
- 20.2. Regulamentos globais que afectam a utilização da IA nos mercados financeiros
 - 20.2.1. Panorâmica dos principais regulamentos financeiros internacionais sobre a IA
 - 20.2.2. Comparação das políticas de regulamentação da IA entre jurisdições
 - 20.2.3. Implicações da regulamentação da IA para a inovação financeira

- 20.3. Transparência e explicabilidade dos modelos de IA no sector financeiro
 - 20.3.1. A importância da transparência nos algoritmos de IA para a confiança dos utilizadores
 - 20.3.2. Técnicas e ferramentas para melhorar a explicabilidade dos modelos de IA
 - 20.3.3. Desafios da implementação de modelos interpretáveis em ambientes financeiros complexos
- 20.4. Gestão dos riscos e conformidade ética na utilização da IA
 - 20.4.1. Estratégias de atenuação dos riscos associadas à implantação da IA no sector financeiro
 - 20.4.2. Conformidade ética no desenvolvimento e aplicação de tecnologias de IA
 - 20.4.3. Supervisão ética e auditorias de sistemas de IA em operações financeiras
- 20.5. Impacto social e económico da IA nos mercados financeiros
 - 20.5.1. Efeitos da IA na estabilidade e eficiência dos mercados financeiros
 - 20.5.2. A IA e o seu impacto no emprego e nas competências profissionais no sector financeiro
 - 20.5.3. Benefícios sociais e riscos da automatização financeira em grande escala
- 20.6. Privacidade e proteção de dados em aplicações de IA financeira
 - 20.6.1. Regulamentação da privacidade dos dados aplicável às tecnologias de IA no sector financeiro
 - 20.6.2. Técnicas de proteção de dados pessoais em sistemas financeiros baseados em IA
 - 20.6.3. Desafios na gestão de dados sensíveis em modelos preditivos e analíticos
- 20.7. Enviesamento algorítmico e equidade nos modelos financeiros da IA
 - 20.7.1. Identificação e atenuação de enviesamentos em algoritmos de IA financeira
 - 20.7.2. Estratégias para garantir a equidade nos modelos automáticos de tomada de decisões automática
 - 20.7.3. Impacto do enviesamento algorítmico na inclusão financeira e na equidade
- 20.8. Desafios da supervisão regulamentar na IA financeira
 - 20.8.1. Dificuldades de monitorização e controlo das tecnologias avançadas de IA
 - 20.8.2. Papel das autoridades financeiras na supervisão contínua da IA
 - 20.8.3. Necessidade de adaptação regulamentar face ao avanço da tecnologia de IA



- 20.9. Estratégias para o desenvolvimento responsável das tecnologias de IA no sector financeiro
 - 20.9.1. Melhores práticas para o desenvolvimento sustentável e responsável da IA no sector financeiro
 - 20.9.2. Iniciativas e *frameworks* para a avaliação ética dos projectos de IA no domínio financeiro
 - 20.9.3. Colaboração entre reguladores e empresas para promover práticas responsáveis
- 20.10. Futuro da regulamentação da IA no sector financeiro
 - 20.10.1. Tendências emergentes e desafios futuros na regulamentação da IA no sector financeiro
 - 20.10.2. Preparar os quadros jurídicos para as inovações disruptivas na tecnologia financeira
 - 20.10.3. Diálogo e cooperação internacionais para uma regulamentação eficaz e unificada da IA no sector financeiro


“Receberá uma formação sólida e actualizada, combinando teoria avançada com aplicações práticas para liderar na intersecção da Inteligência Artificial e das finanças”

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 em Inteligência Artificial na Bolsa e Mercados Financeiros garante, para além de um conteúdo mais rigoroso e atualizado, o acesso a uma certificação a título próprio emitida pela TECH Global University.



“

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

Este curso permitirá a obtenção do certificado do **Mestrado em Inteligência Artificial na Bolsa e Mercados Financeiros** reconhecido pela **TECH Global University**, a maior universidade digital do mundo

A **TECH Global University** é uma Universidade Europeia Oficial reconhecida 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 em Inteligência Artificial na Bolsa e Mercados Financeiros**

Modalidade: **online**

Duração: **12 meses**

Créditos: **90 ECTS**





Mestrado Inteligência Artificial na Bolsa e Mercados Financeiros

- » Modalidade: Online
- » Duração: 12 meses
- » Certificação: TECH Global University
- » Acreditação: 90 ECTS
- » Horário: Ao seu próprio ritmo
- » Exames: Online

Mestrado

Inteligência Artificial na Bolsa e Mercados Financeiros