

# Mestrado Próprio

Inteligência Artificial nas Bolsas de  
Valores e nos Mercados Financeiros



## Mestrado Próprio Inteligência Artificial nas Bolsas de Valores e nos Mercados Financeiros

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

Acesso ao site: [www.techtute.com/br/inteligencia-artificial/mestrado-proprio/mestrado-proprio-inteligencia-artificial-bolsas-valores-mercados-financeiros](http://www.techtute.com/br/inteligencia-artificial/mestrado-proprio/mestrado-proprio-inteligencia-artificial-bolsas-valores-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

Certificado

---

*pág. 52*

# 01

# Apresentação

A Inteligência Artificial (IA) está transformando radicalmente o mundo do mercado de ações e dos mercados financeiros, introduzindo novas formas de análise e tomada de decisões. De fato, os algoritmos de IA, impulsionados pela aprendizagem de máquinas e pelo processamento de grandes volumes de dados, permitem aos investidores fazer previsões mais precisas sobre as tendências do mercado e a identificar oportunidades que poderiam passar despercebidas aos analistas humanos. Neste contexto, a TECH desenvolveu um programa 100% virtual, que se adapta aos horários individuais e de trabalho dos graduados. Além disso, utiliza uma metodologia de aprendizagem inovadora conhecida como o *Relearning*, que é exclusiva desta universidade.



“

*Com este Mestrado Próprio 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 otimizam 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.

Este Mestrado Próprio proporcionará uma sólida compreensão de como aplicar técnicas avançadas de Inteligência Artificial à análise técnica dos mercados. Assim, os profissionais serão capazes de utilizar ferramentas modernas para a visualização e automatização de indicadores técnicos, bem como implementar modelos sofisticados, como redes neurais convolucionais para o reconhecimento de padrões financeiros.

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

Por último, será abordado o processamento de grandes volumes de dados financeiros, tratando e analisando *Big Data* com ferramentas avançadas, como 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. Ao mesmo tempo, serão analisadas as estratégias de *trading* algorítmica, incluindo a concessão e otimização de sistemas automatizados e gestão de riscos.

Dessa forma, a TECH desenvolveu um detalhado Mestrado Próprio totalmente online, que facilita aos graduados o acesso aos materiais educativos por meio de qualquer dispositivo eletrónico com conexão 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 Próprio em Inteligência Artificial nas Bolsas de Valores e nos Mercados Financeiros** conta com o conteúdo mais completo e atualizado do mercado. Suas principais características são:

- ♦ O desenvolvimento de estudos de caso apresentados por especialistas em Inteligência Artificial centrados na Bolsa de Valores e nos Mercados Financeiros
- ♦ Os conteúdos gráficos, esquemáticos e extremamente úteis fornecem informações práticas sobre as disciplinas indispensáveis para o exercício da profissão
- ♦ Contém exercícios práticos em que o processo de auto-avaliação é realizado para melhorar o aprendizado
- ♦ Destaque especial para as metodologias inovadoras
- ♦ Aulas teóricas, perguntas a especialistas, fóruns de discussão sobre temas controversos e trabalhos de reflexão individual
- ♦ Disponibilidade de acesso a todo o conteúdo a partir de qualquer dispositivo, seja fixo ou móvel, com conexão à Internet



*Você 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"*

“

*Você imergirá em métodos avançados, como a aprendizagem por reforço para a ,de séries temporais com LSTM, graças a uma extensa biblioteca de recursos multimídia inovadores”*

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

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

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

*Você terá a capacidade de realizar análises precisas e eficientes em um ambiente de crescente complexidade e dinâmica nos mercados financeiros, através dos melhores materiais didáticos, na vanguarda da tecnologia e da educação.*

*Você 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 setor financeiro.*



# 02

## Objetivos

O programa dotará os profissionais das competências necessárias para aplicar técnicas avançadas de *Machine Learning* e *Deep Learning* que são fundamentais para otimizar as estratégias de investimento e de *trading*. Também se concentrará no desenvolvimento de competências para lidar e processar grandes volumes de dados financeiros, conceber e avaliar sistemas de *trading* algorítmico e abordar questões éticas e regulamentares relacionadas a aplicação da IA nas finanças. Neste sentido, os profissionais estarão preparados para enfrentar os desafios e tirar partido das oportunidades oferecidas pela IA em um ambiente financeiro que apresenta constante mudança.



“

*O principal objetivo deste Mestrado Próprio é formar profissionais altamente qualificados para integrar a Inteligência Artificial na análise e gestão dos mercados financeiros. O que você está esperando para se matricular?"*



## Objetivos gerais

---

- ♦ Compreender os fundamentos teóricos da Inteligência Artificial
- ♦ Estudar os diferentes tipos de dados e entender o ciclo de vida dos dados
- ♦ Avaliar o papel crucial dos dados no desenvolvimento e na implementação de soluções de Inteligência Artificial
- ♦ Aprofundar conhecimentos sobre os algoritmos e a complexidade para resolver problemas específicos
- ♦ Explorar a base teórica das redes neurais para o desenvolvimento do *Deep Learning*
- ♦ Analisar a computação bioinspirada e 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
- ♦ Capacitar os estudantes para conceber, implementar e otimizar estratégias de negociação algorítmica, utilizando técnicas de *Reinforcement Learning* e *Machine Learning* para melhorar a eficiência e a rentabilidade nos mercados financeiros
- ♦ Adquirir competências no processamento e análise de grandes volumes de dados financeiros utilizando tecnologias de *Big Data*, de dados financeiros utilizando tecnologias de grandes volumes de dados, tais como Hadoop e Spark
- ♦ Desenvolver a capacidade de elaborar e aplicar modelos de Inteligência Artificial que sejam explicáveis e transparentes, garantindo que as decisões financeiras baseadas na IA sejam compreensíveis e justificáveis
- ♦ Desenvolver uma compreensão aprofundada dos desafios éticos e regulamentares associados à utilização da Inteligência Artificial nas finanças
- ♦ Dotar os alunos das ferramentas e dos conhecimentos necessários para desenvolver soluções financeiras inovadoras que integrem a Inteligência Artificial
- ♦ Desenvolver modelos preditivos utilizando técnicas de *Machine Learning*, tais como LSTM 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 as decisões de investimento
- ♦ 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 tecnologias de IA nas finanças de 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 seus primórdios até o estado atual, identificando os principais marcos e desenvolvimentos
- ♦ Compreender o funcionamento das redes de neurônios e sua aplicação em modelos de aprendizado na Inteligência Artificial
- ♦ Estudar os princípios e as aplicações dos algoritmos genéticos, analisando sua utilidade na solução de problemas complexos
- ♦ Analisar a importância de tesouros, vocabulários e taxonomias na estruturação e no processamento de dados para sistemas de IA

### Módulo 2. Tipos e Ciclo de Vida dos Dados

- ♦ Compreender os conceitos fundamentais de estatística e sua aplicação na análise de dados
- ♦ Identificar e classificar diferentes tipos de dados estatísticos, desde dados quantitativos até qualitativos
- ♦ Analisar o ciclo de vida dos dados, desde a geração até o descarte, identificando as principais etapas
- ♦ Explorar as fases iniciais do ciclo de vida dos dados, destacando a importância do planejamento e da estrutura dos dados
- ♦ Estudar os processos de coleta de dados, incluindo metodologia, ferramentas e canais de coleta
- ♦ Explorar o conceito de *Datawarehouse* (Data Datawarehouse), com ênfase em seus elementos constituintes e design

### Módulo 3. Dados em Inteligência Artificial

- ♦ Dominar os fundamentos da ciência de dados, abrangendo ferramentas, tipos e fontes de análise de informações
- ♦ Explorar o processo de transformação de dados em informações usando técnicas de mineração e visualização de dados
- ♦ Estudar a estrutura e as características dos *datasets*, compreender sua importância na preparação e no uso de dados para modelos de Inteligência Artificial
- ♦ Usar ferramentas específicas e práticas recomendadas no manuseio e processamento de dados, garantindo eficiência e qualidade na implementação da Inteligência Artificial

### Módulo 4. Mineração de Dados Seleção, Pré-Processamento e Transformação

- ♦ Dominar as técnicas de inferência estatística para entender e aplicar métodos estatísticos na mineração de dados
- ♦ Realizar análises exploratórias detalhadas de conjuntos de dados para identificar padrões, anomalias e tendências relevantes
- ♦ Desenvolver habilidades na preparação de dados, incluindo limpeza, integração e formatação de dados para uso em mineração de dados
- ♦ Implementar estratégias eficazes para lidar com valores perdidos em conjuntos de dados, aplicando métodos de imputação ou eliminação de acordo com o contexto
- ♦ Identificar e mitigar o ruído em dados, usando técnicas de filtragem e suavização para melhorar a qualidade do conjunto de dados
- ♦ Abordar o pré-processamento de dados em ambientes *Big Data*

### Módulo 5. Algoritmo e Complexidade em Inteligência Artificial

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

### Módulo 6. Sistemas Inteligentes

- ♦ Explorar a teoria dos agentes, compreendendo os conceitos fundamentais de como eles funcionam e sua aplicação em Inteligência Artificial e engenharia de software
- ♦ Estudar a representação do conhecimento, incluindo a análise de ontologias e sua aplicação na organização de informações estruturadas
- ♦ Analisar o conceito da Web semântica e seu impacto sobre a organização e a recuperação de informações em ambientes digitais
- ♦ Avaliar e comparar diferentes representações do conhecimento, integrando-as para melhorar a eficiência e a precisão dos sistemas inteligentes

## Módulo 7: Machine Learning e Mineração de Dados

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

## Módulo 8. Redes Neurais como Base do *Deep Learning*

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

- ♦ Compreender a união eficaz de camadas e operações para projetar arquiteturas de redes neurais complexas e eficientes
- ♦ Utilizar capacitadores e otimizadores para ajustar e melhorar o desempenho das redes neurais
- ♦ Explorar a ligação entre neurônios biológicos e artificiais para uma compreensão mais profunda da concepção de modelos

## Módulo 9. Treinamento de Redes Neurais Profundas

- ♦ Resolver problemas relacionados ao gradiente no treinamento de redes neurais profundas
- ♦ Explorar e aplicar diferentes otimizadores para melhorar a eficiência e a convergência dos modelos
- ♦ Programar a taxa de aprendizagem para ajustar dinamicamente a velocidade de convergência do modelo
- ♦ Compreender e lidar com o superajuste por meio de estratégias específicas durante a capacitação
- ♦ Aplicar diretrizes práticas para garantir o treinamento eficiente e eficaz de redes neurais profundas
- ♦ Implementar *Transfer Learning* como uma técnica avançada para melhorar o desempenho do modelo em tarefas específicas
- ♦ Explorar e aplicar técnicas de *Data Augmentation* para enriquecer os conjuntos de dados e melhorar a generalização do modelo
- ♦ Desenvolver aplicações práticas utilizando *Transfer Learning* para resolver problemas do mundo real

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

- ♦ Dominar os fundamentos de *TensorFlow* e sua integração com o NumPy para o manuseio eficiente de dados e cálculos
- ♦ Personalizar modelos e algoritmos de treinamento usando os recursos avançados do *TensorFlow*
- ♦ Explorar a API *tfdataset* para gerenciar e manipular conjuntos de dados com eficiência
- ♦ Implementar o formato *TFRecord* para armazenar e acessar grandes conjuntos de dados em *TensorFlow*
- ♦ Utilizar camadas de pré-processamento do Keras para facilitar a construção de modelos personalizados
- ♦ Explore o projeto *TensorFlow Datasets* para acessar conjuntos de dados predefinidos e melhorar a eficiência do desenvolvimento
- ♦ Desenvolver um aplicativo de *Deep Learning* com *TensorFlow*, integrando o conhecimento adquirido no módulo
- ♦ Aplicar de forma prática todos os conceitos aprendidos na construção e treinamento de modelos personalizados usando *TensorFlow* em situações do mundo real

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

- ♦ Compreender a arquitetura do córtex visual e sua importância para o *Deep Computer Vision*
- ♦ Explorar e aplicar camadas convolucionais para extrair os principais recursos das imagens
- ♦ Implementar camadas de agrupamento e seu uso em modelos de *Deep Computer Vision* com Keras
- ♦ Analisar várias arquiteturas de Redes Neurais Convolucionais (CNN) e sua aplicabilidade em diferentes contextos

- ♦ Desenvolver e implementar uma CNN ResNet utilizando a biblioteca Keras para melhorar a eficiência e o desempenho do modelo
- ♦ Utilizar modelos Keras pré-treinados para aproveitar a aprendizagem por transferência para tarefas específicas
- ♦ Aplicar técnicas de classificação e rastreamento em um ambiente de *Deep Computer Vision*
- ♦ Explorar estratégias de detecção e rastreamento de objetos usando Redes Neurais Convolucionais

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

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

### Módulo 13. Autoencoders, GANs, e Modelos de Difusão

- ♦ Desenvolver representações de dados eficientes utilizando *Autoencoders*, *GANs* e Modelos de Difusão
- ♦ Efetuar PCA utilizando um codificador automático linear incompleto para otimizar a representação dos dados
- ♦ Implementar e compreender a operação de codificadores automáticos empilhados
- ♦ Explorar e aplicar auto-codificadores convolucionais para representações eficientes de dados visuais
- ♦ Analisar e aplicar a eficácia de codificadores automáticos esparsos na representação de dados
- ♦ Gerar imagens de moda a partir do conjunto de dados MNIST usando *Autoencoders*
- ♦ Compreender o conceito de Redes Adversárias Generativas (*GANs*) e modelos de difusão
- ♦ Implementar e avaliar o desempenho dos modelos de difusão e *GANs* na geração de dados

### Módulo 14. Computação Bioinspirada

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

### Módulo 15. Inteligência Artificial: Estratégias e Aplicações

- ♦ Desenvolver estratégias para a implementação de inteligência artificial em serviços financeiros
- ♦ Identificar e avaliar os riscos associados ao uso da IA no campo da saúde
- ♦ Avaliar os possíveis riscos associados ao uso da IA no setor
- ♦ Aplicar técnicas de inteligência artificial no setor para melhorar a produtividade
- ♦ Conceber soluções de Inteligência Artificial para otimizar os processos na administração pública
- ♦ Avaliar a implementação de tecnologias de IA no setor educacional
- ♦ Aplicar técnicas de inteligência artificial na silvicultura e na agricultura para melhorar a produtividade
- ♦ Otimizar os processos de recursos humanos por meio do uso estratégico da inteligência artificial

### Módulo 16. 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 decisões mais fundamentada 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 concepção e otimização de estratégias de negociação algorítmicas utilizando técnicas de *Reinforcement Learning* com *TensorFlow*, centradas na maximização da rentabilidade

### Módulo 17. Análise Fundamental dos Mercados Financeiros com IA

- ♦ Saiba como modelar e prever o desempenho financeiro das empresas utilizando técnicas de *Machine Learning* e *Deep Learning*, facilitando as 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 econômica das empresas
- ♦ Desenvolver competências na detecção de fraudes financeiras e na avaliação de riscos através da utilização de *Machine Learning*, garantindo maior segurança e rigor nas decisões financeiras

### Módulo 18. Processamento de Dados Financeiros em Grande Escala

- ♦ Dominar a utilização de tecnologias de *Big Data*, como Hadoop e Spark, para o armazenamento e processamento de grandes volumes de dados financeiros, otimizando a capacidade de análise e 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 setor



### Módulo 19. Estratégias de *Trading* Algorítmico

- ♦ Adquirir as competências necessárias para conceber e desenvolver sistemas de negociação automatizados, integrando técnicas de *Machine Learning* para melhorar a eficiência e a eficácia da negociação
- ♦ 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 à negociação algorítmica, garantindo que as estratégias são simultaneamente 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
- ♦ Compreenda as regulamentações globais que afetam 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 econômico 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 técnicas 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 enfrentar os desafios éticos e regulamentares relacionados com a utilização da IA.



“

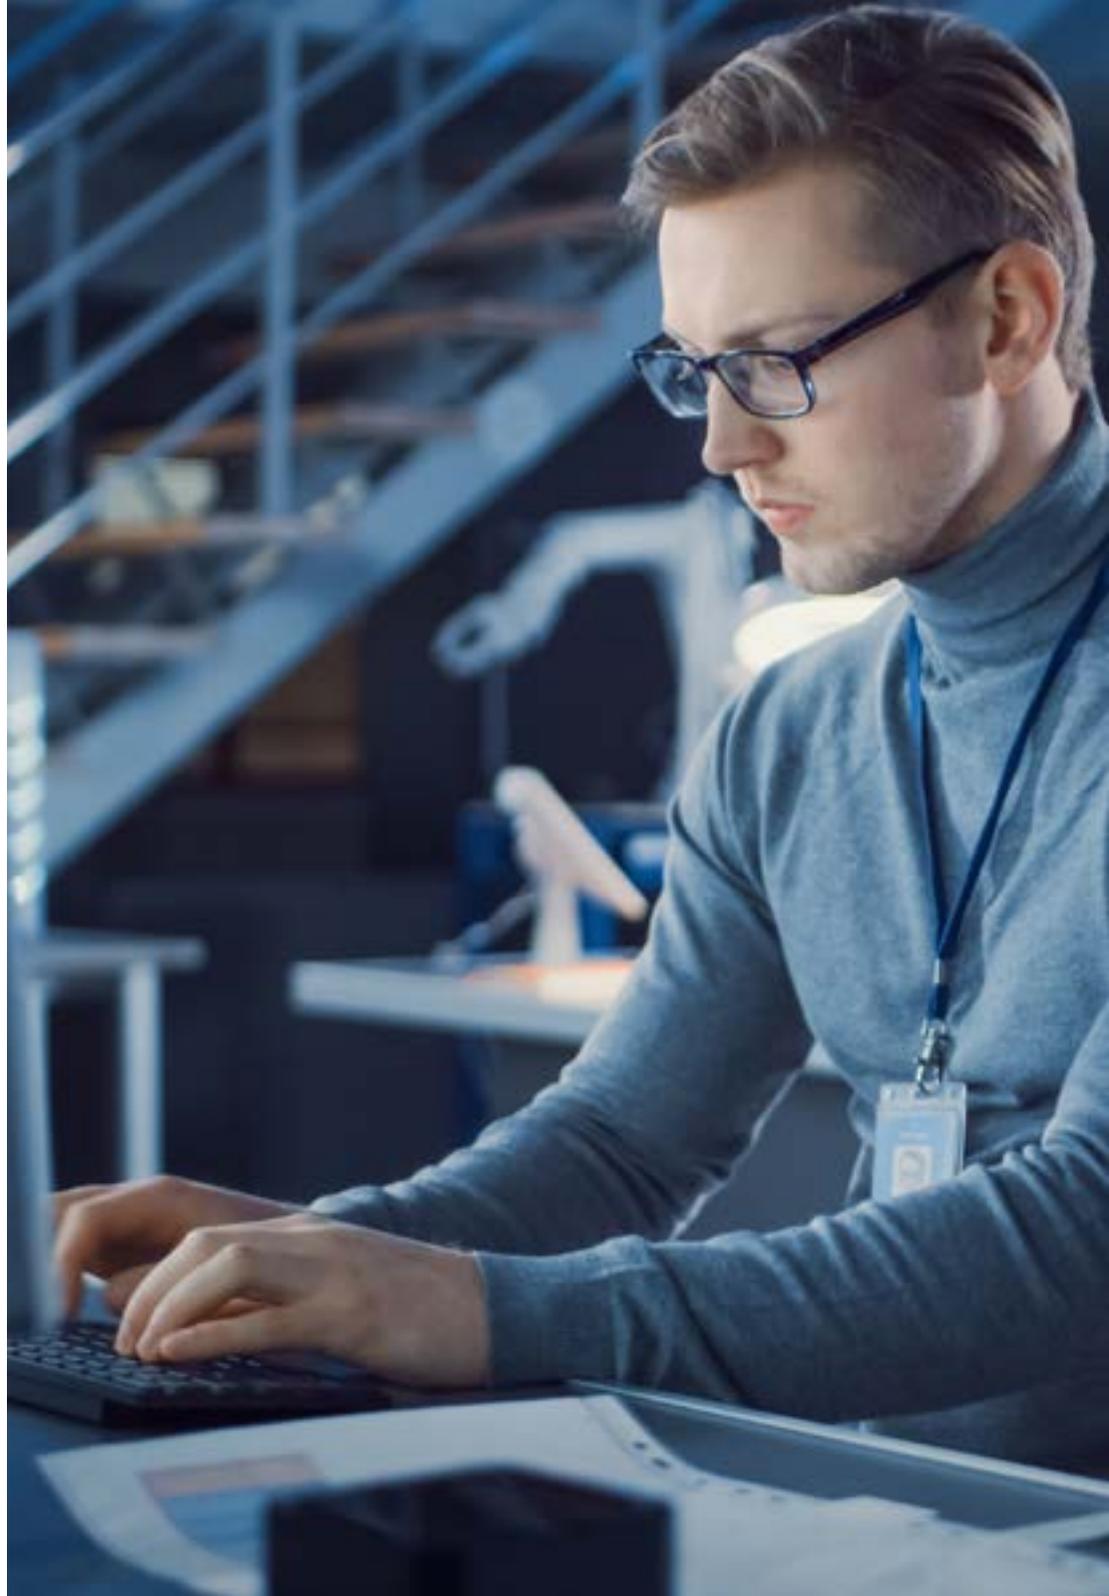
*Estará equipado para liderar a transformação digital nos mercados financeiros, fornecendo soluções inovadoras e estratégicas em um ambiente altamente competitivo. Com todas as garantias de qualidade que a TECH oferece”*



## Competências gerais

---

- ♦ Dominar as técnicas de mineração de dados, incluindo a seleção, o pré-processamento e a transformação de dados complexos
- ♦ Conceção e desenvolvimento de sistemas inteligentes capazes de aprender e de se adaptar a ambientes em mudança
- ♦ Controlar as ferramentas de aprendizado de máquina e sua aplicação na mineração de dados para a tomada de decisões
- ♦ Utilizar *Autoencoders*, *GANs* e modelagem de difusão para resolver desafios específicos em Inteligência Artificial
- ♦ Implementar de uma rede codificador-decodificador para tradução automática neuronal
- ♦ Aplicar os princípios fundamentais das redes neurais na resolução de problemas específicos
- ♦ Conceber e implementar 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
- ♦ Otimização das carteiras de investimento através da aplicação de algoritmos genéticos para equilibrar o risco e o rendimento
- ♦ Detectar e prevenir a fraude financeira através da utilização de modelos de Inteligência Artificial, melhorando a segurança das transações





## Competências específicas

---

- Aplicar técnicas e estratégias de IA para melhorar a eficiência no setor de retenção.
- Aprofundar a compreensão e a aplicação de algoritmos genéticos
- Implementar técnicas de redução de ruído usando codificadores automáticos
- Criar com eficiência conjuntos de dados de treinamento para tarefas de processamento de linguagem natural (NLP)
- Execução de camadas de cluster e sua utilização em modelos de *Deep Computer Vision* com o Keras
- Utilizar funcionalidades e gráficos do TensorFlow para otimizar o desempenho de modelos personalizados
- Otimizar o desenvolvimento e a aplicação de *chatbots* e assistentes virtuais, entendendo como eles funcionam e suas possíveis aplicações
- Dominar a reutilização de camadas pré-treinadas para otimizar e acelerar o processo de treinamento
- Construir a primeira rede neural, aplicando os conceitos aprendidos na prática
- Ativar o Perceptron de Múltiplas Camadas (MLP) usando a biblioteca Keras
- Aplicar técnicas de exploração e pré-processamento de dados, identificando e preparando dados para uso eficaz em modelos de aprendizado de máquina
- Implementar estratégias eficazes para lidar com valores perdidos em conjuntos de dados, aplicando métodos de imputação ou eliminação de acordo com o contexto
- Analisar linguagens e softwares para a criação de ontologias, usando ferramentas específicas para o desenvolvimento de modelos semânticos
- Desenvolver técnicas de limpeza de dados para garantir a qualidade e a precisão das informações usadas em análises subsequentes
- Analisar demonstrações financeiras com Processamento de Linguagem Natural (PNL) para extrair informações valiosas e efetuar avaliações precisas das empresas
- Gestão e processamento de grandes volumes de dados financeiros utilizando ferramentas de *Big Data* como Hadoop e Spark
- Desenvolver e avaliar estratégias de *Trading* de alta frequência (HFT), otimizando a velocidade e a precisão da execução de ordens
- 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 setor financeiro, garantindo práticas responsáveis e em conformidade 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 Hadoop e Spark para processar e visualizar informações de forma eficiente”*

# 04

## Direção do curso

Este Mestrado Próprio conta com um corpo docente composto por profissionais de renome no domínio das finanças e da tecnologia. De fato, são especialistas com vasta experiência no uso da Inteligência Artificial aplicada aos mercados financeiros, combinando experiência prática e acadêmica. Os seus conhecimentos aprofundados vão desde a análise técnica e fundamental até ao desenvolvimento de estratégias de negociação algorítmicas e ao tratamento de *Big Data*. Além disso, estão a par das últimas tendências e desenvolvimentos no setor, o que garantirá que os diplomados recebam uma formação relevante e pertinente.



“

*A experiência e os conhecimentos especializados dos professores enriquecerão a aprendizagem, proporcionando aos alunos perspectivas e ligações valiosas no setor financeiro global”*

## Direção



### Dr. Arturo Peralta Martín-Palomino

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



## Professores

### D. Rodrigo Sánchez Mansilla

- *Digital Advisor* em AI Shepherds GmbH
- *Digital Account Manager* em Kill Draper
- *Head de Canais Digitais* na Naturgy
- *Digital Marketing Manager* em Arconi Solutions, Deltoid Energy e Brinergy Tech
- *Fundador e Diretor Nacional de Vendas e Marketing*
- Mestrado em Marketing Digital (MDM) pela The Power Business School
- Licenciatura em Administração de Empresas (BBA) pela Universidade de Buenos Aires

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

05

# Estrutura e conteúdo

Este grau académico 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.



“

*O programa concentra-se 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: TECH Universidade Tecnológica"*

## Módulo 1. Fundamentos da Inteligência Artificial

- 1.1. História da inteligência artificial
  - 1.1.1. Quando começamos a falar de inteligência artificial?
  - 1.1.2. Referências no cinema
  - 1.1.3. Importância da inteligência artificial
  - 1.1.4. Tecnologias que habilitam e dão suporte à inteligência artificial
- 1.2. Inteligência Artificial em jogos
  - 1.2.1. Teoria dos jogos
  - 1.2.2. *Minimax* e poda Alfa-Beta
  - 1.2.3. Simulação: Monte Carlo
- 1.3. Redes de neurônios
  - 1.3.1. Fundamentos biológicos
  - 1.3.2. Modelo computacional
  - 1.3.3. Redes de neurônios supervisionadas e não supervisionadas
  - 1.3.4. Perceptron simples
  - 1.3.5. Perceptron multicamadas
- 1.4. Algoritmos genéticos
  - 1.4.1. História
  - 1.4.2. Base biológica
  - 1.4.3. Codificação de problemas
  - 1.4.4. Geração da população inicial
  - 1.4.5. Algoritmo principal e operadores genéticos
  - 1.4.6. Avaliação de indivíduos: Fitness
- 1.5. Tesouros, vocabulários, taxonomias
  - 1.5.1. Vocabulários
  - 1.5.2. Taxonomias
  - 1.5.3. Tesouros
  - 1.5.4. Ontologias
  - 1.5.5. Representação do conhecimento: web semântica



- 1.6. Web Semântica
  - 1.6.1. Especificações RDF, RDFS e OWL
  - 1.6.2. Inferência/raciocínio
  - 1.6.3. *Linked Data*
- 1.7. Sistemas especializados e DSS
  - 1.7.1. Sistemas especializados
  - 1.7.2. Sistemas de suporte à decisão
- 1.8. *Chatbots* e assistentes virtuais
  - 1.8.1. Tipos de assistentes: assistentes de voz e texto
  - 1.8.2. Partes fundamentais para o desenvolvimento de um assistente: *Intenções*, entidades e fluxo de diálogo
  - 1.8.3. Integração Web, *Slack*, *Whatsapp*, *Facebook*
  - 1.8.4. Ferramentas para o desenvolvimento de assistentes: *Dialog Flow*, *Watson Assistant*
- 1.9. Estratégia de implementação da IA
- 1.10. O futuro da inteligência artificial
  - 1.10.1. Entendemos como detectar emoções através de algoritmos
  - 1.10.2. Criar uma personalidade: linguagem, expressões e conteúdo
  - 1.10.3. Tendências da inteligência artificial
  - 1.10.4. Reflexões

## Módulo 2. Tipos e Ciclo de Vida dos Dados

- 2.1. Estatísticas
  - 2.1.1. Estatísticas: descritivas e inferências
  - 2.1.2. População, amostra, individual
  - 2.1.3. Variáveis: definição, escalas de medição
- 2.2. Tipos de dados estatísticos
  - 2.2.1. De acordo com o tipo
    - 2.2.1.1. Quantitativos: dados contínuos e dados discretos
    - 2.2.1.2. Qualitativo: dados binomiais, dados nominais, dados ordinais
  - 2.2.2. De acordo com sua forma
    - 2.2.2.1. Numérico
    - 2.2.2.2. Texto
    - 2.2.2.3. Lógico
- 2.2.3. De acordo com a fonte
  - 2.2.3.1. Primários
  - 2.2.3.2. Secundários
- 2.3. Ciclo de vida dos dados
  - 2.3.1. Etapas do ciclo
  - 2.3.2. Marcos do ciclo
  - 2.3.3. Princípios FAIR
- 2.4. Etapas iniciais do ciclo
  - 2.4.1. Definição de objetivos
  - 2.4.2. Determinação de recursos necessários
  - 2.4.3. Diagrama de Gantt
  - 2.4.4. Estruturas dos dados
- 2.5. Coleta de dados
  - 2.5.1. Metodologia de coleta
  - 2.5.2. Ferramentas de coleta
  - 2.5.3. Canais de coleta
- 2.6. Limpeza de dados
  - 2.6.1. Fases da limpeza de dados
  - 2.6.2. Qualidade dos dados
  - 2.6.3. Manipulação de dados (com R)
- 2.7. Análise de dados, interpretação e avaliação dos resultados
  - 2.7.1. Medidas estatísticas
  - 2.7.2. Índices de relação
  - 2.7.3. Mineração de dados
- 2.8. Armazém de dados (*datawarehouse*)
  - 2.8.1. Elementos que o compõem
  - 2.8.2. Desenho
  - 2.8.3. Aspectos a considerar
- 2.9. Disponibilidade de dados
  - 2.9.1. Acesso
  - 2.9.2. Utilidade
  - 2.9.3. Segurança

- 2.10. Aspectos regulamentares
  - 2.10.1. Lei Geral de Proteção de Dados
  - 2.10.2. Boas práticas
  - 2.10.3. Outros aspectos regulamentares

### Módulo 3. Dados em Inteligência Artificial

- 3.1. Ciência de dados
  - 3.1.1. Ciência de dados
  - 3.1.2. Ferramentas avançadas para o cientista de dados
- 3.2. Dados, informações e conhecimentos
  - 3.2.1. Dados, informações e conhecimentos
  - 3.2.2. Tipos de dados
  - 3.2.3. Fontes de dados
- 3.3. De dados a informações
  - 3.3.1. Análise de dados
  - 3.3.2. Tipos de análise
  - 3.3.3. Extração de informações de um *Dataset*
- 3.4. Extração de informações através da visualização
  - 3.4.1. A visualização como ferramenta de análise
  - 3.4.2. Métodos de visualização
  - 3.4.3. Visualização de um conjunto de dados
- 3.5. Qualidade dos dados
  - 3.5.1. Dados de qualidade
  - 3.5.2. Limpeza de dados
  - 3.5.3. Pré-processamento básico de dados
- 3.6. *Dataset*
  - 3.6.1. Enriquecimento do *Dataset*
  - 3.6.2. A maldição da dimensionalidade
  - 3.6.3. Modificação de nosso conjunto de dados
- 3.7. Desequilíbrio
  - 3.7.1. Desequilíbrio de classes
  - 3.7.2. Técnicas de mitigação do desequilíbrio
  - 3.7.3. Equilíbrio de um *Dataset*

- 3.8. Modelos não supervisionados
  - 3.8.1. Modelo não supervisionado
  - 3.8.2. Métodos
  - 3.8.3. Classificação com modelos não supervisionados
- 3.9. Modelos supervisionados
  - 3.9.1. Modelo supervisionado
  - 3.9.2. Métodos
  - 3.9.3. Classificação com modelos supervisionados
- 3.10. Ferramentas e práticas recomendadas
  - 3.10.1. Práticas recomendadas para um cientista de dados
  - 3.10.2. O melhor modelo
  - 3.10.3. Ferramentas úteis

### Módulo 4. Mineração de Dados Seleção, Pré-Processamento e Transformação

- 4.1. Inferência estatística
  - 4.1.1. Estatística descritiva vs. Inferência estatística
  - 4.1.2. Procedimentos paramétricos
  - 4.1.3. Procedimentos paramétricos
- 4.2. Análise exploratória
  - 4.2.1. Análise descritiva
  - 4.2.2. Visualização
  - 4.2.3. Preparação dos dados
- 4.3. Preparação dos dados
  - 4.3.1. Integração e limpeza de dados
  - 4.3.2. Normalização de dados
  - 4.3.3. Transformando atributos
- 4.4. Os Valores Perdidos
  - 4.4.1. Tratamento de valores perdidos
  - 4.4.2. Métodos de imputação de máxima verossimilhança
  - 4.4.3. Imputação de valores perdidos utilizando a aprendizado de máquinas
- 4.5. O ruído nos dados
  - 4.5.1. Classes de ruído e seus atributos
  - 4.5.2. Filtragem de ruídos
  - 4.5.3. O efeito do ruído

- 4.6. A maldição da dimensionalidade
  - 4.6.1. *Oversampling*
  - 4.6.2. *Undersampling*
  - 4.6.3. Redução de dados multidimensionais
- 4.7. De atributos contínuos a discretos
  - 4.7.1. Dados contínuos versus discretos
  - 4.7.2. Processo de discretização
- 4.8. Os dados
  - 4.8.1. Seleção de dados
  - 4.8.2. Perspectivas e critérios de seleção
  - 4.8.3. Métodos de seleção
- 4.9. Seleção de Instâncias
  - 4.9.1. Métodos para seleção de instâncias
  - 4.9.2. Seleção de protótipos
  - 4.9.3. Métodos avançados para seleção de instâncias
- 4.10. Pré-processamento de dados em ambientes *Big Data*

## Módulo 5. Algoritmo e Complexidade em Inteligência Artificial

- 5.1. Introdução às Estratégias de design de algoritmos
  - 5.1.1. Recursividade
  - 5.1.2. Divisão e conquista
  - 5.1.3. Outras estratégias
- 5.2. Eficiência e análise de algoritmos
  - 5.2.1. Medidas de eficiência
  - 5.2.2. Como medir o tamanho da entrada
  - 5.2.3. Como medir o tempo de execução
  - 5.2.4. Melhor, pior e médio caso
  - 5.2.5. Notação assintótica
  - 5.2.6. Critérios de análise matemática para algoritmos não recursivos
  - 5.2.7. Análise matemática de algoritmos recursivos
  - 5.2.8. Análise empírica de algoritmos

- 5.3. Algoritmos de ordenação
  - 5.3.1. Conceito de ordenação
  - 5.3.2. Ordenação bolha (Bubble sort)
  - 5.3.3. Ordenação por seleção (Selection sort)
  - 5.3.4. Ordenação por inserção (Insertion Sort)
  - 5.3.5. Ordenação por mistura (*merge\_sort*)
  - 5.3.6. Classificação rápida (*quick\_sort*)
- 5.4. Algoritmos com árvores
  - 5.4.1. Conceito de árvore
  - 5.4.2. Árvores binárias
  - 5.4.3. Caminhos de árvores
  - 5.4.4. Representar expressões
  - 5.4.5. Árvores binárias ordenadas
  - 5.4.6. Árvores binárias balanceadas
- 5.5. Algoritmos com *Heaps*
  - 5.5.1. Os *Heaps*
  - 5.5.2. O algoritmo *Heapsort*
  - 5.5.3. As filas de prioridade
- 5.6. Algoritmos com grafos
  - 5.6.1. Representação
  - 5.6.2. Caminho em largura
  - 5.6.3. Caminho em profundidade
  - 5.6.4. Ordenação topológica
- 5.7. Algoritmos *Greedy*
  - 5.7.1. A estratégia *Greedy*
  - 5.7.2. Elementos da estratégia *Greedy*
  - 5.7.3. Conversor de moedas
  - 5.7.4. Problema do Caixeiro Viajante
  - 5.7.5. Problema da mochila
- 5.8. Busca do caminho mínimo
  - 5.8.1. O problema do caminho mínimo
  - 5.8.2. Arco e ciclos negativos
  - 5.8.3. Algoritmo de Dijkstra

- 5.9. Algoritmos *Greedy* sobre Grafos
  - 5.9.1. A árvore de extensão mínima
  - 5.9.2. O algoritmo de Prim (algoritmo guloso)
  - 5.9.3. O algoritmo de Kruskal
  - 5.9.4. Análise de complexidade
- 5.10. *Backtracking*
  - 5.10.1. O *Backtracking*
  - 5.10.2. Técnicas alternativas

## Módulo 6. Sistemas Inteligentes

- 6.1. Teoria de Agentes
  - 6.1.1. História do conceito
  - 6.1.2. Definição de agente
  - 6.1.3. Agentes em Inteligência Artificial
  - 6.1.4. Agentes em Engenharia de Software
- 6.2. Arquiteturas de agentes
  - 6.2.1. O processo de raciocínio de um agente
  - 6.2.2. Agentes reativos
  - 6.2.3. Agentes dedutivos
  - 6.2.4. Agentes híbridos
  - 6.2.5. Comparativa
- 6.3. Informação e conhecimento
  - 6.3.1. Distinção entre dados, informações e conhecimentos
  - 6.3.2. Avaliação da qualidade dos dados
  - 6.3.3. Métodos de captura de dados
  - 6.3.4. Métodos de aquisição de informações
  - 6.3.5. Métodos de aquisição de conhecimentos
- 6.4. Representação do conhecimento
  - 6.4.1. A importância da representação do conhecimento
  - 6.4.2. Definição da representação do conhecimento através de suas funções
  - 6.4.3. Características de uma representação do conhecimento

- 6.5. Ontologias
  - 6.5.1. Introdução aos metadados
  - 6.5.2. Conceito filosófico de ontologia
  - 6.5.3. Conceito informático de ontologia
  - 6.5.4. Ontologias de domínio e ontologias de nível superior
  - 6.5.5. Como construir uma ontologia?
- 6.6. Linguagens para ontologias e software para criação de ontologias
  - 6.6.1. Tríade RDF, *Turtle* e N
  - 6.6.2. RDF *Schema*
  - 6.6.3. OWL
  - 6.6.4. SPARQL
  - 6.6.5. Introdução às diferentes ferramentas para a criação de ontologias
  - 6.6.6. Instalação e uso do *Protégé*
- 6.7. Web Semântica
  - 6.7.1. O estado atual e futuro da segurança ad web semântica
  - 6.7.2. Aplicações da web semântica
- 6.8. Outros modelos de representação do conhecimento
  - 6.8.1. Vocabulários
  - 6.8.2. Visão global
  - 6.8.3. Taxonomias
  - 6.8.4. Tesaurus
  - 6.8.5. Folksonomias
  - 6.8.6. Comparativa
  - 6.8.7. Mapas mentais
- 6.9. Avaliação e integração das representações do conhecimento
  - 6.9.1. Lógica de ordem zero
  - 6.9.2. Lógica de primeira ordem
  - 6.9.3. Lógica descritiva
  - 6.9.4. Relação entre diferentes tipos de lógica
  - 6.9.5. *Prolog*: programação baseada em lógica de primeira ordem

- 6.10. Raciocinadores Semânticos, Sistemas Baseados no Conhecimento e Sistemas Especialistas
  - 6.10.1. Conceito de raciocinador
  - 6.10.2. Aplicações de um raciocinador
  - 6.10.3. Sistemas baseados no conhecimento
  - 6.10.4. MYCIN, história dos Sistemas Especialistas
  - 6.10.5. Elementos e Arquitetura de Sistemas Especialistas
  - 6.10.6. Criação de Sistemas Especialistas

## Módulo 7. Machine Learning e Mineração de Dados

- 7.1. Introdução aos processos de descoberta de conhecimento e conceitos básicos de machine learning
  - 7.1.1. Conceitos-chave dos processos de descoberta do conhecimento
  - 7.1.2. Perspectiva histórica dos processos de descoberta do conhecimento
  - 7.1.3. Fases dos processos de descoberta do conhecimento
  - 7.1.4. Técnicas utilizadas nos processos de descoberta do conhecimento
  - 7.1.5. Características dos bons modelos de machine learning
  - 7.1.6. Tipos de informações de machine learning
  - 7.1.7. Noções básicas de aprendizagem
  - 7.1.8. Noções básicas de aprendizagem não supervisionada
- 7.2. Exploração e pré-processamento de dados
  - 7.2.1. Processamento de dados
  - 7.2.2. Tratamento de dados no fluxo de análise de dados
  - 7.2.3. Tipos de dados
  - 7.2.4. Transformações de dados
  - 7.2.5. Visualização e exploração de variáveis contínuas
  - 7.2.6. Visualização e exploração de variáveis categóricas
  - 7.2.7. Medidas de correlação
  - 7.2.8. Representações gráficas mais comuns
  - 7.2.9. Introdução à análise multivariada e redução da dimensionalidade
- 7.3. Árvore de decisão
  - 7.3.1. Algoritmo ID
  - 7.3.2. Algoritmo C
  - 7.3.3. Overtraining e poda
  - 7.3.4. Análise de resultados
- 7.4. Avaliação de classificadores
  - 7.4.1. Matrizes de confusão
  - 7.4.2. Matrizes de avaliação numérica
  - 7.4.3. Estatístico de Kappa
  - 7.4.4. Curvas Roc
- 7.5. Regras de classificação
  - 7.5.1. Medidas de avaliação de regras
  - 7.5.2. Introdução à representação gráfica
  - 7.5.3. Algoritmo de sobreposição sequencial
- 7.6. Redes Neurais
  - 7.6.1. Conceitos básicos
  - 7.6.2. Redes de neurônios simples
  - 7.6.3. Algoritmo de *back propagation*
  - 7.6.4. Introdução às redes neurais recorrentes
- 7.7. Métodos bayesianos
  - 7.7.1. Conceitos básicas de probabilidade
  - 7.7.2. Teorema de Bayes
  - 7.7.3. Naive Bayes
  - 7.7.4. Introdução às redes bayesianas
- 7.8. Modelos de regressão e de resposta contínua
  - 7.8.1. Regressão linear simples
  - 7.8.2. Regressão Linear Múltipla
  - 7.8.3. Regressão logística
  - 7.8.4. Árvores de regressão
  - 7.8.5. Introdução às Máquinas de Vetores de Suporte (SVM)
  - 7.8.6. Medidas de bondade do ajuste
- 7.9. *Clustering*
  - 7.9.1. Conceitos básicos
  - 7.9.2. *Clustering* hierárquico
  - 7.9.3. Métodos probabilísticos
  - 7.9.4. Algoritmo EM
  - 7.9.5. Método *B-Cubed*
  - 7.9.6. Métodos implícitos

- 7.10. Mineração de texto e processamento de linguagem natural (PNL)
  - 7.10.1. Conceitos básicos
  - 7.10.2. Criação do corpus
  - 7.10.3. Análise descritiva
  - 7.10.4. Introdução à análise de sentimentos

## Módulo 8. Redes Neurais como Base do *Deep Learning*

- 8.1. Aprendizagem profunda
  - 8.1.1. Tipos de aprendizagem profunda
  - 8.1.2. Aplicativos de aprendizagem profunda
  - 8.1.3. Vantagens e desvantagens da aprendizagem profunda
- 8.2. Operações
  - 8.2.1. Soma
  - 8.2.2. Produtos
  - 8.2.3. Transferência
- 8.3. Camadas
  - 8.3.1. Camada de entrada
  - 8.3.2. Camada oculta
  - 8.3.3. Camada de saída
- 8.4. União de Camadas e Operações
  - 8.4.1. Design de arquiteturas
  - 8.4.2. Conexão entre camadas
  - 8.4.3. Propagação para frente
- 8.5. Construção da primeira rede neural
  - 8.5.1. Design da rede
  - 8.5.2. Definição dos pesos
  - 8.5.3. Treinamento da rede
- 8.6. Treinador e Otimizador
  - 8.6.1. Seleção do otimizador
  - 8.6.2. Definição de uma função de perda
  - 8.6.3. Definição de uma métrica

- 8.7. Aplicação dos princípios das redes neurais
  - 8.7.1. Funções de ativação
  - 8.7.2. Retropropagação
  - 8.7.3. Ajuste dos parâmetros
- 8.8. Dos neurônios biológicos para os artificiais
  - 8.8.1. Funcionamento de um neurônio biológico
  - 8.8.2. Transferência de conhecimento para os neurônios artificiais
  - 8.8.3. Estabelecimento de relações entre ambos
- 8.9. Implementação de MLP (Perceptron multicamadas) com Keras
  - 8.9.1. Definição da estrutura da rede
  - 8.9.2. Compilação do modelo
  - 8.9.3. Treinamento do modelo
- 8.10. Hiperparâmetros de *Fine tuning* de Redes Neurais
  - 8.10.1. Seleção da função de ativação
  - 8.10.2. Estabelecer o *learning rate*
  - 8.10.3. Ajuste dos pesos

## Módulo 9. Treinamento de Redes Neurais Profundas

- 9.1. Problemas de Gradientes
  - 9.1.1. Técnicas de otimização de gradiente
  - 9.1.2. Gradientes Estocásticos
  - 9.1.3. Técnicas de inicialização de pesos
- 9.2. Reutilização de camadas pré-treinadas
  - 9.2.1. Treinamento de transferência de aprendizagem
  - 9.2.2. Extração de características
  - 9.2.3. Aprendizado profundo
- 9.3. Otimizadores
  - 9.3.1. Otimizadores de descida de gradiente estocástico
  - 9.3.2. Otimizadores Adam e *RMSprop*
  - 9.3.3. Otimizadores de momento

- 9.4. Programação da taxa de aprendizagem
  - 9.4.1. Controle de taxa de aprendizagem automática
  - 9.4.2. Ciclos de aprendizagem
  - 9.4.3. Termos de suavização
- 9.5. Sobre ajuste
  - 9.5.1. Validação cruzada
  - 9.5.2. Regularização
  - 9.5.3. Métricas de avaliação
- 9.6. Diretrizes práticas
  - 9.6.1. Design de modelos
  - 9.6.2. Seleção de métricas e parâmetros de avaliação
  - 9.6.3. Testes de hipóteses
- 9.7. *Transfer Learning*
  - 9.7.1. Treinamento de transferência de aprendizagem
  - 9.7.2. Extração de características
  - 9.7.3. Aprendizado profundo
- 9.8. *Data Augmentation*
  - 9.8.1. Transformações de imagem
  - 9.8.2. Geração de dados sintéticos
  - 9.8.3. Transformação de texto
- 9.9. Aplicação prática de *Transfer Learning*
  - 9.9.1. Treinamento de transferência de aprendizagem
  - 9.9.2. Extração de características
  - 9.9.3. Aprendizado profundo
- 9.10. Regularização
  - 9.10.1. L e L
  - 9.10.2. Regularização por máxima entropia
  - 9.10.3. *Dropout*

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

- 10.1. *TensorFlow*
  - 10.1.1. Uso da biblioteca *TensorFlow*
  - 10.1.2. Treinamento de modelos com *TensorFlow*
  - 10.1.3. Operações com gráficos no *TensorFlow*
- 10.2. *TensorFlow* e NumPy
  - 10.2.1. Ambiente computacional NumPy para *TensorFlow*
  - 10.2.2. Utilização de arrays NumPy com *TensorFlow*
  - 10.2.3. Operações NumPy para gráficos do *TensorFlow*
- 10.3. Personalização de modelos e algoritmos de treinamento
  - 10.3.1. Construção de modelos personalizados com *TensorFlow*
  - 10.3.2. Gestão de parâmetros de treinamento
  - 10.3.3. Utilização de técnicas de otimização para treinamento
- 10.4. Funções e gráficos do *TensorFlow*
  - 10.4.1. Funções com *TensorFlow*
  - 10.4.2. Utilização de gráficos para treinamento de modelos
  - 10.4.3. Otimização de gráficos com operações do *TensorFlow*
- 10.5. Carregamento e pré-processamento de dados com *TensorFlow*
  - 10.5.1. Carregamento de conjuntos de dados com *TensorFlow*
  - 10.5.2. Pré-processamento de dados com *TensorFlow*
  - 10.5.3. Utilização de ferramentas do *TensorFlow* para manipulação de dados
- 10.6. API *tf.data*
  - 10.6.1. Utilização da API *tf.data* para processamento de dados
  - 10.6.2. Construção de fluxos de dados com *tf.data*
  - 10.6.3. Uso da API *tf.data* para treinamento de modelos
- 10.7. O formato *TFRecord*
  - 10.7.1. Utilização da API *TFRecord* para serialização de dados
  - 10.7.2. Carregamento de arquivos *TFRecord* com *TensorFlow*
  - 10.7.3. Utilização de arquivos *TFRecord* para treinamento de modelos

- 10.8. Camadas de pré-processamento do Keras
  - 10.8.1. Utilização da API de pré-processamento do Keras
  - 10.8.2. Construção de *pipelined* de pré-processamento com Keras
  - 10.8.3. Uso da API de pré-processamento do Keras para treinamento de modelos
- 10.9. Projeto *TensorFlow Datasets*
  - 10.9.1. Utilização do *TensorFlow Datasets* para carregamento de dados
  - 10.9.2. Pré-processamento de dados com o *TensorFlow Datasets*
  - 10.9.3. Usar conjuntos de *TensorFlow Datasets* para capacitar modelos
- 10.10. Construção de uma aplicação de Deep Learning com *TensorFlow*
  - 10.10.1. Aplicação Prática
  - 10.10.2. Construção de uma aplicação de Deep Learning com *TensorFlow*
  - 10.10.3. Treinamento de um modelo com *TensorFlow*
  - 10.10.4. Utilização da aplicação para previsão de resultados

## Módulo 11. Visão Computacional Profunda com Redes Neurais Convolucionais

- 11.1. A Arquitetura do *Visual Cortex*
  - 11.1.1. Funções do córtex visual
  - 11.1.2. Teorias da visão computacional
  - 11.1.3. Modelos de processamento de imagens
- 11.2. Camadas convolucionais
  - 11.2.1. Reutilização de pesos na convolução
  - 11.2.2. Convolução D
  - 11.2.3. Funções de ativação
- 11.3. Camadas de agrupamento e implementação de camadas de agrupamento com o Keras
  - 11.3.1. *Agrupamento e Deslocamento*
  - 11.3.2. *Flattening*
  - 11.3.3. Tipos de *Pooling*
- 11.4. Arquiteturas CNN
  - 11.4.1. Arquitetura VGG
  - 11.4.2. Arquitetura *AlexNet*
  - 11.4.3. Arquitetura *ResNet*
- 11.5. Implementação de uma CNN *ResNet*- usando Keras
  - 11.5.1. Inicialização de pesos
  - 11.5.2. Definição da camada de entrada
  - 11.5.3. Definição da saída
- 11.6. Uso de modelos pré-treinados do Keras
  - 11.6.1. Características dos modelos pré-treinados
  - 11.6.2. Usos dos modelos pré-treinados
  - 11.6.3. Vantagens dos modelos pré-treinados
- 11.7. Modelos pré-treinados para aprendizado por transferência
  - 11.7.1. Aprendizagem por transferência
  - 11.7.2. Processo de aprendizagem por transferência
  - 11.7.3. Vantagens do aprendizado por transferência
- 11.8. Classificação e localização em *Deep Computer Vision*
  - 11.8.1. Classificação de imagens
  - 11.8.2. Localização de objetos em imagens
  - 11.8.3. Detecção de objetos
- 11.9. Detecção e rastreamento de objetos
  - 11.9.1. Métodos de detecção de objetos
  - 11.9.2. Algoritmos de rastreamento de objetos
  - 11.9.3. Técnicas de rastreamento e localização
- 11.10. Segmentação semântica
  - 11.10.1. Aprendizagem profunda para segmentação semântica
  - 11.10.2. Detecção de bordas
  - 11.10.3. Métodos de segmentação baseados em regras

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

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

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

## Módulo 13. Autoencoders, GANs, e Modelos de Difusão

- 13.1. Representação de dados eficientes
  - 13.1.1. Redução da dimensionalidade
  - 13.1.2. Aprendizado profundo
  - 13.1.3. Representações compactas
- 13.2. Realização de PCA com um codificador automático linear incompleto
  - 13.2.1. Processo de treinamento
  - 13.2.2. Implementação em Python
  - 13.2.3. Utilização de dados de teste
- 13.3. Codificadores automáticos empilhados
  - 13.3.1. Redes neurais profundas
  - 13.3.2. Construção de arquiteturas de codificação
  - 13.3.3. Uso da regularização
- 13.4. Autoencoders convolucionais
  - 13.4.1. Design de modelos convolucionais
  - 13.4.2. Treinamento de modelos convolucionais
  - 13.4.3. Avaliação de resultados

- 13.5. Eliminação de ruído de codificadores automáticos
  - 13.5.1. Aplicação de filtros
  - 13.5.2. Design de modelos de codificação
  - 13.5.3. Uso de técnicas de regularização
- 13.6. Codificadores automáticos dispersos
  - 13.6.1. Aumentando a eficiência da codificação
  - 13.6.2. Minimizando o número de parâmetros
  - 13.6.3. Utilização de técnicas de regularização
- 13.7. Codificadores automáticos variacionais
  - 13.7.1. Utilização de otimização variacional
  - 13.7.2. Aprendizagem profunda não supervisionada
  - 13.7.3. Representações latentes profundas
- 13.8. Geração de imagens MNIST de moda
  - 13.8.1. Reconhecimento de padrões
  - 13.8.2. Geração de imagens
  - 13.8.3. Treinamento de Redes Neurais Profundas
- 13.9. Redes adversárias generativas e modelos de difusão
  - 13.9.1. Geração de conteúdo a partir de imagens
  - 13.9.2. Modelagem de distribuições de dados
  - 13.9.3. Uso de redes adversárias
- 13.10. Implementação dos Modelos
  - 13.10.1. Aplicação Prática
  - 13.10.2. Implementação dos modelos
  - 13.10.3. Uso de dados reais
  - 13.10.4. Avaliação de resultados

## Módulo 14. Computação Bioinspirada

- 14.1. Introdução à computação bioinspirada
  - 14.1.1. Introdução à computação bioinspirada
- 14.2. Algoritmos de adaptação social
  - 14.2.1. Computação bioinspirada baseada em colônias de formigas
  - 14.2.2. Variantes dos algoritmos das colônias de formigas
  - 14.2.3. Computação baseada em nuvens de partículas
- 14.3. Algoritmos genéticos
  - 14.3.1. Estrutura geral
  - 14.3.2. Implementações dos principais operadores
- 14.4. Estratégias de exploração do espaço para algoritmos genéticos
  - 14.4.1. Algoritmo CHC
  - 14.4.2. Problemas multimodais
- 14.5. Modelos de computação evolutiva (I)
  - 14.5.1. Estratégias evolutivas
  - 14.5.2. Programação evolutiva
  - 14.5.3. Algoritmos baseados na evolução diferencial
- 14.6. Modelos de computação evolutiva (II)
  - 14.6.1. Modelos de evolução baseados em estimativas de distribuições (EDA)
  - 14.6.2. Programação genética
- 14.7. Programação evolutiva aplicada a dificuldades de aprendizagem
  - 14.7.1. Aprendizagem baseada em regras
  - 14.7.2. Métodos evolutivos em problemas de seleção de instâncias
- 14.8. Problemas multiobjetivo
  - 14.8.1. Conceito de dominância
  - 14.8.2. Aplicação de algoritmos evolutivos a problema multiobjetivo

- 14.9. Redes neurais (I)
    - 14.9.1. Introdução às redes neurais
    - 14.9.2. Exemplo prático com redes neurais
  - 14.10. Redes neurais (II)
    - 14.10.1. Casos de uso de redes neurais na pesquisa médica
    - 14.10.2. Casos de uso de redes neurais em economia
    - 14.10.3. Casos de uso de redes neurais em visão artificial
- Módulo 15. Inteligência Artificial: Estratégias e Aplicações**
- 15.1. Serviços financeiros
    - 15.1.1. As implicações da Inteligência Artificial (IA) nos serviços financeiros: oportunidades e desafios
    - 15.1.2. Casos de uso
    - 15.1.3. Riscos potenciais relacionados ao uso de IA
    - 15.1.4. Potenciais desenvolvimentos/utilizações futuras da IA
  - 15.2. Implicações da Inteligência Artificial na área de saúde
    - 15.2.1. Implicações da IA no setor da saúde Oportunidades e desafios
    - 15.2.2. Casos de uso
  - 15.3. Riscos relacionados ao uso de IA na área de saúde
    - 15.3.1. Riscos potenciais relacionados ao uso de IA
    - 15.3.2. Potenciais desenvolvimentos/utilizações futuras da IA
  - 15.4. *Retail*
    - 15.4.1. Participação da IA no *Retail*. Oportunidades e desafios
    - 15.4.2. Casos de uso
    - 15.4.3. Riscos potenciais relacionados ao uso de IA
    - 15.4.4. Potenciais desenvolvimentos/utilizações futuras da IA
  - 15.5. Indústria
    - 15.5.1. Participação da IA na Indústria. Oportunidades e desafios
    - 15.5.2. Casos de uso
  - 15.6. Riscos potenciais relacionados ao uso de IA na indústria
    - 15.6.1. Casos de uso
    - 15.6.2. Riscos potenciais relacionados ao uso de IA
    - 15.6.3. Potenciais desenvolvimentos/utilizações futuras da IA
  - 15.7. Administração pública
    - 15.7.1. Implicações da IA na administração pública. Oportunidades e desafios
    - 15.7.2. Casos de uso
    - 15.7.3. Riscos potenciais relacionados ao uso de IA
    - 15.7.4. Potenciais desenvolvimentos/utilizações futuras da IA
  - 15.8. Educação
    - 15.8.1. Implicações da IA na educação. Oportunidades e desafios
    - 15.8.2. Casos de uso
    - 15.8.3. Riscos potenciais relacionados ao uso de IA
    - 15.8.4. Potenciais desenvolvimentos/utilizações futuras da IA
  - 15.9. Silvicultura e agricultura
    - 15.9.1. Participação da IA na silvicultura e na agricultura Oportunidades e desafios
    - 15.9.2. Casos de uso
    - 15.9.3. Riscos potenciais relacionados ao uso de IA
    - 15.9.4. Potenciais desenvolvimentos/utilizações futuras da IA
  - 15.10. Recursos Humanos
    - 15.10.1. Participação da IA nos Recursos Humanos Oportunidades e desafios
    - 15.10.2. Casos de uso
    - 15.10.3. Riscos potenciais relacionados ao uso de IA
    - 15.10.4. Potenciais desenvolvimentos/utilizações futuras da IA

## Módulo 16. 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. Desenvolvimento de *dashboards* de controle dinâmico 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. Desenvolvimento de 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 gráficos
  - 16.3.2. Melhoria de modelos de reconhecimento com técnicas de *Transfer Learnin*
  - 16.3.3. Validação de modelos de reconhecimento em mercados em tempo real
- 16.4. Estratégias de *trading* quantitativo com QuantConnect
  - 16.4.1. Construção de sistemas de *trading* algorítmicos com QuantConnect
  - 16.4.2. *Backtesting* de estratégias com QuantConnect
  - 16.4.3. Integração de *Machine Learning* em estratégias de *trading* com QuantConnect
- 16.5. Negociação algorítmica com *Reinforcement Learning* utilizando TensorFlow
  - 16.5.1. Aprendizado por reforço para *trading*
  - 16.5.2. Desenvolvimento de agentes de *trading* com TensorFlow *Reinforcement Learning*
  - 16.5.3. Simulação e ajuste de agentes no OpenAI Gym
- 16.6. Modelagem de séries temporais com LSTM no Keras para previsão de cotações
  - 16.6.1. Aplicação de LSTM para previsão de preços
  - 16.6.2. Implementação de modelos LSTM no Keras para séries temporais financeiras
  - 16.6.3. Otimização e ajuste de parâmetros em modelos de séries temporais
- 16.7. Aplicação de Inteligência Artificial Explicável (XAI) em finanças
  - 16.7.1. Aplicação de XAI em finanças
  - 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) otimizado com modelos de *Machine Learning*
  - 16.8.1. Desenvolvimento de modelos de 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 usando *Machine Learning*
  - 16.9.1. Aplicação de modelos inteligentes para prever volatilidade
  - 16.9.2. Implementação de modelos de com PyTorch
  - 16.9.3. Integração da análise de volatilidade na gestão de riscos de portfólios
- 16.10. Otimização de portfólios com algoritmos genéticos
  - 16.10.1. Fundamentos de algoritmos genéticos para otimização de investimentos em mercados
  - 16.10.2. Implementação de algoritmos genéticos para seleção de portfólios
  - 16.10.3. Avaliação de estratégias de otimização de portfólios

## Módulo 17. Análise Fundamental dos Mercados Financeiros com IA

- 17.1. Modelagem preditiva de desempenho financeiro com Scikit-Learn
  - 17.1.1. Regressão linear e logística para previsões financeiras com Scikit-Learn
  - 17.1.2. Uso de redes neurais com TensorFlow para prever receitas e lucros
  - 17.1.3. Validação de modelos preditivos com *cross-validation* utilizando Scikit-Learn
- 17.2. Avaliação de Empresas com *Deep Learning*
  - 17.2.1. Automatização do modelo de Desconto de Fluxos de Caixa (DCF) com TensorFlow
  - 17.2.2. Modelos avançados de valoração utilizando PyTorch
  - 17.2.3. Integração e análise de múltiplos modelos de valoração com Pandas
- 17.3. Análise de demonstrações financeiras com NLP usando ChatGPT
  - 17.3.1. Extração de informações-chave de relatórios anuais com ChatGPT
  - 17.3.2. Análise de sentimentos em relatórios de analistas e notícias financeiras com ChatGPT
  - 17.3.3. Implementação de modelos de NLP com ChatGPT para interpretação de textos financeiros

- 17.4. Análise de risco e crédito com *Machine Learning*
  - 17.4.1. Modelos de scoring de crédito utilizando SVM e árvores de decisão no Scikit-Learn
  - 17.4.2. Análise de risco de crédito em empresas e títulos com TensorFlow
  - 17.4.3. Visualização de dados de risco com 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 de resultados de crédito com Tableau
- 17.6. Avaliação de sustentabilidade ESG com técnicas de *Data Mining*
  - 17.6.1. Métodos de extração de dados ESG
  - 17.6.2. Modelagem de impacto ESG com técnicas de regressão
  - 17.6.3. Aplicações de análise ESG em decisões de investimento
- 17.7. Benchmarking setorial com Inteligência Artificial utilizando TensorFlow e Power BI
  - 17.7.1. Análise comparativa de empresas utilizando IA
  - 17.7.2. Modelagem preditiva de desempenho setorial com TensorFlow
  - 17.7.3. Implementação de *dashboards* setoriais com Power BI
- 17.8. Gestão de portfólios com otimização de IA
  - 17.8.1. Otimização de portfólios
  - 17.8.2. Uso de técnicas de *Machine Learning* para otimização de portfólios com Scikit-Optimize
  - 17.8.3. Implementar e avaliar a eficácia dos algoritmos na gestão de portfólios
- 17.9. Detecção de fraude financeira com IA utilizando TensorFlow e Keras
  - 17.9.1. Conceitos básicos e técnicas de detecção de fraude com IA
  - 17.9.2. Construção de modelos de detecção com redes neurais em TensorFlow
  - 17.9.3. Implementação prática de sistemas de detecção de fraude em transações financeiras
- 17.10. Análise e modelagem em fusões e aquisições com IA
  - 17.10.1. Uso de modelos preditivos de IA para avaliar fusões e aquisições
  - 17.10.2. Simulação de cenários pós-fusão utilizando técnicas de *Machine Learning*
  - 17.10.3. Avaliação do impacto financeiro de M&A com modelos inteligentes

## Módulo 18. Processamento de Dados Financeiros em Grande Escala

- 18.1. *Big Data* no Contexto financeiro
  - 18.1.1. Características chave de *Big Data* em finanças
  - 18.1.2. Importância dos 5 Vs (Volume, Velocidade, Variedade, Veracidade, Valor) em dados financeiros
  - 18.1.3. Casos de uso de *Big Data* em análise de riscos e conformidade
- 18.2. Tecnologias de armazenamento e gestão de dados massivos financeiros
  - 18.2.1. Sistemas de bancos 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 Apache Kafka e Apache Storm
  - 18.3.2. Aplicações de processamento em tempo real para detecção de fraude
  - 18.3.3. Benefícios do processamento em tempo real em *trading* algorítmico
- 18.4. Integração e limpeza de dados em finanças
  - 18.4.1. Métodos e ferramentas para a integração de dados de múltiplas fontes
  - 18.4.2. Técnicas de limpeza de dados para garantir a qualidade e precisão
  - 18.4.3. Desafios na normalização de dados financeiros
- 18.5. Técnicas de mineração de dados posicionamento nos mercados padrões financeiros
  - 18.5.1. Algoritmos de classificação e predição em dados de mercado
  - 18.5.2. Análise de sentimentos em redes sociais para prever movimentos de mercado
  - 18.5.3. Mineração de dados para identificar padrões de *trading* e comportamento do investidor
- 18.6. Visualização avançada de dados para análise financeira
  - 18.6.1. Ferramentas e software de visualização para dados financeiros
  - 18.6.2. Design de dashboards interativos para acompanhamento de mercados
  - 18.6.3. O papel da visualização na comunicação de análise de risco
- 18.7. Uso de Hadoop e ecossistemas relacionados em finanças
  - 18.7.1. Componentes chave do ecossistema Hadoop e sua aplicação em finanças
  - 18.7.2. Casos de uso de Hadoop para a análise de grandes volumes de transações
  - 18.7.3. Vantagens e desafios de integrar Hadoop em infraestruturas financeiras existentes

- 18.8. Aplicações de Spark na análise financeira
  - 18.8.1. Spark para análise de dados em tempo real e batch
  - 18.8.2. Construção de modelos preditivos usando Spark MLlib
  - 18.8.3. Integração de Spark com outras ferramentas de Big Data em finanças
- 18.9. Segurança e privacidade dos dados no setor financeiro
  - 18.9.1. Normativas e regulamentações em proteção de dados (GDPR, CCPA)
  - 18.9.2. Estratégias de criptografia e gestão de acesso para dados sensíveis
  - 18.9.3. Impacto das violações de dados em instituições financeiras
- 18.10. Impacto da computação em nuvem na análise financeira em larga escala
  - 18.10.1. Vantagens da nuvem para escalabilidade e eficiência na análise financeira
  - 18.10.2. Comparação de provedores de nuvem e seus serviços específicos para finanças
  - 18.10.3. Casos de estudo sobre migração para a nuvem em grandes entidades financeiras

## Módulo 19. Estratégias de *Trading* Algorítmico

- 19.1. Fundamentos do *trading* algorítmico
  - 19.1.1. Estratégias de *Trading* Algorítmico
  - 19.1.2. Tecnologias chave e plataformas para o desenvolvimento de algoritmos de *trading*
  - 19.1.3. Vantagens e desafios do *trading* automatizado frente ao *trading* manual
- 19.2. Design de sistemas de *trading* automatizado
  - 19.2.1. Estrutura e componentes de um sistema de *trading* automatizado
  - 19.2.2. Programação de algoritmos: da ideia à implementação
  - 19.2.3. Considerações de latência e hardware em sistemas de *trading*
- 19.3. Backtesting e avaliação de estratégias de *trading*
  - 19.3.1. Metodologias para o *backtesting* eficaz de estratégias algorítmicas
  - 19.3.2. Importância dos dados históricos de qualidade no *backtesting*
  - 19.3.3. Indicadores chave de desempenho para avaliar estratégias de *trading*
- 19.4. Otimização de Estratégias com *Machine Learning*
  - 19.4.1. Aplicação de técnicas de aprendizado supervisionado na melhoria de estratégias
  - 19.4.2. Uso de otimização por enxame de partículas e algoritmos genéticos
  - 19.4.3. Desafios de sobreajuste na otimização de estratégias de *trading*
- 19.5. *Trading* de Alta Frequência (HFT)
  - 19.5.1. Princípios e tecnologias por trás do HFT
  - 19.5.2. Impacto do HFT na liquidez e na volatilidade do mercado
  - 19.5.3. Estratégias comuns de HFT e sua efetividade
- 19.6. Algoritmos de execução de ordens
  - 19.6.1. Tipos de algoritmos de execução e sua aplicação prática
  - 19.6.2. Algoritmos para a minimização do impacto no mercado
  - 19.6.3. Uso de simulações para melhorar a execução de ordens
- 19.7. Estratégias de arbitragem nos mercados financeiros
  - 19.7.1. Arbitragem estatística e de fusão de preços em mercados
  - 19.7.2. Arbitragem de índices e ETFs
  - 19.7.3. Desafios técnicos e legais da arbitragem no *trading* moderno
- 19.8. Gestão de risco em *trading* algorítmico
  - 19.8.1. Medidas de risco para *trading* algorítmico
  - 19.8.2. Integração de limites de risco e stop-loss em algoritmos
  - 19.8.3. Riscos específicos do *trading* algorítmico e como mitigá-los
- 19.9. Aspectos regulatórios e conformidade em *trading* algorítmico
  - 19.9.1. Normativas globais que impactam o *trading* algorítmico
  - 19.9.2. Conformidade e relatórios regulatórios em um ambiente automatizado
  - 19.9.3. Implicações éticas do *trading* automatizado
- 19.10. Futuro do *trading* algorítmico e tendências emergentes
  - 19.10.1. 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 uso de IA em finanças
  - 20.1.2. Casos de estudo sobre dilemas éticos em aplicações financeiras de IA
  - 20.1.3. Desenvolvimento de códigos de conduta ética para profissionais em tecnologia financeira
- 20.2. Regulamentações globais que afetam o uso de IA nos mercados financeiros
  - 20.2.1. Panorama das principais regulamentações financeiras internacionais sobre IA
  - 20.2.2. Comparação de políticas regulatórias de IA entre diferentes jurisdições
  - 20.2.3. Implicações da regulamentação da IA na inovação financeira
- 20.3. Transparência e explicabilidade dos modelos de IA em finanças
  - 20.3.1. Importância da transparência nos algoritmos de IA para a confiança do usuário
  - 20.3.2. Técnicas e ferramentas para melhorar a explicabilidade dos modelos de IA
  - 20.3.3. Desafios na implementação de modelos interpretáveis em ambientes financeiros complexos
- 20.4. Gestão do risco e conformidade ética no uso de IA
  - 20.4.1. Estratégias de mitigação de riscos associados ao implantação de IA em finanças
  - 20.4.2. Conformidade ética no desenvolvimento e aplicação de tecnologias de IA
  - 20.4.3. Supervisão e auditorias éticas de sistemas de IA em operações financeiras
- 20.5. Impacto social e econômico da IA nos mercados financeiros
  - 20.5.1. Efeitos da IA na estabilidade e eficiência dos mercados financeiros
  - 20.5.2. IA e seu impacto no emprego e nas habilidades profissionais em finanças
  - 20.5.3. Benefícios e riscos sociais da automação financeira em larga escala
- 20.6. Privacidade de dados e proteção em aplicações financeiras de IA
  - 20.6.1. Normativas sobre privacidade de dados aplicáveis a tecnologias de IA em finanças
  - 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 de análise
- 20.7. Viés algorítmico e justiça em modelos financeiros de IA
  - 20.7.1. Identificação e mitigação de viés em algoritmos de IA financeira
  - 20.7.2. Estratégias para garantir a equidade nos modelos de tomada de decisões automáticos
  - 20.7.3. Impacto do viés algorítmico na inclusão e equidade financeira
- 20.8. Desafios da supervisão regulatória na IA financeira
  - 20.8.1. Dificuldades na supervisão e controle de tecnologias avançadas de IA
  - 20.8.2. Papel das autoridades financeiras na supervisão contínua da IA
  - 20.8.3. Necessidade de adaptação regulatória diante do avanço da tecnologia de IA
- 20.9. Estratégias para o desenvolvimento responsável de tecnologias de IA em finanças
  - 20.9.1. Melhores práticas para o desenvolvimento sustentável e responsável de IA no setor financeiro
  - 20.9.2. Iniciativas e *frameworks* para a avaliação ética de projetos de IA em finanças
  - 20.9.3. Colaboração entre entidades regulatórias e empresas para fomentar práticas responsáveis
- 20.10. Futuro da regulação da IA no setor financeiro
  - 20.10.1. Tendências emergentes e desafios futuros na regulação da IA em finanças
  - 20.10.2. Preparação de marcos legais para inovações disruptivas em tecnologia financeira
  - 20.10.3. Diálogo internacional e cooperação para uma regulação efetiva e unificada da IA em finanças



*Receberá uma formação sólida e atualizada, combinando teoria avançada com aplicações práticas para liderar na interseção da Inteligência Artificial e das finanças"*

06

# Metodología

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



“

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

## Estudo de caso para contextualizar todo o conteúdo

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

“

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



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



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

## Um método de aprendizagem inovador e diferente

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

“

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

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

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

## Metodologia Relearning

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

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

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

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

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



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

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

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

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



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



#### Material de estudo

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

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



#### Masterclasses

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

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



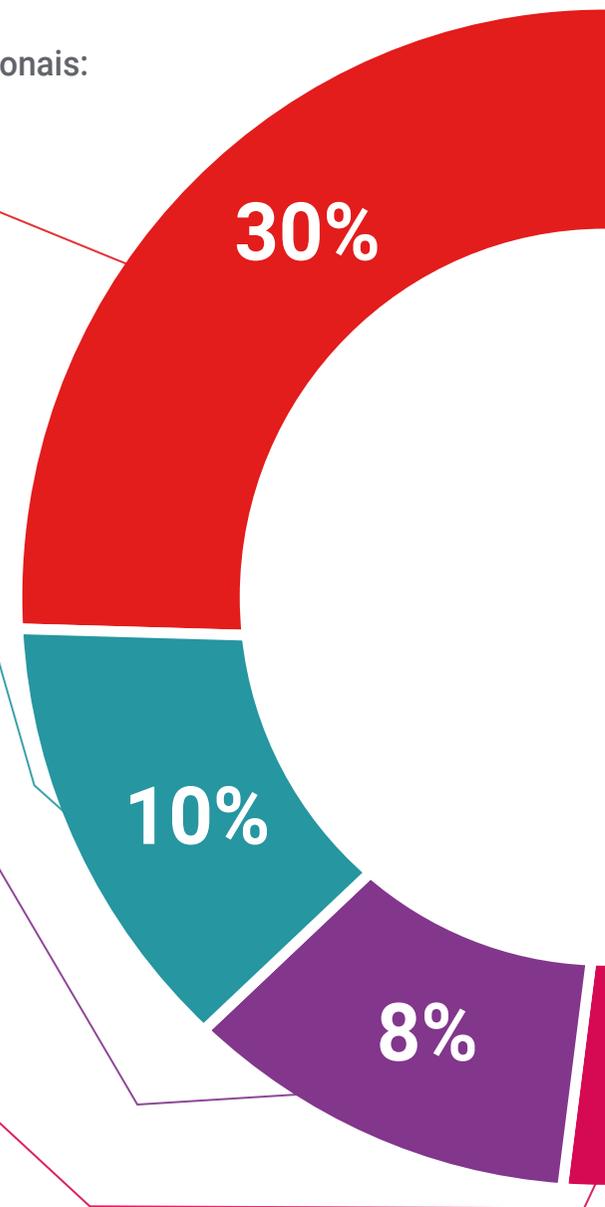
#### Práticas de habilidades e competências

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



#### Leituras complementares

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





#### Estudos de caso

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



#### Resumos interativos

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

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



#### Testing & Retesting

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



07

# Certificado

O Mestrado Próprio em Inteligência Artificial nas Bolsas de Valores e nos Mercados Financeiros garante, além da capacitação mais rigorosa e atualizada, o acesso a um título de Mestrado Próprio emitido pela TECH Universidade Tecnológica.



“

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

Este **Mestrado Próprio em Inteligência Artificial nas Bolsas de Valores e nos Mercados Financeiros** conta com o conteúdo mais completo e atualizado do mercado.

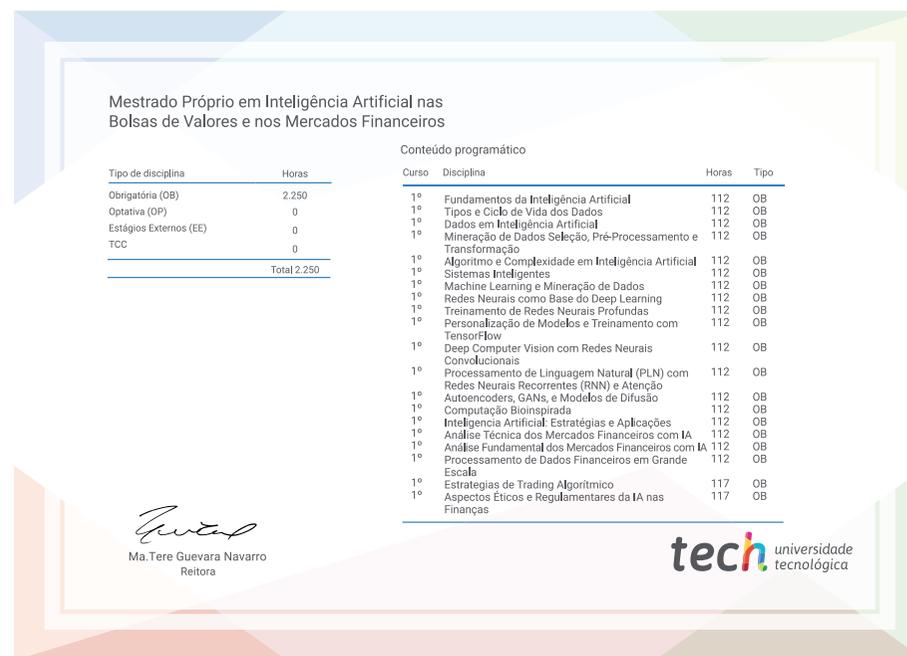
Uma vez aprovadas as avaliações, o aluno receberá por correio o certificado\* correspondente ao título de **Mestrado Próprio** emitido pela **TECH Universidade Tecnológica**.

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

Título: **Mestrado Próprio em Inteligência Artificial nas Bolsas de Valores e nos Mercados Financeiros**

Modalidade: **online**

Duração: **7 meses**



\*Apostila de Haia: Caso o aluno solicite que seu certificado seja apostilado, a TECH Universidade Tecnológica providenciará a obtenção do mesmo a um custo adicional.

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

**tech** universidade  
tecnológica

**Mestrado Próprio**  
Inteligência Artificial nas  
Bolsas de Valores e nos  
Mercados Financeiros

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

# Mestrado Próprio

Inteligência Artificial nas Bolsas de  
Valores e nos Mercados Financeiros