

Mestrado

Deep Learning



Mestrado Deep Learning

- » Modalidade: online
- » Duração: 12 meses
- » Certificação: TECH Global University
- » Acreditação: 60 ECTS
- » Horário: ao seu próprio ritmo
- » Exames: online

Acesso ao site: www.techtitute.com/pt/engenharia/mestrado/mestrado-deep-learning



Índice

01

Apresentação

pág. 4

02

Objetivos

pág. 8

03

Competências

pág. 14

04

Direção do curso

pág. 18

05

Estrutura e conteúdo

pág. 22

06

Metodología de estudio

pág. 32

07

Certificação

pág. 42

01

Apresentação

Desde o reconhecimento de voz e a tradução automática dos vídeos do YouTube, até à interpretação de objetos e formas do Google Fotos, passando pelo método antifraude utilizado pela Banca Privada, tudo está sustentado no *Deep Learning*. O progresso na automatização, na análise e deteção de imagens, e na previsão para a tomada de decisões de forma rápida, fez com que o perfil do profissional engenheiro se tornasse ainda mais relevante. Uma tarefa que contribui para o crescimento de outros setores, pelo que é necessário contar com autênticos especialistas nesta área. Por essa razão, nasce esta qualificação 100% online, que leva o profissional a adquirir um conhecimento avançado para desenvolver Inteligência Artificial e projetos de Aprendizagem Profunda. Tudo isto, além disso, com um material didático inovador e atualizado, elaborado por autênticos especialistas com vasta experiência no setor.



“

*Eleve o seu nível de conhecimento em
Deep Learning com este Mestrado de
1.800 horas letivas. Increva-se já”*

Sem dúvida, um dos setores de maior crescimento nos últimos anos tem sido o tecnológico, impulsionado pelos avanços que a engenharia trouxe com o desenvolvimento do Aprendizado Profundo. Desta forma, proliferam os Chatbots, as aplicações de reconhecimento facial, a deteção precoce de doenças como o câncer, com a identificação de imagens médicas de maior qualidade.

Um sem-fim de possibilidades que requer um domínio profundo do *Deep Learning* por parte dos profissionais de Engenharia. Neste sentido, a TECH impulsionou o desenvolvimento deste Mestrado de 12 meses de duração, que oferece ao estudante o conhecimento mais avançado e atual nesta área.

Trata-se de uma qualificação que levará o profissional a aprofundar os fundamentos matemáticos, a construção de redes neurais, a personalização de modelos e treinamentos com o TensorFlow, ou a explorar o *Deep Computer Vision* com Redes Neuronais Convolucionais. Tudo isto, além disso, com material didático baseado em vídeos-resumo de cada tema, vídeos detalhados, leituras especializadas e casos de estudo a que poderá aceder, confortavelmente, 24 horas por dia, de qualquer dispositivo eletrônico com conexão à internet.

Um plano de estudos que lhe permitirá potenciar as suas habilidades para criar projetos que se concentram na análise de dados, no processamento de linguagem natural ou têm aplicação direta em áreas como a Robótica, as Finanças, o *Gaming* ou os carros autónomos, entre outros.

Desta forma, a TECH abre um mundo de possibilidades graças a uma especialização de qualidade, elaborada por autênticos especialistas e que oferece uma maior liberdade na autogestão dos estudos. E é que, sem presencialidade nem aulas com horários rígidos, o aluno poderá aceder ao plano de estudos a qualquer momento e conciliar as suas atividades diárias com uma aprendizagem que se encontra na vanguarda acadêmica.

Este **Mestrado em Deep Learning** conta com o conteúdo educacional mais completo e atualizado do mercado. As suas principais características são:

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



Esta face uma qualificação universitária que dar-lhe-á o impulso necessário para fazer parte das grandes empresas tecnológicas do momento. Inscreva-se já"

“

Com esta especialização, não precisa de preocupar-se com a frequência das aulas, não tem de estar presente nas aulas e não tem um horário fixo. Aceda à agenda, quando e onde quiser”

Domine os GANS e os Modelos de Difusão e melhore os seus projetos para gerar imagens novas, realistas e de alta qualidade.

Um curso que permitir-lhe-á aprofundar o Backward Pass e a forma como se aplicam as derivadas de funções vetoriais para aprender automaticamente.

O curso inclui no seu corpo docente, profissionais do setor que trazem a experiência do seu trabalho para esta formação, bem como especialistas reconhecidos das principais sociedades e universidades de prestígio.

O seu conteúdo multimédia, desenvolvido com a mais recente tecnologia educativa, permitirá ao profissional uma aprendizagem situada e contextual, ou seja, um ambiente simulado que proporcionará uma formação imersiva programada para treinar-se em situações reais.


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



02

Objetivos

A TECH disponibiliza a todos os seus alunos numerosos materiais pedagógicos inovadores para que, em somente 12 meses, possam obter os conhecimentos necessários em Deep Learning que lhes permitirão crescer num dos setores mais vanguardistas da atualidade. Assim, no final desta qualificação, o profissional terá desenvolvido as competências e capacidades necessárias para participar em projetos de Inteligência Artificial e Aprendizagem Profunda destinados a melhorar diferentes setores socioeconómicos.






66

Obterá o conhecimento de que necessita para criar ambientes OpenAI e progredir na sua carreira”



Objetivos gerais

- Fundamentar os conceitos chave das funções matemáticas e das suas derivadas
- Aplicar estes princípios aos algoritmos de aprendizagem profunda para aprender automaticamente
- Examinar os conceitos chave do Aprendizagem Supervisionada e como se aplicam aos modelos de redes neurais
- Analisar o treino, a avaliação e a análise dos modelos de redes neurais
- Fundamentar os conceitos chave e as principais aplicações da aprendizagem profunda
- Implementar e otimizar redes neurais com o Keras
- Desenvolver conhecimento especializado sobre o treino de redes neurais profundas
- Analisar os mecanismos de otimização e regularização necessários para o treino de redes profundas





Objetivos específicos

Módulo 1. Fundamentos Matemáticos de Deep Learning

- ♦ Desenvolver a regra da cadeia para calcular derivadas de funções aninhadas
- ♦ Analisar como se criam novas funções a partir de funções existentes e como se calculam as derivadas das mesmas
- ♦ Examinar o conceito do Backward Pass e como se aplicam as derivadas das funções vetoriais para aprender automaticamente
- ♦ Aprender sobre como usar o TensorFlow para construir modelos personalizados
- ♦ Compreender como carregar e processar dados utilizando ferramentas do TensorFlow
- ♦ Fundamentar os conceitos chave do processamento de linguagem natural NLP com RNN e mecanismos de atenção
- ♦ Explorar a funcionalidade das bibliotecas de transformers da Hugging Face e outras ferramentas de processamento de linguagem natural para aplicar a problemas de visão
- ♦ Aprender a construir e treinar modelos de autoencoders, GANs e modelos de difusão
- ♦ Compreender como os autoencoders podem ser utilizados para codificar dados de forma eficiente

Módulo 2. Princípios de Deep Learning

- ♦ Analisar o funcionamento da regressão linear e como pode ser aplicada aos modelos de redes neurais
- ♦ Fundamentar a otimização dos hiperparâmetros para melhorar o desempenho dos modelos de redes neurais
- ♦ Determinar como se pode avaliar o desempenho dos modelos de redes neurais através do uso do conjunto de treino e do conjunto de teste

Módulo 3. As redes Neuronais, a base do Deep Learning

- Analisar a arquitetura das redes neuronais e os seus princípios de funcionamento
- Determinar como podem ser aplicadas as redes neuronais a uma variedade de problemas
- Estabelecer como otimizar o desempenho dos modelos de aprendizagem profunda através do ajuste dos hiperparâmetros

Módulo 4. Treino de Redes Neuronais profundas

- Analisar os problemas de gradiente e como se podem evitar
- Determinar como reutilizar camadas pré-treinadas para treinar redes neuronais profundas
- Estabelecer como programar a taxa de aprendizagem para obter os melhores resultados

Módulo 5. Personalização de Modelos e Treino com TensorFlow

- Determinar como usar a API do TensorFlow para definir funções e gráficos personalizados
- Fundamentar o uso da API tf.data para carregar e pré-processar os dados de forma eficiente
- Discutir o projeto TensorFlow Datasets e como se pode usar para facilitar o acesso a conjuntos de dados pré-processados

Módulo 6. Deep Computer Vision com Redes Neuronais Convolucionais

- Explorar e entender como funcionam as camadas convolucionais e de agrupamento para a arquitetura do CórTEX Visual
- Desenvolver arquiteturas CNN com Keras
- Usar modelos pré-treinados de Keras para classificação, localização, deteção e acompanhamento de objetos, assim como para segmentação semântica



Módulo 7. Sequências de processamento utilizando RNN e CNN

- ♦ Analisar a arquitetura das neurônios e camadas recorrentes
- ♦ Examinar os diversos algoritmos de treino para o treinamento de modelos RNN
- ♦ Avaliar o desempenho dos modelos RNN utilizando métricas de exatidão e sensibilidade

Módulo 8. Processamento da Linguagem Natural PLN com RNN e Atenção

- ♦ Gerar texto utilizando redes neuronais recorrentes
- ♦ Treinar uma rede codificador-decodificador para realizar tradução automática neuronal
- ♦ Desenvolver uma aplicação prática de processamento de linguagem natural com RNN e atenção

Módulo 9. Autoencoders, GANs e Modelos de Difusão

- ♦ Implementar técnicas de PCA com um codificador automático linear incompleto
- ♦ Utilizar autoencoders convolucionais e variacionais para melhorar os resultados dos autoencoders
- ♦ Analisar como as GANs e os modelos de difusão podem gerar imagens novas e realistas

Módulo 10. Reinforcement Learning

- ♦ Utilizar gradientes para otimizar a política de um agente
- ♦ Avaliar o uso de redes neuronais para melhorar a precisão de um agente ao tomar decisões
- ♦ Implementar diferentes algoritmos de reforço para melhorar o desempenho de um agente

03

Competências

Esta qualificação avançada permite ao estudante investigar, desenvolver e projetar sistemas de Inteligência Artificial que automatizem modelos preditivos. São capacidades e habilidades técnicas que conseguirá potenciar ao longo deste percurso académico, graças não só ao enfoque teórico deste ensino, mas também à perspetiva prática que obterá através dos cenários de simulações. Uma oportunidade única de progressão que só oferece a TECH, a maior universidade digital do mundo”



66

Aperfeiçoe as suas capacidades para gerar chatbots que compreendam e respondam de forma mais adequada às perguntas dos utilizadores”



Competências gerais

- Implementar arquitetura do CórTEX Visual
- Utilizar modelos pré-treinados de Keras para o aprendizado por transferência e outras tarefas de visão computacional
- Dominar a Rede Neuronal Recorrente (RNN)
- Treinar e avaliar um modelo RNN para a previsão de séries temporais
- Melhorar a capacidade de um agente para tomar decisões ótimas em um ambiente
- Aumentar a eficiência de um agente ao aprender com recompensas

“

Obtenha uma visão prática e real da aplicação do processamento da linguagem natural com RNN e atenção graças a esta qualificação”





Competências específicas

- ♦ Resolver problemas com dados, o que implica melhorar processos existentes e desenvolver novos processos através do uso de ferramentas tecnológicas adequadas
- ♦ Implementar projetos e tarefas baseadas em dados
- ♦ Utilizar métricas como a precisão, a exatidão e o erro de classificação
- ♦ Otimizar os parâmetros de uma rede neuronal
- ♦ Construir modelos personalizados utilizando a API do TensorFlow
- ♦ Implementar com Keras tarefas como a classificação, a localização, a deteção e o acompanhamento de objetos, assim como a segmentação semântica
- ♦ Gerar imagens novas e realistas
- ♦ Implementar Deep Q-Learning e variantes do Deep Q-Learning
- ♦ Utilizar técnicas de otimização para o treino
- ♦ Treinar com sucesso redes neurais profundas

04

Direção do curso

Esta instituição académica dedicou todos os seus esforços a reunir uma excelente equipa de especialistas em *Deep Learning* e na sua aplicação em diversos setores. Desta forma, o profissional de engenharia terá a garantia de aceder a um plano de estudos de qualidade e de grande valor para a sua progressão num setor em crescimento. Além disso, graças à proximidade dos docentes, o estudante poderá esclarecer qualquer dúvida que tenha sobre o conteúdo deste ensino ao longo do seu percurso académico.



“

Especialistas com vasto domínio de
TensorFlow, arquitetura em streaming,
Machine Learning ou Big Data integram
esta excelente qualificação universitária”

Direção



Sr. Gil Contreras, Armando

- ◆ Lead Big Data Scientist-Big Data em Johnson Controls
- ◆ Data Scientist-Big Data em Opensistemas
- ◆ Auditor de Fundos em Criatividade e Tecnologia e na PricewaterhouseCoopers
- ◆ Docente na EAE Business School
- ◆ Licenciatura em Economia pelo Instituto Tecnológico de Santo Domingo INTEC
- ◆ Mestrado em Data Science no Centro Universitário de Tecnologia e Arte
- ◆ Mestrado MBA em Relações e Negócios Internacionais no Centro de Estudos Financeiros CEF
- ◆ Pós-graduação em Finanças Corporativas no Instituto Tecnológico de Santo Domingo

Professores

Sr. Villar Valor, Javier

- ◆ Diretor e sócio fundador Impulsa2
- ◆ Chefe de Operações da Summa Insurance Brokers
- ◆ Responsável por identificar oportunidades de melhoria na Liberty Seguros
- ◆ Diretor de Transformação e Excelência Profissional na Johnson Controls Iberia
- ◆ Responsável pela organização da empresa Groupama Seguros
- ◆ Responsável pela metodologia Lean Six Sigma na Honeywell
- ◆ Diretor de qualidade e compras na SP & PO
- ◆ Docente na Escola Europeia de Negócios

Sr. Matos Rodríguez, Dionis

- ◆ Data Engineer em Wide Agency Sodexo
- ◆ Data Consultant em Tokiota Site
- ◆ Data Engineer em Devoteam Testa Home
- ◆ Business Intelligence Developer em Ibermatica Daimler
- ◆ Mestrado em Big Data and Analytics / Project Management (Minor) na EAE Business School



Sra. Delgado Feliz, Benedit

- ♦ Assistente e Operadora de Vigilância Eletrônica na Direção Nacional de Controle de Drogas
- ♦ Comunicação Social pela Universidade Católica de Santo Domingo
- ♦ Locução pela Escola de Locução Profissional Otto Rivera


Sra. Gil de León, María

- ♦ Codiretora de Marketing e secretária na RAÍZ Magazine
- ♦ Editora de Cópia na Gauge Magazine
- ♦ Leitora da Stork Magazine pelo Emerson College
- ♦ Licenciatura em Escrita, Literatura e Publicação concedida pelo Emerson College

05

Estrutura e conteúdo

Graças ao método *Relearning*, baseado na repetição contínua de conceitos-chave ao longo deste itinerário académico, o engenheiro conseguirá uma aprendizagem avançada e eficaz, sem necessidade de investir grandes quantidades de horas de estudo. Desta forma, poderá aprofundar um currículo abrangente sobre a codificação de modelos de aprendizagem profunda, técnicas avançadas de otimização, treino de redes neurais profundas, visualização de resultados e avaliação de modelos de aprendizagem profunda.



“

Aceda, a partir do seu dispositivo digital com ligação à Internet, ao conteúdo programático mais avançado e atualizado de Deep Learning no panorama académico”

Módulo 1. Fundamentos Matemáticos de Deep Learning

- 1.1. Funções e Derivadas
 - 1.1.1. Funções lineares
 - 1.1.2. Derivadas parciais
 - 1.1.3. Derivadas de ordem superior
- 1.2. Funções aninhadas
 - 1.2.1. Funções compostas
 - 1.2.2. Funções inversas
 - 1.2.3. Funções recursivas
- 1.3. A regra da cadeia
 - 1.3.1. Derivadas de funções aninhadas
 - 1.3.2. Derivadas de funções compostas
 - 1.3.3. Derivadas de funções inversas
- 1.4. Funções com múltiplas entradas
 - 1.4.1. Funções de várias variáveis
 - 1.4.2. Funções vetoriais
 - 1.4.3. Funções matriciais
- 1.5. Derivadas de funções com entradas múltiplas
 - 1.5.1. Derivadas parciais
 - 1.5.2. Derivadas direcionais
 - 1.5.3. Derivadas mistas
- 1.6. Funções com múltiplas entradas vetoriais
 - 1.6.1. Funções vetoriais lineares
 - 1.6.2. Funções vetoriais não lineares
 - 1.6.3. Funções vetoriais de matriz
- 1.7. Criação de novas funções a partir de funções existentes
 - 1.7.1. Soma de funções
 - 1.7.2. Produto de funções
 - 1.7.3. Composição de funções
- 1.8. Derivadas de funções com múltiplas entradas vetoriais
 - 1.8.1. Derivadas de funções lineares
 - 1.8.2. Derivadas de funções não lineares
 - 1.8.3. Derivadas de funções compostas

- 1.9. Funções vetoriais e suas derivadas: Um passo além

- 1.9.1. Derivadas direcionais

- 1.9.2. Derivadas mistas

- 1.9.3. Derivadas matriciais

- 1.10. O Backward Pass

- 1.10.1. Propagação de erros

- 1.10.2. Aplicação de regras de atualização

- 1.10.3. Otimização de parâmetros

Módulo 2. Princípios de Deep Learning

- 2.1. O Aprendizado Supervisado

- 2.1.1. Máquinas de aprendizado supervisado

- 2.1.2. Usos do aprendizado supervisado

- 2.1.3. Diferenças entre aprendizado supervisado e não supervisado

- 2.2. Modelos de aprendizado supervisado

- 2.2.1. Modelos lineares

- 2.2.2. Modelos de árvores de decisão

- 2.2.3. Modelos de redes neuroniais

- 2.3. Regressão linear

- 2.3.1. Regressão linear simples

- 2.3.2. Regressão linear múltipla

- 2.3.3. Análise de regressão

- 2.4. Treino do modelo

- 2.4.1. *Batch Learning*

- 2.4.2. *Online Learning*

- 2.4.3. Métodos de Otimização

- 2.5. Avaliação do modelo: Conjunto de treino versus conjunto de teste

- 2.5.1. Métricas de avaliação

- 2.5.2. Validação cruzada

- 2.5.3. Comparação de conjuntos de dados

- 2.6. Avaliação do modelo: O código

- 2.6.1. Geração de previsões

- 2.6.2. Análise de erros

- 2.6.3. Métricas de avaliação

- 2.7. Análise das variáveis
 - 2.7.1. Identificação de variáveis relevantes
 - 2.7.2. Análise de correlação
 - 2.7.3. Análise de regressão
- 2.8. Explicabilidade dos modelos de redes neuronais
 - 2.8.1. Modelos interpretáveis
 - 2.8.2. Métodos de visualização
 - 2.8.3. Métodos de avaliação
- 2.9. Otimização
 - 2.9.1. Métodos de otimização
 - 2.9.2. Técnicas de regularização
 - 2.9.3. A utilização de gráficos
- 2.10. Hiperparâmetros
 - 2.10.1. Seleção de hiperparâmetros
 - 2.10.2. Pesquisa de parâmetros
 - 2.10.3. Ajuste de hiperparâmetros

Módulo 3. As redes neuronais, a base da Deep Learning


- 3.1. Aprendizagem Profunda
 - 3.1.1. Tipos de aprendizagem profunda
 - 3.1.2. Aplicações da aprendizagem profunda
 - 3.1.3. Vantagens e desvantagens da aprendizagem profunda
- 3.2. Operações
 - 3.2.1. Adição
 - 3.2.2. Produto
 - 3.2.3. Transferência
- 3.3. Camadas
 - 3.3.1. Camada de entrada
 - 3.3.2. Camada oculta
 - 3.3.3. Camada de saída
- 3.4. Ligação de Camadas e Operações
 - 3.4.1. Design de arquiteturas
 - 3.4.2. Conexão entre camadas
 - 3.4.3. Propagação para a frente

- 3.5. Construção da primeira rede neuronal
 - 3.5.1. Design da rede
 - 3.5.2. Estabelecer os pesos
 - 3.5.3. Treino da rede
- 3.6. Treinador e Otimizador
 - 3.6.1. Seleção do otimizador
 - 3.6.2. Estabelecimento de uma função de perda
 - 3.6.3. Estabelecimento de uma métrica
- 3.7. Aplicação dos Princípios das Redes Neuronais
 - 3.7.1. Funções de ativação
 - 3.7.2. Propagação para trás
 - 3.7.3. Ajuste dos parâmetros
- 3.8. Dos neurónios biológicos aos neurónios artificiais
 - 3.8.1. Funcionamento de um neurónio biológico
 - 3.8.2. Transferência de conhecimentos para os neurónios artificiais
 - 3.8.3. Estabelecer de relações entre os dois
- 3.9. Implementação do MLP (Perceptron Multicamadas) com o Keras
 - 3.9.1. Definição da estrutura da rede
 - 3.9.2. Compilação do modelo
 - 3.9.3. Treino do modelo
- 3.10. Hiperparâmetros de Fine tuning de Redes Neuronais
 - 3.10.1. Seleção da função de ativação
 - 3.10.2. Estabelecer o *learning rate*
 - 3.10.3. Ajuste dos pesos

Módulo 4. Treino de redes neuronais profundas

- 4.1. Problemas de Gradientes
 - 4.1.1. Técnicas de otimização de gradiente
 - 4.1.2. Gradientes Estocásticos
 - 4.1.3. Técnicas de inicialização de pesos
- 4.2. Reutilização de camadas pré-treinadas
 - 4.2.1. Treino de transferência de aprendizagem
 - 4.2.2. Extração de características
 - 4.2.3. Aprendizagem profunda

- 4.3. Otimizadores
 - 4.3.1. Otimizadores estocásticos de gradiente descendente
 - 4.3.2. Otimizadores Adam e RMSprop
 - 4.3.3. Otimizadores de momento
- 4.4. Programação da taxa de aprendizagem
 - 4.4.1. Controlo de taxa sobre aprendizagem automática
 - 4.4.2. Ciclos de aprendizagem
 - 4.4.3. Termos de suavização
- 4.5. Sobreajuste
 - 4.5.1. Validação cruzada
 - 4.5.2. Regularização
 - 4.5.3. Métricas de avaliação
- 4.6. Orientações práticas
 - 4.6.1. Design do modelo
 - 4.6.2. Seleção de métricas e parâmetros de avaliação
 - 4.6.3. Teste de hipóteses
- 4.7. *Transfer learning*
 - 4.7.1. Treino de transferência de aprendizagem
 - 4.7.2. Extração de caraterísticas
 - 4.7.3. Aprendizagem profunda
- 4.8. *Data Augmentation*
 - 4.8.1. Transformações de imagem
 - 4.8.2. Geração de dados sintéticos
 - 4.8.3. Transformação de texto
- 4.9. Aplicação Prática de *Transfer Learning*
 - 4.9.1. Treino de transferência de aprendizagem
 - 4.9.2. Extração de caraterísticas
 - 4.9.3. Aprendizagem profunda
- 4.10. Regularização
 - 4.10.1. L1 e L2
 - 4.10.2. Regularização por entropia máxima
 - 4.10.3. *Dropout*



Módulo 5. Personalização de modelos e treino com TensorFlow

- 5.1. TensorFlow
 - 5.1.1. Uso da biblioteca TensorFlow
 - 5.1.2. Treino de modelos com o TensorFlow
 - 5.1.3. Operações de gráfico no TensorFlow
- 5.2. TensorFlow e NumPy
 - 5.2.1. Ambiente computacional NumPy para TensorFlow
 - 5.2.2. Utilização das arrays NumPy com TensorFlow
 - 5.2.3. Operações NumPy para o TensorFlow gráficos do TensorFlow
- 5.3. Personalização de modelos e algoritmos de treino
 - 5.3.1. Construir modelos personalizados com o TensorFlow
 - 5.3.2. Gestão dos parâmetros de treino
 - 5.3.3. Utilização de técnicas de otimização para o treino
- 5.4. Funções e gráficos do TensorFlow
 - 5.4.1. Funções com o TensorFlow
 - 5.4.2. Utilização de gráficos para treino de modelos
 - 5.4.3. Otimização de gráficos com operações do TensorFlow
- 5.5. Carregamento e pré-processamento de dados com TensorFlow
 - 5.5.1. Carga de conjuntos de dados com o TensorFlow
 - 5.5.2. Préprocessamento de dados com o TensorFlow
 - 5.5.3. Utilizar de ferramentas do TensorFlow para a manipulação de dados
- 5.6. A API tf.data
 - 5.6.1. Utilização da API tf.data para o processamento de dados
 - 5.6.2. Construção de fluxo de dados com tf.data
 - 5.6.3. Utilização da API tf.data para o treino de modelos
- 5.7. O formato TFRecord
 - 5.7.1. Utilização da API TFRecord para a serialização de dados
 - 5.7.2. Carregar arquivos TFRecord com TensorFlow
 - 5.7.3. Utilização de arquivos TFRecord para o treino de modelos
- 5.8. Camadas de pré-processamento do Keras
 - 5.8.1. Utilização da API de pré-processamento do Keras
 - 5.8.2. Construção de pipelined de pré-processamento com o Keras
 - 5.8.3. Utilização da API de pré-processamento do Keras para o treino de modelos

5.9. O projeto TensorFlow Datasets

- 5.9.1. Usando conjuntos de dados do TensorFlow para carregamento de dados
 - 5.9.2. Pré-processamento de dados com conjuntos de dados TensorFlow
 - 5.9.3. Utilização de TensorFlow Datasets para o treino de modelos
- 5.10. Construção de uma Aplicação de Deep Learning com TensorFlow. Aplicação Prática
 - 5.10.1. Construção de uma aplicação de Deep Learning com TensorFlow
 - 5.10.2. Treinar um modelo com TensorFlow
 - 5.10.3. Utilizar a aplicação para previsão de resultados

Módulo 6. Deep Computer Vision com Redes Neuronais Convolucionais

- 6.1. A Arquitetura Visual Cortex
 - 6.1.1. Funções do córtex visual
 - 6.1.2. Teoria da visão computacional
 - 6.1.3. Modelos de processamento de imagens
- 6.2. Camadas convolucionais
 - 6.2.1. Reutilização de pesos na convolução
 - 6.2.2. Convolução 2D
 - 6.2.3. Funções de ativação
- 6.3. Camadas de agrupamento e implementação de camadas de agrupamento
 - 6.3.1. Pooling e Striding
 - 6.3.2. Flattening
 - 6.3.3. Tipos de Pooling
- 6.4. Arquitetura CNN
 - 6.4.1. Arquitetura VGG
 - 6.4.2. Arquitetura AlexNet
 - 6.4.3. Arquitetura ResNet
- 6.5. Implementação de uma CNN ResNet -34 utilizando Keras
 - 6.5.1. Inicialização de pesos
 - 6.5.2. Definição da camada de entrada
 - 6.5.3. Definição da saída
- 6.6. Utilização de modelos pré-treinados do Keras
 - 6.6.1. Características dos modelos pré-treinados
 - 6.6.2. Usos dos modelos pré-treinados
 - 6.6.3. Vantagens dos modelos pré-treinados

- 6.7. Modelos pré-treinados para a aprendizagem por transferência
 - 6.7.1. A Aprendizagem por transferência
 - 6.7.2. Processo de aprendizagem por transferência
 - 6.7.3. Vantagens do aprendizagem por transferência
- 6.8. Classificação e Localização em Deep Computer Vision
 - 6.8.1. Classificação de imagens
 - 6.8.2. Localização de objetos em imagens
 - 6.8.3. Detecção de objetos
- 6.9. Deteção e seguimento de objetos
 - 6.9.1. Métodos de deteção de objetos
 - 6.9.2. Algoritmos de seguimento de objetos
 - 6.9.3. Técnicas de seguimento e localização
- 6.10. Segmentação semântica
 - 6.10.1. Aprendizagem profunda para a segmentação semântica
 - 6.10.2. Deteção de bordas
 - 6.10.3. Métodos de segmentação baseado sem regras
- 7.4. RNN pré-treinadas
 - 7.4.1. Redes pré-treinadas
 - 7.4.2. Transferência de aprendizado
 - 7.4.3. Ajuste fino
- 7.5. Previsão de uma série temporal
 - 7.5.1. Modelos estatísticos para previsões
 - 7.5.2. Modelos de séries temporais
 - 7.5.3. Modelos baseados em redes neuronais
- 7.6. Interpretação dos resultados da análise de séries temporais
 - 7.6.1. Análises de componentes principais
 - 7.6.2. Análise de clusters
 - 7.6.3. Análise de correlações
- 7.7. Gerenciamento de sequências longas
 - 7.7.1. Long Short-Term Memory (LSTM)
 - 7.7.2. Gated Recurrent Units (GRU)
 - 7.7.3. Convolucionais 1D
- 7.8. Aprendizado de sequência parcial
 - 7.8.1. Métodos de aprendizado profundo
 - 7.8.2. Modelos generativos
 - 7.8.3. Aprendizado por reforço
- 7.9. Aplicação Prática de RNN e CNN
 - 7.9.1. Processamento de linguagem natural
 - 7.9.2. Reconhecimento de padrões
 - 7.9.3. Visão computacional
- 7.10. Diferenças nos resultados clássicos
 - 7.10.1. Métodos clássicos vs RNN
 - 7.10.2. Métodos clássicos vs CNN
 - 7.10.3. Diferença no tempo de treinamento

Módulo 7. Sequências de Processamento utilizando RNN (Redes Neuronais Recorrentes) e CNN (Redes Neuronais Convolucionais)

- 7.1. Neurônios e camadas recorrentes
 - 7.1.1. Tipos de neurônios recorrentes
 - 7.1.2. Arquitetura de uma camada recorrente
 - 7.1.3. Aplicações das camadas recorrentes
- 7.2. Treinamento de Redes Neuronais Recorrentes (RNN)
 - 7.2.1. Backpropagation através do tempo (BPTT)
 - 7.2.2. Gradiente descendente estocástico
 - 7.2.3. Regularização no treinamento de RNN
- 7.3. Avaliação de modelos RNN
 - 7.3.1. Métricas de avaliação
 - 7.3.2. Validação cruzada
 - 7.3.3. Ajuste de hiperparâmetros
- 7.4. RNN pré-treinadas
 - 7.4.1. Redes pré-treinadas
 - 7.4.2. Transferência de aprendizado
 - 7.4.3. Ajuste fino
- 7.5. Previsão de uma série temporal
 - 7.5.1. Modelos estatísticos para previsões
 - 7.5.2. Modelos de séries temporais
 - 7.5.3. Modelos baseados em redes neuronais
- 7.6. Interpretação dos resultados da análise de séries temporais
 - 7.6.1. Análises de componentes principais
 - 7.6.2. Análise de clusters
 - 7.6.3. Análise de correlações
- 7.7. Gerenciamento de sequências longas
 - 7.7.1. Long Short-Term Memory (LSTM)
 - 7.7.2. Gated Recurrent Units (GRU)
 - 7.7.3. Convolucionais 1D
- 7.8. Aprendizado de sequência parcial
 - 7.8.1. Métodos de aprendizado profundo
 - 7.8.2. Modelos generativos
 - 7.8.3. Aprendizado por reforço
- 7.9. Aplicação Prática de RNN e CNN
 - 7.9.1. Processamento de linguagem natural
 - 7.9.2. Reconhecimento de padrões
 - 7.9.3. Visão computacional
- 7.10. Diferenças nos resultados clássicos
 - 7.10.1. Métodos clássicos vs RNN
 - 7.10.2. Métodos clássicos vs CNN
 - 7.10.3. Diferença no tempo de treinamento

Módulo 8. Processamento de linguagem natural (PLN) com Redes Neurais Recorrentes (RNN) e Atenção

- 8.1. Geração de texto utilizando RNN
 - 8.1.1. Treino de uma RNN para geração de texto
 - 8.1.2. Geração de linguagem natural com RNN
 - 8.1.3. Aplicações de geração de texto com RNN
- 8.2. Criação de conjuntos de dados de treino
 - 8.2.1. Preparação dos dados para o treino de uma RNN
 - 8.2.2. Armazenamento do conjunto de dados de treino
 - 8.2.3. Limpeza e transformação dos dados
- 8.3. Análise de Sentimento
 - 8.3.1. Classificação da opiniões com RNN
 - 8.3.2. Detecção de temas nos comentários
 - 8.3.3. Análise de sentimento com algoritmos de aprendizagem profunda
- 8.4. Rede codificadora-descodificadora para a tradução automática neural
 - 8.4.1. Treino de uma RNN para a tradução automática
 - 8.4.2. Utilização de uma rede encoder-decoder para a tradução automática
 - 8.4.3. Melhoria da precisão da tradução automática com RNNs
- 8.5. Mecanismos de atenção
 - 8.5.1. Implementação de mecanismos de atenção em RNN
 - 8.5.2. Utilização de mecanismos de atenção para melhorar a precisão dos modelos
 - 8.5.3. Vantagens dos mecanismos de atenção nas redes neurais
- 8.6. Modelos *Transformers*
 - 8.6.1. Uso de modelos *Transformers* no processamento de linguagem natural
 - 8.6.2. Aplicação de modelos *Transformers* na visão
 - 8.6.3. Vantagens dos modelos *Transformers*
- 8.7. *Transformers* para a visão
 - 8.7.1. Utilização de modelos *Transformers* para a visão
 - 8.7.2. Pré-processamento de dados de imagem
 - 8.7.3. Treino de um modelo *Transformer* para a visão
- 8.8. Biblioteca de *Transformers* de Hugging Face
 - 8.8.1. Utilização da biblioteca *Transformers* de Hugging Face
 - 8.8.2. Aplicação da biblioteca de *Transformers* de Hugging Face
 - 8.8.3. Vantagens da biblioteca *Transformers* de Hugging Face
- 8.9. Outras Bibliotecas de *Transformers*. Comparação
 - 8.9.1. Comparação entre as diferentes bibliotecas de *Transformers*
 - 8.9.2. Uso das outras bibliotecas de *Transformers*
 - 8.9.3. Vantagens das outras bibliotecas de *Transformers*
- 8.10. Desenvolvimento de uma aplicação de PLN com RNN e Atenção. Aplicação Prática
 - 8.10.1. Desenvolvimento de uma aplicação de processamento de linguagem natural com RNN e atenção
 - 8.10.2. Utilização de RNN, mecanismos de atenção e modelos *Transformers* na aplicação
 - 8.10.3. Avaliação da aplicação prática

Módulo 9. Autoencoders, GANs, e Modelos de Divulgação

- 9.1. Representação de dados eficientes
 - 9.1.1. Redução da dimensionalidade
 - 9.1.2. Aprendizagem profunda
 - 9.1.3. Representações compactas
- 9.2. Realização da PCA com um codificador automático linear incompleto
 - 9.2.1. Processo de treino
 - 9.2.2. Implementação em Python
 - 9.2.3. Utilização de dados de teste
- 9.3. Codificadores automáticos empilhados
 - 9.3.1. Redes neurais profundas
 - 9.3.2. Construção de arquiteturas de codificação
 - 9.3.3. Utilização da regularização
- 9.4. Autoencodificadores convolucionais
 - 9.4.1. Design do modelo convolucionais
 - 9.4.2. Treino do modelo convolucionais
 - 9.4.3. Avaliação dos resultados

- 9.5. Redução do ruído dos codificadores automáticos
 - 9.5.1. Aplicação de filtros
 - 9.5.2. Design de modelos de codificação
 - 9.5.3. Utilização de técnicas de regularização
- 9.6. Codificadores automáticos dispersos
 - 9.6.1. Aumento da eficiência da codificação
 - 9.6.2. Minimizar o número de parâmetros
 - 9.6.3. Utilização de técnicas de regularização
- 9.7. Codificadores automáticos variacionais
 - 9.7.1. Utilização da otimização variacional
 - 9.7.2. Aprendizagem profunda não supervisionada
 - 9.7.3. Representações latentes profundas
- 9.8. Geração de imagens MNIST de moda
 - 9.8.1. Reconhecimento de padrões
 - 9.8.2. Geração de imagens
 - 9.8.3. Treino de redes neurais profundas
- 9.9. Redes geradoras antagónicas e modelos de difusão
 - 9.9.1. Geração de conteúdos a partir de imagens
 - 9.9.2. Modelação de distribuições de dados
 - 9.9.3. Utilização de redes contraditórias
- 9.10. Implementação dos Modelos. Aplicação Prática
 - 9.10.1. Implementação dos modelos
 - 9.10.2. Utilização de dados reais
 - 9.10.3. Avaliação dos resultados

Módulo 10. Reinforcement Learning

- 10.1. Otimização das recompensas e a busca de políticas
 - 10.1.1. Algoritmos de otimização de recompensas
 - 10.1.2. Processos de busca de políticas
 - 10.1.3. Aprendizado por reforço para otimizar as recompensas
- 10.2. OpenAI
 - 10.2.1. Ambiente OpenAI Gym
 - 10.2.2. Criação de ambientes OpenAI
 - 10.2.3. Algoritmos de aprendizado por reforço no OpenAI



- 10.3. Políticas de redes neurais
 - 10.3.1. Redes neurais convolucionais para a busca de políticas
 - 10.3.2. Políticas de aprendizado profundo
 - 10.3.3. Ampliação de políticas de redes neurais
- 10.4. Avaliação de ações: o problema da atribuição de créditos
 - 10.4.1. Análise de risco para a atribuição de créditos
 - 10.4.2. Estimativa de rentabilidade de empréstimos
 - 10.4.3. Modelos de avaliação de créditos baseados em redes neurais
- 10.5. Gradientes de Política
 - 10.5.1. Aprendizado por reforço com gradientes de política
 - 10.5.2. Otimização de gradientes de política
 - 10.5.3. Algoritmos de gradientes de política
- 10.6. Processos de decisão de Markov
 - 10.6.1. Otimização de processos de decisão de Markov
 - 10.6.2. Aprendizado por reforço para processos de decisão de Markov
 - 10.6.3. Modelos de processos de decisão de Markov
- 10.7. Aprendizado de diferenças temporais e *Q-Learning*
 - 10.7.1. Aplicação de diferenças temporais no aprendizado
 - 10.7.2. Aplicação de *Q-Learning* no aprendizado
 - 10.7.3. Otimização de parâmetros de *Q-Learning*
- 10.8. Implementação de *Deep Q-Learning* e variantes de *Deep Q-Learning*
 - 10.8.1. Construção de redes neurais profundas para *Deep Q-Learning*
 - 10.8.2. Implementação de *Deep Q-Learning*
 - 10.8.3. Variações de *Deep Q-Learning*
- 10.9. Algoritmos de *Reinforcement Learning*
 - 10.9.1. Algoritmos de aprendizado por reforço
 - 10.9.2. Algoritmos de aprendizado por recompensa
 - 10.9.3. Algoritmos de aprendizado por castigo
- 10.10. Desenho de um ambiente de aprendizado por Reforço. Aplicação Prática
 - 10.10.1. Desenho de um ambiente de aprendizado por reforço
 - 10.10.2. Implementação de um algoritmo de aprendizado por reforço
 - 10.10.3. Avaliação de um algoritmo de aprendizado por reforço

06

Metodologia de estudo

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

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



“

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

O aluno: a prioridade de todos os programas da TECH

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

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

“

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



Os programas de ensino mais abrangentes do mundo

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

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

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

“

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

Case studies ou Método de caso

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

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

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




Método Relearning

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

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

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

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



Um Campus Virtual 100% online com os melhores recursos didáticos

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

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

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

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



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

A eficácia do método é justificada por quatro conquistas fundamentais:

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



A metodologia universitária mais bem avaliada por seus alunos

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

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

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

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

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



Material de estudo

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

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



Práticas de aptidões e competências

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



Resumos interativos


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


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



Leituras complementares

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





Case Studies

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



Testing & Retesting

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



Masterclasses

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

O *Learning from an expert* fortalece o conhecimento e a memória, e aumenta nossa confiança para tomar decisões difíceis no futuro.



Guias rápidos de ação

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



07

Certificação

O Mestrado em Deep Learning garante, além da formação mais rigorosa e atualizada, o acesso a um certificado de Mestrado emitido pela TECH Global University.



“

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

Este programa permitirá a obtenção do certificado próprio de **Mestrado em Deep Learning** reconhecido pela TECH Global University, a maior universidade digital do mundo.

A **TECH Global University**, é uma Universidade Europeia Oficial reconhecida publicamente pelo Governo de Andorra (*bollettino ufficiale*). 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 dos seus mecanismos de garantia de qualidade para fomentar a colaboração e a mobilidade entre alunos, investigadores 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.

Título: **Mestrado em Deep Learning**

Modalidade: **online**

Duração: **12 meses**

Acreditação: **60 ECTS**

The curriculum vitae template has a decorative border. It starts with the title 'Mestrado em Deep Learning'. Below it are two tables: 'Distribuição Geral do Plano de Estudos' and 'Distribuição Geral do Plano de Estudos'. The first table shows the distribution of credits by type: Obligatoria (OB) 60, Opção (OP) 0, Estágio (PR) 0, Tese de Mestrado 0, with a total of 60. The second table lists the courses and their details:

Curso	Disciplina	ECTS	Carácter
1º	Fundamentos Matemáticos de Deep Learning	6	OB
1º	Princípios de Deep Learning	6	OB
1º	As redes neurais, a base da Deep Learning	6	OB
1º	Treino de redes neurais profundas	6	OB
1º	Personalização de modelos e treino com TensorFlow	6	OB
1º	Deep Computer Visión com Redes Neuronais Convolucionais	6	OB
1º	Sequências de Processamento utilizando RNN (Redes Neuronais Recorrentes) e CNN (Redes Neuronais Convolucionais)	6	OB
1º	Processamento de Imagem natural (PLN) com Redes Neurais Recorrentes (RNN) e Atenção	6	OB
1º	Autoencoders, GANs, e Modelos de Divulgação	6	OB
1º	Reinforcement Learning	6	OB

At the bottom right is the 'tech global university' logo.

*Apostila de Haia: Caso o aluno solicite que o seu certificado seja apostilado, a TECH Global University 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 situações



Mestrado
Deep Learning

- » Modalidade: online
- » Duração: 12 meses
- » Certificação: TECH Global University
- » Acreditação: 60 ECTS
- » Horário: ao seu próprio ritmo
- » Exames: online

Mestrado

Deep Learning

