

Mestrado Próprio

Deep Learning



Mestrado Próprio 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.techtute.com/pt/inteligencia-artificial/mestrado-proprio/mestrado-proprio-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 estudo

pág. 32

07

Certificação

pág. 42

01

Apresentação

O *Deep Learning* tem sido uma revolução tecnológica nos últimos anos. Esta vertente da Inteligência Artificial foca no treinamento de Redes Neurais Profundas para aprender representações hierárquicas de dados. Além disso, possui um amplo leque de aplicações, sendo um exemplo o mundo das finanças. Dessa forma, os especialistas conseguem detetar fraudes, analisar riscos e até mesmo prever preços de ações. Não é surpreendente, portanto, que cada vez mais pessoas decidam se especializar nesta área. Para atender a essa demanda, a TECH desenvolve uma qualificação que abordará em detalhes as particularidades do Aprendizado Profundo. Tudo em formato 100% online, para oferecer mais comodidade aos estudantes.





“

Aplicará em seus projetos as técnicas mais inovadoras do Aprendizado Profundo graças a este Mestrado Próprio 100% online”

O TensorFlow se tornou a ferramenta mais importante para implementar e treinar modelos de Aprendizado Profundo. Os desenvolvedores utilizam tanto sua variedade de ferramentas quanto bibliotecas para treinar modelos que realizam tarefas automáticas de detecção de objetos, classificação e processamento de linguagem natural. Neste mesmo sentido, essa plataforma é útil para detetar anomalias nos dados, o que é essencial em áreas como segurança cibernética, manutenção preditiva e controle de qualidade. No entanto, seu uso pode envolver uma série de desafios para os profissionais, entre eles a seleção da arquitetura de rede neural adequada.

Diante dessa situação, a TECH implementa um Mestrado Próprio que fornecerá aos especialistas uma visão integral sobre o *Deep Learning*. Elaborado por especialistas na área, o plano de estudos abordará os fundamentos matemáticos e princípios do Aprendizado Profundo. Isso permitirá que os alunos construam Redes Neurais voltadas para o processamento de informações, que envolvem reconhecimento de padrões, tomada de decisões e aprendizado a partir de dados. Além disso, o conteúdo do curso abordará o *Reinforcement Learning* considerando fatores como a otimização de recompensas e a busca por políticas. Por outro lado, os materiais didáticos oferecerão técnicas avançadas de otimização e visualização de resultados.

Quanto ao formato da certificação, ela é oferecida por meio de uma metodologia 100% online, permitindo que os estudantes completem o programa com conforto. Para acessar o conteúdo acadêmico, basta ter um dispositivo eletrônico com acesso à Internet, pois os horários e cronogramas de avaliações são planejados individualmente. Além disso, o conteúdo se apoiará no inovador sistema de ensino *Relearning*, no qual a TECH é pioneira. Esse sistema de aprendizagem consiste na repetição dos aspetos-chave para garantir o domínio completo dos diferentes tópicos.

Este **Mestrado Próprio 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



Estude através de inovadores formatos de aprendizagem multimédia que otimizarão o seu processo de atualização em Deep Learning”

“

Pretende enriquecer a sua prática com técnicas de otimização de gradientes mais avançadas? Consiga-o com este curso em somente 12 meses”

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.

Aprofundará os Backward Pass para calcular os gradientes da função de perda em relação aos parâmetros da rede.

Graças à metodologia de Relearning, terá liberdade para planejar tanto seus horários de estudo quanto os cronogramas educacionais.



02

Objetivos

Com este Mestrado Próprio, os alunos desenvolverão suas habilidades e conhecimentos no campo do Aprendizado Profundo e Inteligência Artificial. Dessa forma, implementarão as técnicas mais avançadas de *Deep Learning* em seus projetos para melhorar o desempenho dos modelos em tarefas específicas. Além disso, os especialistas serão capazes de desenvolver sistemas inteligentes que realizem automaticamente tarefas como o reconhecimento de padrões em imagens, análise de sentimentos em textos ou detecção de anomalias nos dados.



“

Um curso projetado com base nas últimas tendências em Deep Learning, garantindo um aprendizado bem-sucedido”



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 neuronais
- Analisar o treino, a avaliação e a análise dos modelos de redes neuronais
- Fundamentar os conceitos chave e as principais aplicações da aprendizagem profunda
- Implementar e otimizar redes neuronais com o Keras
- Desenvolver conhecimento especializado sobre o treino de redes neuronais 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 neurais, a base do *Deep Learning*

- Analisar a arquitetura das redes neurais e os seus princípios de funcionamento
- Determinar como podem ser aplicadas as redes neurais 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 Neurais profundas

- Analisar os problemas de gradiente e como se podem evitar
- Determinar como reutilizar camadas pré-treinadas para treinar redes neurais 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 Neurais 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 neurais 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 neurais para melhorar a precisão de um agente ao tomar decisões
- ♦ Implementar diferentes algoritmos de reforço para melhorar o desempenho de um agente



“

*Uma experiência de formação chave,
única e decisiva que irá impulsionar o
seu desenvolvimento profissional”*

03

Competências

Por meio do Mestrado Próprio, os alunos adquirirão novas habilidades para enfrentar com sucesso os desafios apresentados pela Inteligência Artificial. Após a conclusão do curso, os profissionais dominarão o uso das ferramentas TensorFlow para manipulação de dados. Além disso, os especialistas aproveitarão ao máximo o treinamento de Redes Neurais Profundas para resolver problemas complexos e criar modelos precisos. Dessa forma, implementarão propostas inovadoras para se destacar em um setor tecnológico em constante crescimento.





“

*Adquirirá habilidades avançadas
para aplicar em seus projetos a
arquitetura Visual Cortex”*



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

“

Utilizará a ferramenta TensorFlow para manipular dados e criar modelos de aprendizagem automática de alto nível”





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 detecção 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

Para oferecer a máxima qualidade educacional, a TECH realizou um processo rigoroso de seleção de cada um dos docentes que integram suas qualificações universitárias. Por isso, os alunos que ingressarem neste Mestrado Próprio terão acesso a um plano de estudos desenvolvido pelos melhores especialistas na área de *Deep Learning*. Além disso, esses profissionais não se destacam apenas por possuírem uma sólida compreensão da matéria, mas também por acumular uma vasta trajetória profissional em instituições renomadas. Tudo isso proporcionará aos estudantes uma experiência imersiva que os permitirá dar um grande salto em suas carreiras profissionais.



“

A diversidade de talentos do corpo docente permitirá que desfrute de um ambiente de ensino totalmente dinâmico e enriquecedor”

Direção



Sr. Gil Contreras, Armando

- ♦ *Lead Big Data Scientist-Big Data* em Jhonson Controls
- ♦ *Data Scientist-Big Data* em Opensistemas S.A
- ♦ Auditor de Fundos em Criatividade e Tecnologia S.A. CYTSA)
- ♦ Auditor do Setor Público na PricewaterhouseCoopers Auditores
- ♦ Mestrado em *Data Science* pelo Centro Universitário de Tecnologia e Arte
- ♦ Mestrado MBA em Relações e Negócios Internacionais pelo Centro de Estudos Financeiros (CEF)
- ♦ Licenciatura em Economia pelo Instituto Tecnológico de Santo Domingo

Professores

Sra. Delgado Feliz, Benedit

- ♦ Assistente Administrativa e Operadora de Vigilância Eletrônica na Direção Nacional de Controle de Drogas(DNCD)
- ♦ Servicio ao Cliente em Cáceres e Equipos
- ♦ Reclamações e Serviço ao Cliente na Express Parcel Services (EPS)
- ♦ Especialista em Microsoft Office pela Escola Nacional de Informática
- ♦ Comunicadora Social pela Universidade Católica Santo Domingo

Sr. Villar Valor, Javier

- ♦ Diretor e Sócio Fundador da Impulsa2
- ♦ *Chief Operations Officer* (COO) na Summa Insurance Brokers
- ♦ Diretor de Transformação e Excelência Operacional na Johnson Controls
- ♦ Mestrado em *Coaching* Profissional
- ♦ Executive MBA pela Emlyon Business School, França
- ♦ Mestrado em Gestão da Qualidade pela EOI
- ♦ Engenharia Informática pela Universidade Ação Pro-Educação e Cultura (UNAPEC)



Sr. Matos Rodríguez, Dionis

- ♦ *Data Engineer* em Wide Agency Sadexo
- ♦ *Data Consultant* em Tokiota
- ♦ *Data Engineer* em Devoteam
- ♦ *BI Developer* em Ibermática
- ♦ *Applications Engineer* em Johnson Controls
- ♦ *Database Developer* em Suncapital España
- ♦ *Senior Web Developer* em Deadlock Solutions
- ♦ *QA Analyst* em Metaconcept
- ♦ Mestrado em Big Data& Analytics pela EAE Business School
- ♦ Mestrado em Análise e Design de Sistemas
- ♦ Licenciatura em Engenharia Informática pela Universidades APEC

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

Este Mestrado Próprio oferecerá aos alunos uma ampla gama de técnicas de *Deep Learning*, que elevarão seus horizontes profissionais a um nível superior. Para alcançar esse objetivo, o itinerário acadêmico se aprofundará na codificação de modelos de aprendizado profundo. Dessa forma, os alunos traduzirão com eficácia os algoritmos e as arquiteturas de redes neurais profundas. Além disso, o conteúdo abordará em detalhes o treinamento de redes neurais profundas, assim como a visualização de resultados e a avaliação de modelos de aprendizado. Os estudantes também analisarão os principais Modelos *Transformers*, com o objetivo de manipulá-los para gerar traduções automáticas.



“

Aplicará em seus projetos os princípios do Deep Learning para resolver uma variedade de problemas complexos, em campos como o reconhecimento de imagens”

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 supervisionado
 - 2.1.2. Usos do aprendizado supervisionado
 - 2.1.3. Diferenças entre aprendizado supervisionado e não supervisionado
- 2.2. Modelos de aprendizado supervisionado
 - 2.2.1. Modelos lineares
 - 2.2.2. Modelos de árvores de decisão
 - 2.2.3. Modelos de redes neurais
- 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 neurais
 - 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 neurais, 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 Neurais
 - 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 Neurais
 - 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 neurais 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 características
 - 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 características
 - 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 préprocessamento 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 pipeline 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 Neurais 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. Detecção e seguimento de objetos
 - 6.9.1. Métodos de detecção 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. Detecção de bordas
 - 6.10.3. Métodos de segmentação baseado sem regras

Módulo 7. Sequências de Processamento utilizando RNN (Redes Neurais Recorrentes) e CNN (Redes Neurais 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 Neurais 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 neurais
- 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 Difusão

- 9.1. Representação de dados eficientes
 - 9.1.1. Redução da dimensionalidade
 - 9.1.2. Aprendizagem profunda
 - 9.1.3. Representações compatas
- 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 generativas antagônicas 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



Estude no conforto da sua casa e atualize os seus conhecimentos online com a TECH, a maior Universidade Digital do mundo”

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



Testing & Retesting



Masterclasses



Guias rápidos de ação



07

Certificação

O Mestrado Próprio em Deep Learning garante, além da formação mais rigorosa e atualizada, o acesso a um certificado de Mestrado Próprio 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 Próprio 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 Próprio em Deep Learning**

Modalidade: **online**

Duração: **12 meses**

Acreditação: **60 ECTS**





Mestrado Próprio Deep Learning

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

Mestrado Próprio

Deep Learning