

Mestrado Próprio

Deep Learning





Mestrado Próprio Deep Learning

- » Modalidade: online
- » Duração: 12 meses
- » Certificado: TECH Universidade Tecnológica
- » Horário: no seu próprio ritmo
- » Provas: online

Acesso ao site: www.techtute.com/br/engenharia/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

Metodologia

pág. 32

07

Certificado

pág. 40

01

Apresentação

Desde o reconhecimento de voz e a tradução automática de vídeos do YouTube, passando pela interpretação de objetos e formas no Google Photos, até o método antifraude usado por bancos privados, todos eles são baseados em *Deep Learning*. O progresso na automação, na análise e detecção de imagens e na previsão para a tomada rápida de decisões tornou o perfil do engenheiro profissional mais relevante. Esse trabalho contribui para o crescimento de outros setores, e é por isso que há necessidade de verdadeiros especialistas nesse campo. Por esse motivo, esse curso 100% online foi criado para fornecer aos alunos conhecimentos avançados para desenvolver projetos de Inteligência Artificial e Deep Learning. Além disso, tudo com material didático inovador e atualizado, preparado por verdadeiros especialistas com experiência acumulada no setor.



“

Amplie seu nível de conhecimento em Deep Learning com este Mestrado Próprio composto por 1.500 horas de aprendizagem. Faça sua matrícula já”

Sem dúvida, um dos setores que mais cresceram nos últimos anos foi o setor de tecnologia, impulsionado pelos avanços de engenharia trazidos pelo desenvolvimento do Deep Learning. Assim, estão proliferando os chatbots, os aplicativos de reconhecimento facial e a detecção precoce de doenças, como o câncer, por meio da identificação de imagens médicas de maior qualidade.

Uma infinidade de possibilidades que exigem um domínio completo do *Deep Learning* por parte dos profissionais de engenharia. Nesse sentido, a TECH promoveu o desenvolvimento desse mestrado de 12 meses, que oferece aos alunos o conhecimento mais avançado e atual nesse campo.

Este é um programa que levará o aluno a se aprofundar nos fundamentos matemáticos, na construção de redes neurais, na personalização de modelos e no treinamento com o TensorFlow ou a se aprofundar em *Deep Computer Vision* com Redes Neurais Convolucionais. Além disso, tudo com material didático baseado em resumos em vídeo de cada tópico, vídeos detalhados, leituras especializadas e estudos de caso que o aluno pode acessar, confortavelmente, 24 horas por dia, de qualquer dispositivo eletrônico com conexão à Internet.

Um programa de estudos que lhe permitirá aprimorar suas habilidades para criar projetos com foco em análise de dados, processamento de linguagem natural ou que tenham aplicação direta em áreas como robótica, finanças, jogos ou carros autônomos, entre outras.

Dessa forma, a TECH abre um mundo de possibilidades graças a uma capacitação de qualidade, desenvolvida por verdadeiros especialistas e que oferece maior liberdade de autogerenciamento dos estudos. E o fato é que, sem a necessidade de aulas presenciais ou horários restritos, os alunos podem acessar o programa de estudos a qualquer momento e conciliar suas atividades diárias com uma capacitação que está na vanguarda da educação acadêmica.

Este **Mestrado Próprio em Deep Learning** conta com o conteúdo científico mais completo e atualizado do mercado. Suas principais características são:

- ♦ O desenvolvimento de casos práticos apresentados por especialistas em Data Engineer e Data Scientist
- ♦ O conteúdo gráfico, esquemático e eminentemente prático oferece informações técnicas e práticas sobre aquelas disciplinas que são essenciais para a prática profissional
- ♦ Exercícios práticos em que o processo de autoavaliação é realizado para melhorar a aprendizagem
- ♦ Destaque especial para as metodologias inovadoras
- ♦ Lições teóricas, perguntas a especialistas, fóruns de discussão sobre temas controversos e trabalhos de reflexão individual
- ♦ Disponibilidade de acesso a todo o conteúdo a partir de qualquer dispositivo, fixo ou portátil, com conexão à Internet



Este é um curso que lhe dará o impulso necessário para fazer parte das grandes empresas de tecnologia do momento. Matricule-se já"

“

Com este programa, você não precisa se preocupar em assistir às aulas, não precisa estar presente nas aulas e não tem um horário fixo. Acesse o conteúdo, quando e onde quiser”

O corpo docente do curso conta com profissionais do setor, que transferem toda a experiência adquirida ao longo de suas carreiras para esta capacitação, além de especialistas reconhecidos de sociedades de referência e universidades de prestígio.

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

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

Domine os modelos GANS e Diffusion e aprimore seus projetos para gerar imagens novas, realistas e de alta qualidade.

Um programa que permitirá a você se aprofundar no Backward Pass e em como as derivadas de funções vetoriais são aplicadas para aprender automaticamente.



02

Objetivos

A TECH oferece a todos os seus alunos inúmeros materiais didáticos inovadores para que, em apenas 12 meses, eles possam obter o conhecimento necessário em Deep Learning que lhes permitirá crescer em um dos setores mais avançados da atualidade. Assim, ao final do curso, o aluno terá desenvolvido as competências e habilidades necessárias para se envolver em projetos de Inteligência Artificial e Deep Learning destinados a melhorar diferentes setores socioeconômicos.






“

*Obtenha o conhecimento necessário
para criar ambientes OpenAI e avançar
em sua carreira”*



Objetivos gerais

- ♦ Fundamentar os conceitos-chave das funções matemáticas e suas derivadas
- ♦ Aplicar esses princípios aos algoritmos de aprendizado profundo para aprender automaticamente
- ♦ Examinar os conceitos-chave de Aprendizado Supervisionado e como eles se aplicam aos modelos de redes neurais
- ♦ Analisar o treinamento, a avaliação e a análise de modelos de redes neurais
- ♦ Fundamentar os conceitos-chave e as principais aplicações do aprendizado profundo
- ♦ Implementar e otimizar redes neurais com o Keras
- ♦ Desenvolver conhecimento especializado sobre o treinamento de redes neurais profundas
- ♦ Analisar os mecanismos de otimização e regularização necessários para o treinamento de redes profundas





Objetivos específicos

Módulo 1. Fundamentos Matemáticos do Deep Learning

- ◆ Desenvolver a regra da cadeia para calcular derivadas de funções aninhadas
- ◆ Analisar como novas funções são criadas a partir de funções existentes e como calcular suas derivadas
- ◆ Examinar o conceito de Backward Pass e como aplicar derivadas de funções vetoriais para aprendizado automático
- ◆ Aprender como usar o TensorFlow para construir modelos personalizados
- ◆ Compreender como carregar e processar dados usando ferramentas do TensorFlow
- ◆ Fundamentar os conceitos-chave de Processamento de Linguagem Natural (PLN) com RNNs e mecanismos de atenção
- ◆ Explorar a funcionalidade das bibliotecas 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 usados para codificar dados de forma eficiente

Módulo 2. Princípios do Deep Learning

- ◆ Analisar o funcionamento da regressão linear e como ela pode ser aplicada a modelos de redes neurais
- ◆ Fundamentar a otimização dos hiperparâmetros para melhorar o desempenho dos modelos de redes neurais
- ◆ Determinar como avaliar o desempenho dos modelos de redes neurais usando conjuntos de treinamento e teste



Módulo 3. Redes Neurais como Base do Deep Learning

- ♦ Analisar a arquitetura das redes neurais e seus princípios de funcionamento
- ♦ Determinar como aplicar redes neurais a uma variedade de problemas
- ♦ Estabelecer como otimizar o desempenho de modelos de aprendizado profundo ajustando os hiperparâmetros

Módulo 4. Treinamento de Redes Neurais Profundas

- ♦ Analisar problemas de gradiente e como evitá-los
- ♦ Determinar como reutilizar camadas pré-treinadas para treinar redes neurais profundas
- ♦ Estabelecer como ajustar a taxa de aprendizado para obter os melhores resultados

Módulo 5. Personalização de Modelos e Treinamento 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 dados de maneira eficiente
- ♦ Discutir o projeto TensorFlow Datasets e como ele pode ser usado para facilitar o acesso a conjuntos de dados pré-processados

Módulo 6. Deep Computer Vision com Redes Neurais Convolucionais

- ♦ Explorar e entender como as camadas convolucionais e de pooling funcionam para a arquitetura do Córtex Visual
- ♦ Desenvolver arquiteturas de CNN com o Keras
- ♦ Usar modelos pré-treinados do Keras para classificação, localização, detecção e rastreamento de objetos, bem como segmentação semântica





Módulo 7. Processamento de sequências usando RNN e CNN

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

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

- ♦ Gerar texto usando redes neurais recorrentes
- ♦ Treinar uma rede codificador-decodificador para 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 GANs e 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 aprendizado por reforço para melhorar o desempenho de um agente

03

Competências

Essa capacitação permite que os alunos pesquisem, desenvolvam e projetem sistemas de Inteligência Artificial que automatizam modelos preditivos. Essas são competências e habilidades técnicas que o estudante poderá aprimorar ao longo deste curso acadêmico, graças não apenas ao foco teórico deste curso, mas também à perspectiva prática que o aluno obterá por meio dos cenários de simulação. Uma oportunidade única de progressão que somente a TECH, a maior universidade digital do mundo, pode oferecer.





“

Aprimore suas habilidades para gerar chatbots que entendam melhor e respondam às perguntas dos usuários”



Competências gerais

- Implementar a arquitetura do Visual Cortex
- Utilizar modelos pré-treinados do Keras para aprendizado por transferência e outras tarefas de visão computacional
- Dominar a Rede Neural Recorrente (RNN)
- Treinar e avaliar um modelo RNN para previsão de séries de tempo
- Melhorar a capacidade de um agente em 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 de linguagem natural com RNN e atenção graças a este curso”





Competências específicas

- ♦ Resolver problemas com dados, o que implica melhorar processos existentes e desenvolver novos processos por meio do uso de ferramentas tecnológicas adequadas
- ♦ Implementar projetos e tarefas baseados em dados
- ♦ Utilizar métricas como precisão, exatidão e erro de classificação
- ♦ Otimizar os parâmetros de uma rede neural
- ♦ Construir modelos personalizados usando a API do TensorFlow
- ♦ Implementar com Keras tarefas como classificação, localização, detecção e rastreamento de objetos, bem como segmentação semântica
- ♦ Gerar imagens novas e realistas
- ♦ Implementar Deep Q-Learning e variantes de Deep Q-Learning
- ♦ Utilizar técnicas de otimização para treinamento
- ♦ Treinar com sucesso redes neurais profundas

04

Direção do curso

Essa instituição acadêmica se esforçou ao máximo para reunir uma excelente equipe de especialistas em Deep Learning e sua aplicação em vários setores. Dessa forma, o profissional de engenharia terá a garantia de acesso a um programa de qualidade de grande valor para sua progressão em um setor em ascensão. Além disso, graças à grande proximidade com o corpo docente, os alunos poderão resolver quaisquer dúvidas que possam ter sobre o conteúdo dessa especialização ao longo de sua carreira acadêmica.



“

Especialistas com amplo conhecimento em Tensorflow, arquitetura de streaming, aprendizado de máquina ou Big Data fazem parte dessa excelente capacitação”

Direção



Sr. Armando Gil Contreras

- ♦ *Lead Big Data Scientist-Big Data* na Jhonson Controls
- ♦ *Data Scientist-Big Data* na Opensistemas
- ♦ *Auditor de Fundos em Criatividade e Tecnologia* e PricewaterhouseCoopers
- ♦ *Professor* da EAE Business School
- ♦ *Formado em Economia* pelo Instituto Tecnológico de Santo Domingo (INTEC)
- ♦ *Mestrado em Data Science* no Centro Universitário de Tecnologia e Artes
- ♦ *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. Ángel Delgado Panadero

- ♦ *ML Engenieer* na Paradigma Digital
- ♦ *Computer Vision Engineer* na NTT Disruption
- ♦ *Data Scientist* na Singular People
- ♦ *Data Analys* na Parclick
- ♦ *Orientador* no Mestrado em Big Data e Análise na EAE Business School
- ♦ *Formado em Física* pela Universidade de Salamanca

Sr. Dionis Matos

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



Sr. Javier Villar Valor

- ◆ Diretor e Sócio fundador Impulsa2
- ◆ Chefe de Operações, Summa Insurance Brokers
- ◆ Responsável pela identificação de oportunidades de melhoria na Liberty Seguros
- ◆ Diretor de Transformação e Excelência Profissional da Johnson Controls Iberia
- ◆ Responsável pela organização da Groupama Seguros
- ◆ Responsável pela Metodologia Lean Six Sigma na Honeywell
- ◆ Gestor de Qualidade e Compras na SP & PO
- ◆ Professor da Escola Europeia de Negócios

05

Estrutura e conteúdo

Graças ao método *Relearning*, baseado na repetição contínua de conceitos-chave ao longo desse itinerário acadêmico, o engenheiro obterá um aprendizado avançado e eficaz, sem a necessidade de investir grandes quantidades de horas de estudo. Dessa forma, o aluno poderá se aprofundar em um programa completo sobre a codificação de modelos de aprendizagem profunda, técnicas avançadas de otimização, treinamento de redes neurais profundas, visualização de resultados e avaliação de modelos de Deep Learning.





“

Acesse, a partir de seu dispositivo digital com conexão à Internet, o conteúdo de Deep Learning mais avançado e atualizado do panorama acadêmico”

Módulo 1. Fundamentos Matemáticos do 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. 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 múltiplas entradas
 - 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 do Deep Learning

- 2.1. Aprendizagem supervisionada
 - 2.1.1. Máquinas de aprendizagem supervisionada
 - 2.1.2. Usos de aprendizagem supervisionada
 - 2.1.3. Diferenças entre aprendizagem supervisionada e não supervisionada
- 2.2. Modelos de aprendizagem supervisionada
 - 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. Treinamento 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 treinamento versus conjunto de teste
 - 2.5.1. Métricas de avaliação
 - 2.5.2. Validação cruzada
 - 2.5.3. Comparação dos conjuntos de dados
- 2.6. Avaliação do modelo: O código
 - 2.6.1. Geração de predições
 - 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. Uso de gráficos
- 2.10. Hiperparâmetros
 - 2.10.1. Seleção de hiperparâmetros
 - 2.10.2. Busca de parâmetros
 - 2.10.3. Ajuste de hiperparâmetros

Módulo 3. Redes Neurais como Base do Deep Learning


- 3.1. Aprendizagem profunda
 - 3.1.1. Tipos de aprendizagem profunda
 - 3.1.2. Aplicativos de aprendizagem profunda
 - 3.1.3. Vantagens e desvantagens da aprendizagem profunda
- 3.2. Operações
 - 3.2.1. Soma
 - 3.2.2. Produtos
 - 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. União de Camadas e Operações
 - 3.4.1. Design de arquiteturas
 - 3.4.2. Conexão entre camadas
 - 3.4.3. Propagação para frente

- 3.5. Construção da primeira rede neural
 - 3.5.1. Design da rede
 - 3.5.2. Definição dos pesos
 - 3.5.3. Treinamento da rede
- 3.6. Treinador e Otimizador
 - 3.6.1. Seleção do otimizador
 - 3.6.2. Definição de uma função de perda
 - 3.6.3. Definição de uma métrica
- 3.7. Aplicação dos princípios das redes neurais
 - 3.7.1. Funções de ativação
 - 3.7.2. Retropropagação
 - 3.7.3. Ajuste dos parâmetros
- 3.8. Dos neurônios biológicos para os artificiais
 - 3.8.1. Funcionamento de um neurônio biológico
 - 3.8.2. Transferência de conhecimento para os neurônios artificiais
 - 3.8.3. Estabelecimento de relações entre ambos
- 3.9. Implementação de MLP (Perceptron multicamadas) com Keras
 - 3.9.1. Definição da estrutura da rede
 - 3.9.2. Compilação do modelo
 - 3.9.3. Treinamento 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. Treinamento 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. Treinamento de transferência de aprendizagem
 - 4.2.2. Extração de características
 - 4.2.3. Aprendizado profundo

- 4.3. Otimizadores
 - 4.3.1. Otimizadores de descida de gradiente estocástico
 - 4.3.2. Otimizadores Adam e RMSprop
 - 4.3.3. Otimizadores de momento
- 4.4. Programação da taxa de aprendizagem
 - 4.4.1. Controle de taxa de 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. Diretrizes práticas
 - 4.6.1. Design de modelos
 - 4.6.2. Seleção de métricas e parâmetros de avaliação
 - 4.6.3. Testes de hipóteses
- 4.7. *Transfer Learning*
 - 4.7.1. Treinamento de transferência de aprendizagem
 - 4.7.2. Extração de características
 - 4.7.3. Aprendizado profundo
- 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. Treinamento de transferência de aprendizagem
 - 4.9.2. Extração de características
 - 4.9.3. Aprendizado profundo
- 4.10. Regularização
 - 4.10.1. L1 E L2
 - 4.10.2. Regularização por máxima entropia
 - 4.10.3. *Dropout*



Módulo 5. Personalização de Modelos e Treinamento com TensorFlow

- 5.1. TensorFlow
 - 5.1.1. Uso da biblioteca TensorFlow
 - 5.1.2. Treinamento de modelos com TensorFlow
 - 5.1.3. Operações com gráficos no TensorFlow
- 5.2. TensorFlow e NumPy
 - 5.2.1. Ambiente computacional NumPy para TensorFlow
 - 5.2.2. Utilização de arrays NumPy com TensorFlow
 - 5.2.3. Operações NumPy para gráficos do TensorFlow
- 5.3. Personalização de modelos e algoritmos de treinamento
 - 5.3.1. Construção de modelos personalizados com TensorFlow
 - 5.3.2. Gestão de parâmetros de treinamento
 - 5.3.3. Utilização de técnicas de otimização para treinamento
- 5.4. Funções e gráficos do TensorFlow
 - 5.4.1. Funções com TensorFlow
 - 5.4.2. Utilização de gráficos para treinamento 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. Carregamento de conjuntos de dados com TensorFlow
 - 5.5.2. Pré-processamento de dados com TensorFlow
 - 5.5.3. Utilização de ferramentas do TensorFlow para manipulação de dados
- 5.6. API tf.data
 - 5.6.1. Utilização da API tf.data para processamento de dados
 - 5.6.2. Construção de fluxos de dados com tf.data
 - 5.6.3. Uso da API tf.data para treinamento de modelos
- 5.7. Formato TFRecord
 - 5.7.1. Utilização da API TFRecord para serialização de dados
 - 5.7.2. Carregamento de arquivos TFRecord com TensorFlow
 - 5.7.3. Utilização de arquivos TFRecord para treinamento 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 pipelines de pré-processamento com Keras
 - 5.8.3. Uso da API de pré-processamento do Keras para treinamento de modelos

- 5.9. Projeto TensorFlow Datasets
 - 5.9.1. Utilização do TensorFlow Datasets para carregamento de dados
 - 5.9.2. Pré-processamento de dados com o TensorFlow Datasets
 - 5.9.3. Uso do TensorFlow Datasets para treinamento de modelos
- 5.10. Construção de uma Aplicação de Deep Learning com TensorFlow. Aplicação Prática
 - 5.9.1. Construção de uma aplicação de Deep Learning com TensorFlow
 - 5.10.2. Treinamento de um modelo com TensorFlow
 - 5.10.3. Utilização da aplicação para previsão de resultados

Módulo 6. Deep Computer Vision com Redes Neurais Convolucionais

- 6.1. A Arquitetura do Visual Cortex
 - 6.1.1. Funções do córtex visual
 - 6.1.2. Teorias 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 com o Keras
 - 6.3.1. *Pooling e Striding*
 - 6.3.2. *Flattening*
 - 6.3.3. Tipos de *Pooling*
- 6.4. Arquiteturas CNN
 - 6.4.1. Arquitetura VGG
 - 6.4.2. Arquitetura AlexNet
 - 6.4.3. Arquitetura ResNet
- 6.5. Implementação de uma CNN ResNet-34 usando o Keras
 - 6.5.1. Inicialização de pesos
 - 6.5.2. Definição da camada de entrada
 - 6.5.3. Definição da saída
- 6.6. Uso 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 aprendizado por transferência
 - 6.7.1. 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 rastreamento de objetos
 - 6.9.1. Métodos de detecção de objetos
 - 6.9.2. Algoritmos de rastreamento de objetos
 - 6.9.3. Técnicas de rastreamento e localização
- 6.10. Segmentação semântica
 - 6.10.1. Aprendizagem profunda para segmentação semântica
 - 6.10.2. Detecção de bordas
 - 6.10.3. Métodos de segmentação baseados em regras

Módulo 7. Processamento de Sequências usando 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 de 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 aprendizagem
 - 7.4.3. Ajuste fino
- 7.5. Previsão de uma série de tempo
 - 7.5.1. Modelos estatísticos para previsão
 - 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. Análise de componentes principais
 - 7.6.2. Análise de Cluster
 - 7.6.3. Análise de correlações
- 7.7. Manejo 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. Aprendizagem de sequência parcial
 - 7.8.1. Métodos de aprendizagem profunda
 - 7.8.2. Modelos generativos
 - 7.8.3. Aprendizagem de 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 por computador
- 7.10. Diferenças nos resultados clássicos
 - 7.10.1. Métodos clássicos x
 - 7.10.2. Métodos clássicos x
 - 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 usando RNN
 - 8.1.1. Treinamento 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 do conjunto de dados de treinamento
 - 8.2.1. Preparação dos dados para treinamento de uma RNN
 - 8.2.2. Armazenamento do conjunto de dados de treinamento
 - 8.2.3. Limpeza e transformação dos dados
- 8.3. Análise de sentimento
 - 8.3.1. Classificação de 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 codificador-decodificador para tradução automática neural
 - 8.4.1. Treinamento de uma RNN para tradução automática
 - 8.4.2. Uso de uma rede *encoder-decoder* para tradução automática
 - 8.4.3. Aumento da precisão da tradução automática com RNN
- 8.5. Mecanismos de atenção
 - 8.5.1. Aplicação de mecanismos de atenção em RNN
 - 8.5.2. Uso de mecanismos de atenção para melhorar a precisão dos modelos
 - 8.5.3. Vantagens dos mecanismos de atenção em redes neurais
- 8.6. Modelos *Transformers*
 - 8.6.1. Uso de modelos *Transformers* para processamento de linguagem natural
 - 8.6.2. Aplicação de modelos *Transformers* para visão
 - 8.6.3. Vantagens dos modelos *Transformers*
- 8.7. Transformers para visão
 - 8.7.1. Uso de modelos *Transformers* para visão
 - 8.7.2. Processamento de dados Imagem
 - 8.7.3. Treinamento de modelos *transformação* para visão

- 8.8. Biblioteca *Transformers* de Hugging Face
 - 8.8.1. Uso da biblioteca *Transformers* de rostos abraçados
 - 8.8.2. Aplicação da Biblioteca *Transformers* de Hugging Face
 - 8.8.3. Vantagens da Biblioteca *Transformers* de Hugging Face
- 8.9. Outras bibliotecas *Transformers*. Comparativa
 - 8.9.1. Comparação entre as diferentes bibliotecas *Transformers*
 - 8.9.2. Uso das diferentes bibliotecas *Transformers*
 - 8.9.3. Vantagens das diferentes bibliotecas *Transformers*
- 8.10. Desenvolvimento de um aplicativo de PLN com RNN e atenção. Aplicação Prática
 - 8.10.1. Desenvolvimento de um aplicativo de processamento de linguagem natural com RNN e atenção
 - 8.10.2. Uso de RNN, mecanismos de atenção e modelos *Transformers* no aplicativo
 - 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. Aprendizado profundo
 - 9.1.3. Representações compactas
- 9.2. Realização de PCA com um codificador automático linear incompleto
 - 9.2.1. Processo de treinamento
 - 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. Uso da regularização
- 9.4. Autoencoders convolucionais
 - 9.4.1. Design de modelos convolucionais
 - 9.4.2. Treinamento de modelos convolucionais
 - 9.4.3. Avaliação de resultados

- 9.5. Eliminação de ruído de codificadores automáticos
 - 9.5.1. Aplicação de filtros
 - 9.5.2. Design de modelos de codificação
 - 9.5.3. Uso de técnicas de regularização
- 9.6. Codificadores automáticos dispersos
 - 9.6.1. Aumentando a eficiência da codificação
 - 9.6.2. Minimizando o número de parâmetros
 - 9.6.3. Utilização de técnicas de regularização
- 9.7. Codificadores automáticos variacionais
 - 9.7.1. Utilização de 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. Treinamento de Redes Neurais Profundas
- 9.9. Redes adversárias generativas e modelos de difusão
 - 9.9.1. Geração de conteúdo a partir de imagens
 - 9.9.2. Modelagem de distribuições de dados
 - 9.9.3. Uso de redes adversárias
- 9.10. Implementação dos Modelos. Aplicação Prática
 - 9.10.1. Implementação dos modelos
 - 9.10.2. Uso de dados reais
 - 9.10.3. Avaliação de resultados

Módulo 10. Reinforcement Learning

- 10.1. Otimização de recompensas e busca de políticas
 - 10.1.1. Algoritmos de otimização de recompensas
 - 10.1.2. Processos de busca de políticas
 - 10.1.3. Aprendizagem por reforço para otimizar 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 na OpenAI



- 
- 10.3. Políticas de redes neurais
 - 10.3.1. Redes neurais convolucionais para busca de políticas
 - 10.3.2. Políticas de aprendizagem profunda
 - 10.3.3. Extensão de políticas de redes neurais
 - 10.4. Avaliação de ações: o problema da atribuição de créditos
 - 10.4.1. Análise de risco para atribuição de créditos
 - 10.4.2. Estimativa de rentabilidade de empréstimos
 - 10.4.3. Modelos de avaliação de crédito baseados em redes neurais
 - 10.5. Gradientes de Política
 - 10.5.1. Aprendizagem 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. Aprendizagem por reforço para processos de decisão de Markov
 - 10.6.3. Modelos de processos de decisão de Markov
 - 10.7. Aprendizagem de diferenças temporais e *Q-Learning*
 - 10.7.1. Aplicação de diferenças temporais na aprendizagem
 - 10.7.2. Aplicação da *Q-Learning* em aprendizagem
 - 10.7.3. Otimização de parâmetros de *Q-Learning*
 - 10.8. Implementar *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 do *Deep Q-Learning*
 - 10.8.3. Variações do *Deep Q-Learning*
 - 10.9. Algoritmos de *Reinforcement Learning*
 - 10.9.1. Algoritmos de Aprendizagem por Reforço
 - 10.9.2. Algoritmos de Aprendizagem por Recompensa
 - 10.9.3. Algoritmos de Aprendizagem por Castigo
 - 10.10. Projeto de um Ambiente de aprendizagem por reforço. Aplicação Prática
 - 10.10.1. Projeto de um Ambiente de aprendizagem por reforço
 - 10.10.2. Implementação de um algoritmo de aprendizagem por reforço
 - 10.10.3. Avaliação de um Algoritmo de aprendizagem por reforço

06

Metodologia

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





“

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

Estudo de caso para contextualizar todo o conteúdo

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

“

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



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



Um método de aprendizagem inovador e diferente

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

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

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

O método do caso é o sistema de aprendizagem mais utilizado pelas melhores faculdades do mundo. Desenvolvido em 1912 para que os alunos de Direito pudessem aprender a lei não apenas com base no conteúdo teórico, o método do caso consistia em apresentar situações reais e complexas para que os alunos tomassem decisões e justificassem como resolvê-las. Em 1924 foi estabelecido como o método de ensino padrão em Harvard.

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

Metodologia Relearning

A TECH utiliza de maneira eficaz a metodologia do estudo de caso com um sistema de aprendizagem 100% online, baseado na repetição, combinando 8 elementos didáticos diferentes em cada aula.

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

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

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

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



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

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

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

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



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



Material de estudo

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

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



Masterclasses

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

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




Práticas de habilidades e competências


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



Leituras complementares

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





Estudos de caso

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



Resumos interativos

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

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



Testing & Retesting

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



07

Certificado

O Mestrado Próprio em Deep Learning garante, além da capacitação mais rigorosa e atualizada, o acesso a um título de Mestrado Próprio emitido pela TECH Universidade Tecnológica.



“

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

Este **Mestrado Próprio em Deep Learning** conta com o conteúdo mais completo e atualizado do mercado.

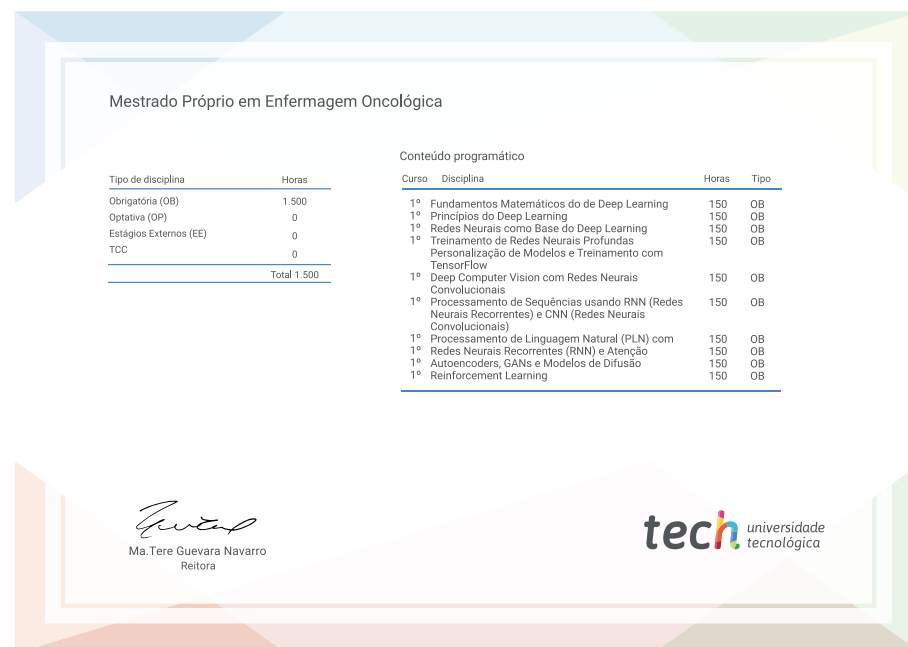
Uma vez aprovadas as avaliações, o aluno receberá por correio o certificado* do **Mestrado Próprio** emitido pela **TECH Universidade Tecnológica**.

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

Título: **Mestrado Próprio em Deep Learning**

Modalidade: **online**

Duração: **12 meses**



*Apostila de Haia: Caso o aluno solicite que seu certificado seja apostilado, a TECH EDUCATION 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 sustentabilidade

tech universidade
tecnológica

Mestrado Próprio Deep Learning

- » Modalidade: online
- » Duração: 12 meses
- » Certificado: TECH Universidade Tecnológica
- » Horário: no seu próprio ritmo
- » Provas: online

Mestrado Próprio

Deep Learning

