

Weiterbildender Masterstudiengang

Deep Learning



Weiterbildender Masterstudiengang Deep Learning

- » Modalität: **online**
- » Dauer: **12 monate**
- » Qualifizierung: **TECH Global University**
- » Akkreditierung: **60 ECTS**
- » Zeitplan: **in Ihrem eigenen Tempo**
- » Prüfungen: **online**

Internetzugang: www.techtitute.com/de/informatik/masterstudiengang/masterstudiengang-deep-learning



Index

01

Präsentation

Seite 4

02

Ziele

Seite 8

03

Kompetenzen

Seite 12

04

Kursleitung

Seite 16

05

Struktur und Inhalt

Seite 20

06

Methodik

Seite 30

07

Qualifizierung

Seite 38

01

Präsentation

Der technologische Aufschwung der letzten Jahre ist insbesondere auf die Entwicklung des *Deep Learning* zurückzuführen. Derzeit werden neue Herausforderungen in Bezug auf die Verbesserung und die Auswirkungen auf verschiedene Sektoren wie Industrie, Gaming, Automobilindustrie und Gesundheitswesen angegangen. In all diesen Bereichen werden Technologien gesucht, die eine intelligente Fehlererkennung, die Automatisierung von Prozessen oder die Entwicklung präziserer Diagnosegeräte ermöglichen. In diesem Szenario ist das Profil eines Informatikers mit fundierten technischen Kenntnissen in diesem Bereich von großer Bedeutung. Aus diesem Grund hat TECH diesen Studiengang entwickelt, der das fortschrittlichste Programm für künstliche Intelligenz und *Deep Learning* im akademischen Panorama bietet. Außerdem in einem 100%igen Online-Format, mit den innovativsten didaktischen Inhalten, die von anerkannten Spezialisten des Sektors ausgearbeitet wurden.

66

Revolutionieren Sie den Technologiesektor
dank dieses Weiterbildenden
Masterstudiengangs in Deep Learning"

Die rasante technologische Entwicklung der letzten Jahre hat das selbstfahrende Auto, die Früherkennung schwerer Krankheiten durch hochpräzise bildgebende Geräte oder die Gesichtserkennung durch mobile Anwendungen in greifbare Nähe gerückt. Diese neuen Innovationen zielen heute darauf ab, die Präzision der Automatisierung und die Qualität der erzielten Ergebnisse zu verbessern.

Ein Szenario, in dem der Informatiker eine entscheidende Rolle spielt, da er über fundierte Kenntnisse des *Deep Learning* verfügen und in der Lage sein muss, im Wettlauf der Industrie um die Schaffung einer echten künstlichen Intelligenz einen Schritt weiter zu gehen. Aus diesem Grund hat TECH diesen privaten 12-monatigen weiterbildenden Masterstudiengang mit dem fortschrittlichsten und aktuellsten Lehrplan entwickelt, der von echten Experten auf diesem Gebiet ausgearbeitet wurde.

Ein Programm mit theoretisch-praktischer Perspektive, das dem Studenten ein intensives Lernen der mathematischen Grundlagen, der Konstruktion neuronaler Netze, der Modellanpassung und des Trainings mit TensorFlow ermöglicht. Der umfangreiche Inhalt wird durch Videozusammenfassungen zu jedem Thema, Videos *in Focus*, Fachliteratur und Fallstudien erleichtert. Darüber hinaus ermöglicht das von TECH eingesetzte *Relearning*-System dem Informatiker ein natürlicheres Fortschreiten durch das Programm, eine leichtere Festigung der neuen Konzepte und somit eine Verkürzung der langen Studienzeiten.

Eine wissensbasierte universitäre Weiterbildung, die dem Studenten, der eine erstklassige akademische Option mit seinen täglichen Aktivitäten verbinden möchte, dabei hilft, sich beruflich weiterzuentwickeln. Alles, was man braucht, ist ein digitales Gerät mit Internetanschluss, um jederzeit auf diesen Studiengang zugreifen zu können, der an der Spitze der akademischen Welt steht.

Dieser **Weiterbildender Masterstudiengang in Deep Learning** enthält das vollständigste und aktuellste Programm auf dem Markt. Die hervorstechendsten Merkmale sind:

- ♦ Die Erarbeitung von Fallstudien, die von Experten in *Data Engineering* und *Data Science* vorgestellt werden
- ♦ Der anschauliche, schematische und äußerst praxisnahe Inhalt vermittelt alle für die berufliche Praxis unverzichtbaren wissenschaftlichen und praktischen Informationen
- ♦ Praktische Übungen, bei denen der Selbstbewertungsprozess zur Verbesserung des Lernens genutzt werden kann
- ♦ Sein besonderer Schwerpunkt liegt auf innovativen Methoden
- ♦ Theoretische Vorträge, Fragen an den Experten, Diskussionsforen zu kontroversen Themen und individuelle Reflexionsarbeit
- ♦ Die Verfügbarkeit des Zugriffs auf die Inhalte von jedem festen oder tragbaren Gerät mit Internetanschluss

“

Führen Sie Ihre KI-Projekte in Sektoren wie Automobil, Finanzen oder Medizin mit der Fortbildung von TECH zum Erfolg"

“

Lernen Sie in aller Ruhe die Transformers-Bibliotheken von Hugging Face und andere Tools zur Verarbeitung natürlicher Sprache kennen, die Sie auf Visionsprobleme anwenden können"

Sie haben Zugang zu einem fortgeschrittenen Lehrplan für Deep Learning, 24 Stunden am Tag, von jedem digitalen Gerät mit einer Internetverbindung.

Ein 12-monatiger weiterbildender Masterstudiengang mit der Anwendung von Deep Learning-Techniken auf reale Probleme.

Das Dozententeam des Programms besteht aus Fachleuten aus der Branche, die ihre Erfahrungen aus ihrer Arbeit in diese Fortbildung einbringen, sowie aus anerkannten Spezialisten von führenden Gesellschaften und renommierten Universitäten.

Die multimedialen Inhalte, die mit der neuesten Bildungstechnologie entwickelt wurden, werden der Fachkraft ein situiertes und kontextbezogenes Lernen ermöglichen, d. h. eine simulierte Umgebung, die eine immersive Fortbildung bietet, die auf die Ausführung von realen Situationen ausgerichtet ist

Das Konzept dieses Programms konzentriert sich auf problemorientiertes Lernen, bei dem die Fachkraft versuchen muss, die verschiedenen Situationen aus der beruflichen Praxis zu lösen, die während des gesamten Studiengangs gestellt werden. Zu diesem Zweck wird sie von einem innovativen interaktiven Videosystem unterstützt, das von renommierten Experten entwickelt wurde.



02 Ziele

Die Studenten, die diesen 1.500 Stunden umfassenden Studiengang absolvieren, haben die Möglichkeit, eine Weiterbildung zu absolvieren, die ihre Chancen auf eine Karriere im Technologiesektor, insbesondere im Bereich der Entwicklung künstlicher Intelligenz, erhöht. Um den Studenten zu helfen, dieses Ziel zu erreichen, bietet diese akademische Einrichtung innovative und leicht zugängliche didaktische Hilfsmittel sowie ein hervorragendes Team von Dozenten, die alle Zweifel, die während des Lernprozesses aufkommen könnten, ausräumen werden.



66

Sie werden starke analytische, problemlösende und algorithmische Fähigkeiten erwerben, um die Künstliche Intelligenz zu perfektionieren"



Allgemeine Ziele

- ◆ Verstehen der zentralen Konzepte von mathematischen Funktionen und deren Ableitungen
- ◆ Anwenden dieser Prinzipien auf Deep-Learning-Algorithmen für das automatische Lernen
- ◆ Untersuchen der wichtigsten Konzepte des überwachten Lernens und wie sie auf Modelle neuronaler Netze angewendet werden
- ◆ Erörterung des Trainings, der Bewertung und der Analyse von Modellen neuronaler Netze
- ◆ Verstehen der zentralen Konzepte und Hauptanwendungen des Deep Learning
- ◆ Implementieren und Optimieren neuronaler Netze mit Keras
- ◆ Entwickeln von Fachwissen über das Training tiefer neuronaler Netze
- ◆ Analysieren der Optimierungs- und Regularisierungsmechanismen, die für das Training von tiefen neuronalen Netzen erforderlich sind



TECH passt sich an Ihre beruflichen Bedürfnisse und Motivationen an und hat deshalb das umfassendste und flexibelste Programm zum Thema Deep Learning entwickelt"



Spezifische Ziele

Modul 1. Mathematische Grundlagen des Deep Learning

- ◆ Entwickeln der Kettenregel zur Berechnung von Ableitungen verschachtelter Funktionen
- ◆ Analysieren wie neue Funktionen aus bestehenden Funktionen erstellt werden und wie ihre Ableitungen berechnet werden
- ◆ Untersuchen des Konzepts des Rückwärtspasses und wie Ableitungen von Vektorfunktionen beim automatischen Lernen angewendet werden
- ◆ Lernen der Verwendung von TensorFlow zur Erstellung benutzerdefinierter Modelle
- ◆ Verstehen, wie man Daten mit TensorFlow-Tools lädt und verarbeitet
- ◆ Fundieren der zentralen Konzepte der natürlichen Sprachverarbeitung (NLP) mit RNN und Aufmerksamkeitsmechanismen
- ◆ Erforschen der Funktionalität der Hugging Face Transformers-Bibliotheken und anderer Tools zur Verarbeitung natürlicher Sprache für die Anwendung auf Sehprobleme
- ◆ Lernen Autoencoder-Modelle und GANs sowie Diffusionsmodelle zu konstruieren und zu trainieren
- ◆ Verstehen, wie Autoencoder verwendet werden können, um Daten effizient zu kodieren

Modul 2. Grundsätze des Deep Learning

- ◆ Analysieren der Funktionsweise der linearen Regression und deren Anwendung auf Modelle neuronaler Netze
- ◆ Fundieren von Hyperparameter-Optimierung zur Verbesserung der Leistung von Modellen neuronaler Netze
- ◆ Bestimmen wie die Leistung von Modellen neuronaler Netze anhand des Trainingssets und des Test-Sets bewertet werden kann

Modul 3. Neuronale Netze, die Grundlage von Deep Learning

- ◆ Analysieren der Architektur von neuronalen Netzen und ihrer Funktionsprinzipien
- ◆ Bestimmen wie neuronale Netze auf eine Vielzahl von Problemen angewendet werden können
- ◆ Festlegen, wie die Leistung von Deep Learning-Modellen durch die Abstimmung von Hyperparametern optimiert werden kann

Modul 4. Training Tiefer Neuronaler Netze

- ◆ Analysieren der Gradientenprobleme und wie sie vermieden werden können
- ◆ Bestimmen, wie vorgefertigte Schichten wiederverwendet werden können, um tiefe neuronale Netze zu trainieren
- ◆ Festlegen, wie die Trainingsrate zu programmieren ist, um die besten Ergebnisse zu erzielen

Modul 5. Anpassung von Modellen und Training mit TensorFlow

- ◆ Bestimmen wie die TensorFlow API benutzt werden, um eigene Funktionen und Graphen zu definieren
- ◆ Festigen von Grundlagen der Verwendung der tf.data API zum effizienten Laden und Vorverarbeiten von Daten
- ◆ Diskutieren des TensorFlow Datasets Projekts und wie es genutzt werden kann, um den Zugang zu vorverarbeiteten Datensätzen zu erleichtern

Modul 6. Deep Computer Vision mit Convolutional Neural Networks

- ◆ Erforschen und Verstehen, wie Faltungsschichten und Clustering-Schichten für die Architektur des visuellen Kortex funktionieren
- ◆ Entwickeln von CNN-Architekturen mit Keras
- ◆ Verwenden von vorgefertigten Keras-Modellen zur Objektklassifizierung, Lokalisierung, Erkennung und Verfolgung sowie zur semantischen Segmentierung

Modul 7. Verarbeitung von Sequenzen unter Verwendung von RNNs (Rekurrente Neuronale Netze) und CNNs (Convolutional Neural Networks)

- ◆ Analysieren der Architektur von Neuronen und rekurrenten Schichten
- ◆ Untersuchen der verschiedenen Trainingsalgorithmen für das Training von RNN-Modellen
- ◆ Bewerten der Leistung von RNN-Modellen anhand von Genauigkeits- und Sensitivitätsmetriken

Modul 8. Natürliche Sprachverarbeitung (NLP) mit Natürlichen Rekurrenten Netzen (RNN) und Aufmerksamkeit

- ◆ Generieren von Text mit rekurrenten neuronalen Netzen
- ◆ Trainieren eines Encoder-Decoder-Netzes zur Durchführung einer neuronalen maschinellen Übersetzung
- ◆ Entwickeln einer praktischen Anwendung der natürlichen Sprachverarbeitung mit RNN und Aufmerksamkeit

Modul 9. Autoencoder, GANs und Diffusionsmodelle

- ◆ Implementieren von PCA-Techniken mit einem unvollständigen linearen automatischen Kodierer
- ◆ Verwenden von Faltungs-Autoencodern und Variations-Autoencodern, um die Leistung von Autoencodern zu verbessern
- ◆ Analysieren, wie GANs und Diffusionsmodelle neue und realistische Bilder erzeugen können

Modul 10. Reinforcement Learning

- ◆ Verwenden von Gradienten zur Optimierung der Politik eines Agenten
- ◆ Bewerten des Einsatzes neuronaler Netze zur Verbesserung der Entscheidungsgenauigkeit eines Agenten
- ◆ Implementieren von verschiedenen Boosting-Algorithmen, um die Leistung eines Agenten zu verbessern

03

Kompetenzen

Dank dieses weiterbildenden Masterstudiengangs werden Fachkräfte für Informatik ihre technischen Kenntnisse und Fähigkeiten verbessern, um die Herausforderungen der Künstlichen Intelligenz zu meistern. Zu diesem Zweck vermittelt ihnen dieser Universitätsabschluss das nötige Wissen, um die wichtigsten Tools zu beherrschen, die für die Fortbildung in Deep Learning verwendet werden. So können sie Analysen durchführen und die wichtigsten Probleme lösen, die bei der Erstellung von Projekten in diesem Bereich bestehen.



66

Erweitern Sie mit diesem Programm
Ihre Fähigkeiten zur Implementierung
der Visuellen Cortex Architektur"

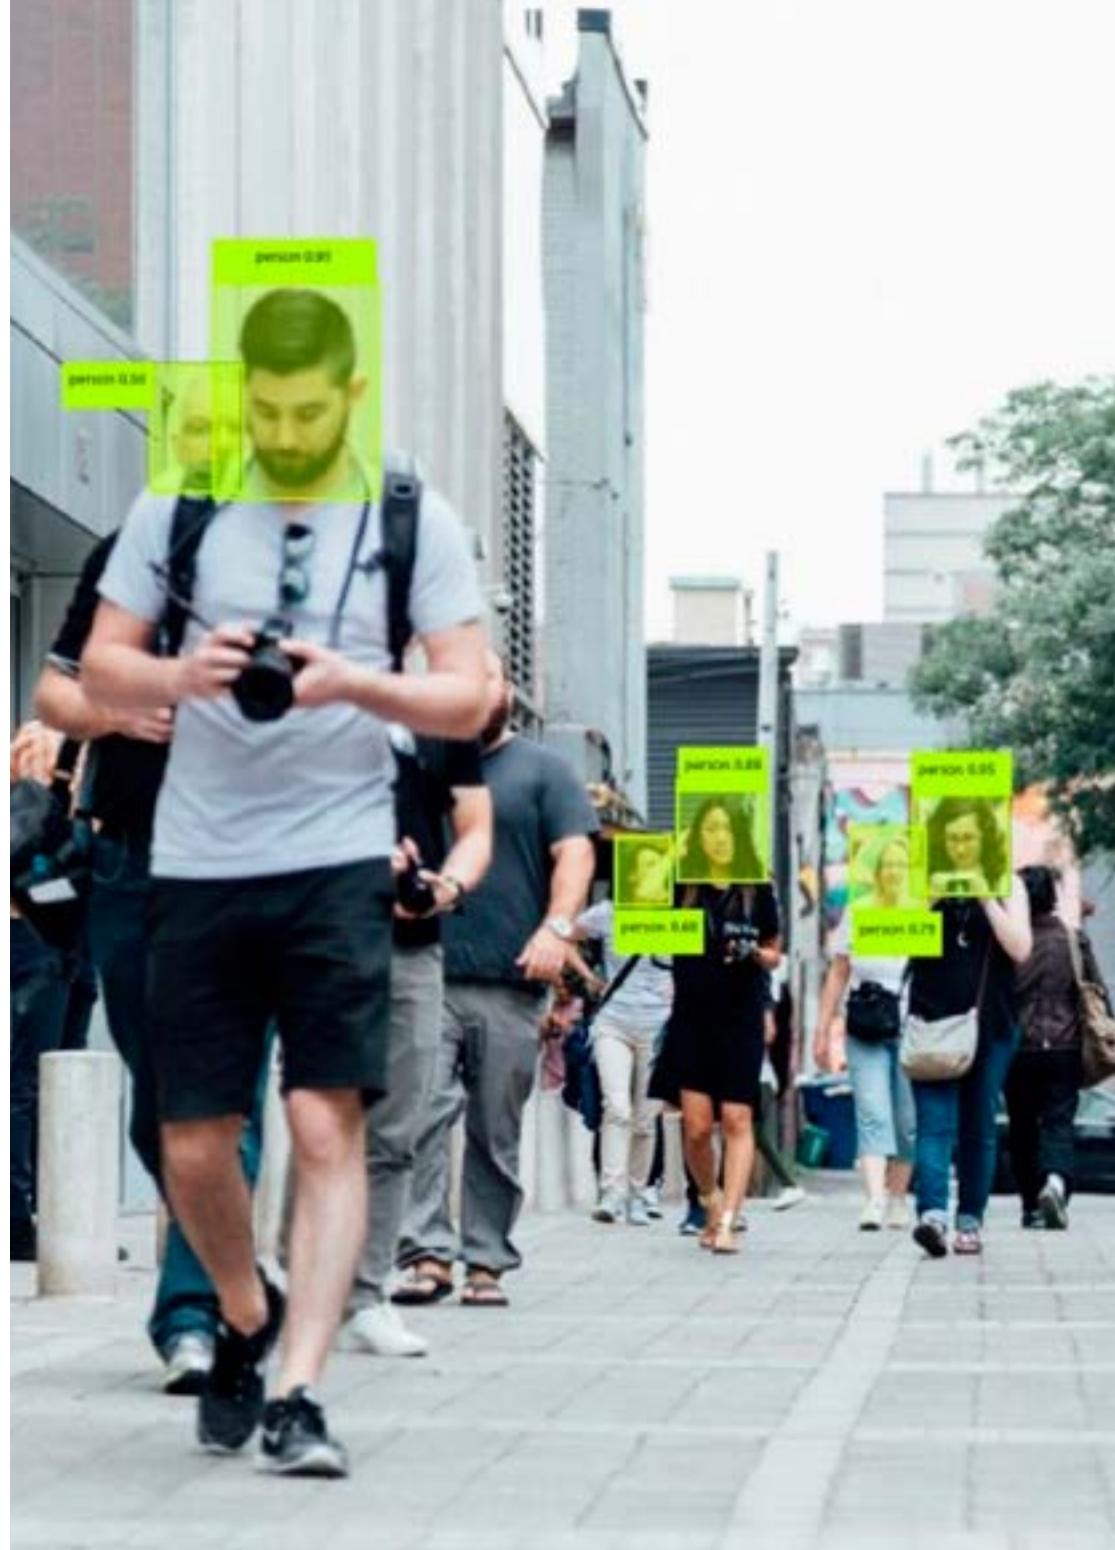


Allgemeine Kompetenzen

- ◆ Implementieren der Visuellen Cortex Architektur
- ◆ Verwenden von vortrainierten Keras-Modellen für *Transfer-Learning* und andere Computer-Vision-Aufgaben
- ◆ Beherrschen des Rekurrenten Neuronalen Netzes (RNN)
- ◆ Trainieren und Bewerten eines RNN-Modells für Zeitreihenprognosen
- ◆ Verbessern der Fähigkeit eines Agenten, optimale Entscheidungen in einer Umgebung zu treffen
- ◆ Steigern der Effizienz eines Agenten durch Lernen mit Belohnungen

“

Sie werden das Tool TensorFlow vollständig beherrschen und Deep-Learning-Modelle auf höchstem Niveau erstellen"





Spezifische Kompetenzen

- ◆ Lösen von Problemen mit Daten, was die Verbesserung bestehender Prozesse und die Entwicklung neuer Prozesse durch den Einsatz geeigneter technologischer Hilfsmittel beinhaltet
- ◆ Implementieren von datengesteuerten Projekten und Aufgaben
- ◆ Verwenden von Metriken wie Präzision, Genauigkeit und Klassifizierungsfehler
- ◆ Optimieren der Parameter eines neuronalen Netzes
- ◆ Erstellen eigener Modelle mit der TensorFlow API
- ◆ Implementieren von Aufgaben wie Klassifizierung, Lokalisierung, Objekterkennung und -verfolgung sowie semantische Segmentierung mit Keras
- ◆ Generieren von neuen und realistischen Bildern
- ◆ Implementieren von *Deep Q-Learning* und *Deep Q-Learning*-Varianten
- ◆ Verwenden von Optimierungstechniken für das Training
- ◆ Erfolgreiches Trainieren tiefer neuronaler Netze

04

Kursleitung

Um eine qualitativ hochwertige Weiterbildung zu gewährleisten, führt die TECH ein präzises Auswahlverfahren für jeden Dozenten durch, der an den Studiengängen teilnimmt. Auf diese Weise wird sichergestellt, dass die Studenten Zugang zu einem Abschluss haben, der von den besten Experten auf ihrem Gebiet entwickelt wurde. So werden die Studenten dieses weiterbildenden Masterstudiengangs einen Lehrplan vor sich haben, der von den besten Spezialisten im Bereich *Deep Learning* entwickelt wurde, die über eine langjährige Erfahrung in diesem Sektor verfügen.



66

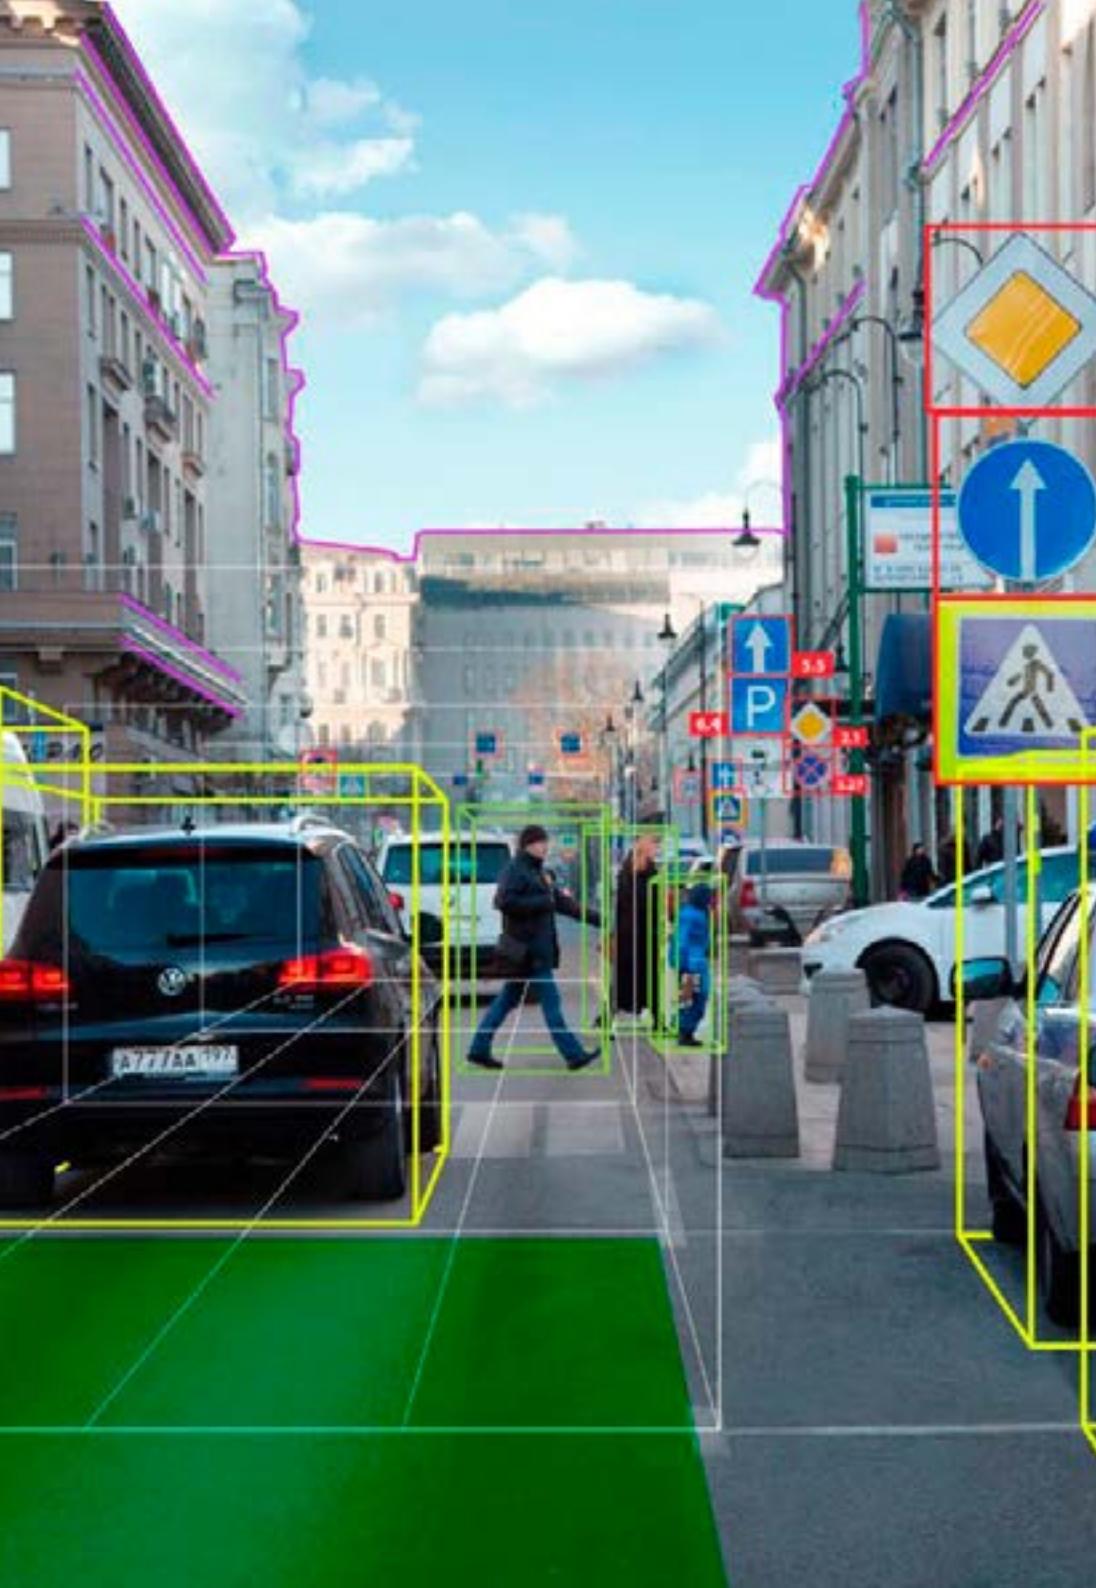
Großartige Spezialisten in Deep Learning und künstliche Intelligenz mit Erfahrung in Projekten für verschiedene Sektoren werden Sie dabei unterstützen, Ihre Karriereziele zu erreichen"

Leitung



Hr. Gil Contreras, Armando

- *Lead Big Data Scientist-Big Data* bei Jhonson Controls
- *Data Scientist-Big Data* bei Opensistemas
- Wirtschaftsprüfer im Bereich Kreativität und Technologie und PricewaterhouseCoopers
- Dozent an der EAE Business School
- Hochschulabschluss in Wirtschaftswissenschaften am Technologischen Institut von Santo Domingo INTEC
- Masterstudiengang in Data Science am Universitätszentrum für Technologie und Kunst
- Masterstudiengang MBA in Internationale Beziehungen und Wirtschaft am Finanzstudienzentrum CEF
- Aufbaustudiengang in Unternehmensfinanzierung am Technologischen Institut von Santo Domingo



Professoren

Hr. Delgado Panadero, Ángel

- ◆ ML-Ingenieur bei Paradigma Digital
- ◆ Computer Vision Ingenieur bei NTT Disruption
- ◆ Data Scientist bei Singular People
- ◆ Datenanalyst bei Parclick
- ◆ Tutor für den Masterstudiengang in Big Data und Analytik an der EAE Business School
- ◆ Hochschulabschluss in Physik an der Universität von Salamanca

Hr. Matos, Dionis

- ◆ Data Engineer bei Wide Agency Sodexo
- ◆ Data Consultant bei Tokiota Site
- ◆ Data Engineer bei Devoteam Testa Home
- ◆ Business Intelligence Developer bei Ibermatica Daimler
- ◆ Masterstudiengang in Big Data and Analytics /Project Management (Minor) an der EAE Business School

Hr. Villar Valor, Javier

- ◆ Direktor und Gründungspartner von Impulsa2
- ◆ Betriebsleiter bei Summa Insurance Brokers
- ◆ Verantwortlich für die Identifizierung von Verbesserungsmöglichkeiten bei Liberty Seguros
- ◆ Direktor für Transformation und Professionelle Exzellenz bei Johnson Controls Iberia
- ◆ Verantwortlich für die Organisation des Unternehmens Groupama Seguros
- ◆ Verantwortlich für die Lean Six Sigma-Methodik bei Honeywell
- ◆ Direktor für Qualität und Einkauf bei SP & PO
- ◆ Dozent an der Europäischen Wirtschaftsschule

05

Struktur und Inhalt

Der Lehrplan dieses Universitätsabschlusses nimmt die Studenten mit auf eine akademische Reise durch die mathematischen Grundlagen des *Deep Learning*, seine Prinzipien, das Training tiefer neuronaler Netze, die Visualisierung der Ergebnisse und die Bewertung von *Deep Learning*-Modellen. Umfassende Inhalte, die durch zahlreiche innovative Lehrmittel ergänzt werden, bilden die virtuelle Bibliothek dieses Programms.



66

*Mit dem Relearning-System verabschieden
Sie sich vom stundenlangen Lernen
und erhalten einen viel effektiveren und
einfacheren Lernprozess"*

Modul 1. Mathematische Grundlagen des Deep Learning

- 1.1. Funktionen und Ableitungen
 - 1.1.1. Lineare Funktionen
 - 1.1.2. Partielle Ableitungen
 - 1.1.3. Ableitungen höherer Ordnung
- 1.2. Verschachtelte Funktionen
 - 1.2.1. Zusammengesetzte Funktionen
 - 1.2.2. Inverse Funktionen
 - 1.2.3. Rekursive Funktionen
- 1.3. Kettenregel
 - 1.3.1. Ableitungen von verschachtelten Funktionen
 - 1.3.2. Ableitungen von zusammengesetzten Funktionen
 - 1.3.3. Ableitungen von inversen Funktionen
- 1.4. Funktionen mit mehreren Eingaben
 - 1.4.1. Funktionen von mehreren Variablen
 - 1.4.2. Vektorielle Funktionen
 - 1.4.3. Matrix-Funktionen
- 1.5. Ableitungen von Funktionen mit mehreren Eingängen
 - 1.5.1. Partielle Ableitungen
 - 1.5.2. Richtungsabhängige Ableitungen
 - 1.5.3. Gemischte Ableitungen
- 1.6. Funktionen mit mehreren Vektoreingabe
 - 1.6.1. Lineare Vektorfunktionen
 - 1.6.2. Nichtlineare Vektorfunktionen
 - 1.6.3. Matrix-Vektor-Funktionen
- 1.7. Erstellen neuer Funktionen aus bestehenden Funktionen
 - 1.7.1. Addition von Funktionen
 - 1.7.2. Produkt von Funktionen
 - 1.7.3. Komposition von Funktionen
- 1.8. Ableitungen von Funktionen mit mehreren Vektoreingaben
 - 1.8.1. Ableitungen von linearen Funktionen
 - 1.8.2. Ableitungen von nicht-linearen Funktionen
 - 1.8.3. Ableitungen von zusammengesetzten Funktionen

- 1.9. Vektorfunktionen und ihre Ableitungen: Ein Schritt weiter

- 1.9.1. Richtungsabhängige Ableitungen
 - 1.9.2. Gemischte Ableitungen
 - 1.9.3. Matrix-Ableitungen

- 1.10. Der *Backward Pass*

- 1.10.1. Fehlerausbreitung
 - 1.10.2. Anwendung von Aktualisierungsregeln
 - 1.10.3. Parameter-Optimierung

Modul 2. Grundsätze des Deep Learning

- 2.1. Überwachtes Lernen
 - 2.1.1. Maschinen für überwachtes Lernen
 - 2.1.2. Anwendungen des überwachten Lernens
 - 2.1.3. Unterschiede zwischen überwachtem und unüberwachtem Lernen
- 2.2. Überwachte Lernmodelle
 - 2.2.1. Lineare Modelle
 - 2.2.2. Entscheidungsbaum-Modelle
 - 2.2.3. Modelle neuronaler Netze
- 2.3. Lineare Regression
 - 2.3.1. Einfache lineare Regression
 - 2.3.2. Multiple lineare Regression
 - 2.3.3. Regressionsanalyse
- 2.4. Modell-Training
 - 2.4.1. *Batch Learning*
 - 2.4.2. *Online Learning*
 - 2.4.3. Optimierungsmethoden
- 2.5. Bewertung des Modells: Trainingsmenge vs. Testmenge
 - 2.5.1. Bewertungsmetriken
 - 2.5.2. Kreuzvalidierung
 - 2.5.3. Vergleich von Datensätzen

- 2.6. Bewertung des Modells: Der Code
 - 2.6.1. Generierung von Vorhersagen
 - 2.6.2. Fehleranalyse
 - 2.6.3. Bewertungsmetriken
- 2.7. Analyse der Variablen
 - 2.7.1. Identifizierung der relevanten Variablen
 - 2.7.2. Korrelationsanalyse
 - 2.7.3. Regressionsanalyse
- 2.8. Erklärbarkeit von Modellen neuronaler Netze
 - 2.8.1. Interpretierbare Modelle
 - 2.8.2. Visualisierungsmethoden
 - 2.8.3. Bewertungsmethoden
- 2.9. Optimierung
 - 2.9.1. Optimierungsmethoden
 - 2.9.2. Regularisierungs-Techniken
 - 2.9.3. Die Verwendung von Grafiken
- 2.10. Hyperparameter
 - 2.10.1. Auswahl von Hyperparametern
 - 2.10.2. Suche nach Parametern
 - 2.10.3. Abstimmung der Hyperparameter

Modul 3. Neuronale Netze, die Grundlage von Deep Learning

- 3.1. Tiefes Lernen
 - 3.1.1. Arten von tiefem Lernen
 - 3.1.2. Anwendungen von tiefem Lernen
 - 3.1.3. Vor- und Nachteile von tiefem Lernen
- 3.2. Operationen
 - 3.2.1. Addition
 - 3.2.2. Produkt
 - 3.2.3. Transfer
- 3.3. Ebenen
 - 3.3.1. Eingangsebene
 - 3.3.2. Ausgeblendete Ebene
 - 3.3.3. Ausgangsebene
- 3.4. Schichtenverbund und Operationen
 - 3.4.1. Design-Architekturen
 - 3.4.2. Verbindung zwischen Ebenen
 - 3.4.3. Vorwärtsausbreitung
- 3.5. Aufbau des ersten neuronalen Netzes
 - 3.5.1. Entwurf des Netzes
 - 3.5.2. Festlegen der Gewichte
 - 3.5.3. Training des Netzes
- 3.6. Trainer und Optimierer
 - 3.6.1. Auswahl des Optimierers
 - 3.6.2. Festlegen einer Verlustfunktion
 - 3.6.3. Festlegung einer Metrik
- 3.7. Anwendung der Prinzipien des neuronalen Netzes
 - 3.7.1. Aktivierungsfunktionen
 - 3.7.2. Rückwärtspropagation
 - 3.7.3. Einstellung der Parameter
- 3.8. Von biologischen zu künstlichen Neuronen
 - 3.8.1. Funktionsweise eines biologischen Neurons
 - 3.8.2. Wissensübertragung auf künstliche Neuronen
 - 3.8.3. Die Herstellung von Beziehungen zwischen den beiden
- 3.9. Implementierung von MLP (Multilayer Perceptron) mit Keras
 - 3.9.1. Definition der Netzstruktur
 - 3.9.2. Kompilierung des Modells
 - 3.9.3. Modell-Training
- 3.10. Fine Tuning der Hyperparameter von neuronalen Netzen
 - 3.10.1. Auswahl der Aktivierungsfunktion
 - 3.10.2. Einstellung der *Learning Rate*
 - 3.10.3. Einstellung der Gewichte

Modul 4. Training Tiefer Neuronaler Netze

- 4.1. Gradienten-Probleme
 - 4.1.1. Techniken der Gradientenoptimierung
 - 4.1.2. Stochastische Gradienten
 - 4.1.3. Techniken zur Initialisierung der Gewichte
- 4.2. Wiederverwendung von vortrainierten Schichten
 - 4.2.1. Training für Transferlernen
 - 4.2.2. Merkmalsextraktion
 - 4.2.3. Tiefes Lernen
- 4.3. Optimierer
 - 4.3.1. Stochastische Gradientenabstiegsoptimierer
 - 4.3.2. Adam- und RMSprop-Optimierer
 - 4.3.3. Moment-Optimierer
- 4.4. Programmierung der Lernrate
 - 4.4.1. Automatische Steuerung der Lernrate
 - 4.4.2. Lernzyklen
 - 4.4.3. Glättungsbedingungen
- 4.5. Überanpassung
 - 4.5.1. Kreuzvalidierung
 - 4.5.2. Regulierung
 - 4.5.3. Bewertungsmetriken
- 4.6. Praktische Leitlinien
 - 4.6.1. Entwurf von Modellen
 - 4.6.2. Auswahl der Metriken und Bewertungsparameter
 - 4.6.3. Testen von Hypothesen
- 4.7. *Transfer Learning*
 - 4.7.1. Training für Transferlernen
 - 4.7.2. Merkmalsextraktion
 - 4.7.3. Tiefes Lernen
- 4.8. *Data Augmentation*
 - 4.8.1. Bildtransformationen
 - 4.8.2. Generierung synthetischer Daten
 - 4.8.3. Text-Transformation





4.9. Praktische Anwendung von *Transfer Learning*

4.9.1. Training für Transferlernen

4.9.2. Merkmalsextraktion

4.9.3. Tiefes Lernen

4.10. Regulierung

4.10.1. L1 und L2

4.10.2. Maximale Entropie-Regularisierung

4.10.3. *Dropout*

Modul 5. Anpassung von Modellen und Training mit TensorFlow

5.1. TensorFlow

5.1.1. Die Verwendung der TensorFlow Bibliothek

5.1.2. Training von Modellen mit TensorFlow

5.1.3. Operationen mit Grafiken in TensorFlow

5.2. TensorFlow und NumPy

5.2.1. NumPy Berechnungsumgebung für TensorFlow

5.2.2. Die Verwendung von NumPy-Arrays mit TensorFlow

5.2.3. NumPy Operationen für TensorFlow Grafiken

5.3. Personalisierung von Modellen und Trainingsalgorithmen

5.3.1. Erstellen von benutzerdefinierten Modellen mit TensorFlow

5.3.2. Verwaltung von Trainingsparametern

5.3.3. Verwendung von Optimierungstechniken für das Training

5.4. TensorFlow Funktionen und Grafiken

5.4.1. TensorFlow Funktionen

5.4.2. Anwendung von Grafiken für das Modelltraining

5.4.3. Optimierung von Grafiken mit TensorFlow Operationen

5.5. Ladung und Vorverarbeitung von Daten mit TensorFlow

5.5.1. Ladung von Datensätzen mit TensorFlow

5.5.2. Vorverarbeitung von Daten mit TensorFlow

5.5.3. Verwendung von TensorFlow Tools zur Datenmanipulation

5.6. Die `tf.data` API

5.6.1. Die Verwendung der `tf.data` API für die Datenverarbeitung

5.6.2. Konstruktion von Datenströmen mit `tf.data`

5.6.3. Verwendung der `tf.data` API für das Modelltraining

- 5.7. Das TFRecord-Format
 - 5.7.1. Verwendung der TFRecord API für die Serialisierung von Daten
 - 5.7.2. Laden von TFRecord-Dateien mit TensorFlow
 - 5.7.3. Verwendung von TFRecord-Dateien für das Modelltraining
- 5.8. Keras Vorverarbeitungsschichten
 - 5.8.1. Verwendung der Keras-API für die Vorverarbeitung
 - 5.8.2. Konstruktion von Vorverarbeitungs-Pipelines mit Keras
 - 5.8.3. Verwendung der Keras Preprocessing-API für das Modelltraining
- 5.9. Das TensorFlow Datasets Projekt
 - 5.9.1. Verwendung von TensorFlow Datasets zum Laden von Daten
 - 5.9.2. Vorverarbeitung von Daten mit TensorFlow-Datasets
 - 5.9.3. Verwendung von TensorFlow-Datasets für das Modelltraining
- 5.10. Konstruktion einer Deep Learning Anwendung mit TensorFlow. Praktische Anwendung
 - 5.10.1. Konstruktion einer Deep Learning Anwendung mit TensorFlow
 - 5.10.2. Trainieren eines Modells mit TensorFlow
 - 5.10.3. Verwendung der Anwendung für die Ergebnisvorhersage
- 6.4. CNN-Architektur
 - 6.4.1. VGG-Architektur
 - 6.4.2. AlexNet-Architektur
 - 6.4.3. ResNet-Architektur
- 6.5. Implementierung eines ResNet-34 CNN mit Keras
 - 6.5.1. Initialisierung der Gewichte
 - 6.5.2. Definition der Eingabeschicht
 - 6.5.3. Definition der Ausgabe
- 6.6. Verwendung von vorgeübten Keras-Modellen
 - 6.6.1. Merkmale der vorgeübten Modelle
 - 6.6.2. Verwendung von vor-geübten Modellen
 - 6.6.3. Vorteile von vor-geübten Modellen
- 6.7. Vorgeübte Modelle für das Transferlernen
 - 6.7.1. Transferlernen
 - 6.7.2. Prozess des Transferlernens
 - 6.7.3. Vorteile des Transferlernens
- 6.8. Klassifizierung und Lokalisierung in Deep Computer Vision
 - 6.8.1. Bild-Klassifizierung
 - 6.8.2. Lokalisierung von Bildobjekten
 - 6.8.3. Objekt-Erkennung
- 6.9. Objekterkennung und Objektverfolgung
 - 6.9.1. Methoden zur Objekterkennung
 - 6.9.2. Algorithmen zur Objektverfolgung
 - 6.9.3. Verfolgungs- und Lokalisierungstechniken
- 6.10. Semantische Segmentierung
 - 6.10.1. Deep Learning für semantische Segmentierung
 - 6.10.2. Kantenerkennung
 - 6.10.3. Regelbasierte Segmentierungsmethoden

Modul 6. Deep Computer Vision mit Convolutional Neural Networks

- 6.1. Die Architektur des *Visual Cortex*
 - 6.1.1. Funktionen des visuellen Kortex
 - 6.1.2. Theorien des rechnergestützten Sehens
 - 6.1.3. Modelle der Bildverarbeitung
- 6.2. Faltungsebenen
 - 6.2.1. Wiederverwendung von Gewichten bei der Faltung
 - 6.2.2. 2D-Faltung
 - 6.2.3. Aktivierungsfunktionen
- 6.3. Gruppierungsschichten und Implementierung von Gruppierungsschichten mit Keras
 - 6.3.1. *Pooling* und *Striding*
 - 6.3.2. *Flattening*
 - 6.3.3. Arten des *Pooling*
- 6.4. CNN-Architektur
 - 6.4.1. VGG-Architektur
 - 6.4.2. AlexNet-Architektur
 - 6.4.3. ResNet-Architektur
- 6.5. Implementierung eines ResNet-34 CNN mit Keras
 - 6.5.1. Initialisierung der Gewichte
 - 6.5.2. Definition der Eingabeschicht
 - 6.5.3. Definition der Ausgabe
- 6.6. Verwendung von vorgeübten Keras-Modellen
 - 6.6.1. Merkmale der vorgeübten Modelle
 - 6.6.2. Verwendung von vor-geübten Modellen
 - 6.6.3. Vorteile von vor-geübten Modellen
- 6.7. Vorgeübte Modelle für das Transferlernen
 - 6.7.1. Transferlernen
 - 6.7.2. Prozess des Transferlernens
 - 6.7.3. Vorteile des Transferlernens
- 6.8. Klassifizierung und Lokalisierung in Deep Computer Vision
 - 6.8.1. Bild-Klassifizierung
 - 6.8.2. Lokalisierung von Bildobjekten
 - 6.8.3. Objekt-Erkennung
- 6.9. Objekterkennung und Objektverfolgung
 - 6.9.1. Methoden zur Objekterkennung
 - 6.9.2. Algorithmen zur Objektverfolgung
 - 6.9.3. Verfolgungs- und Lokalisierungstechniken
- 6.10. Semantische Segmentierung
 - 6.10.1. Deep Learning für semantische Segmentierung
 - 6.10.2. Kantenerkennung
 - 6.10.3. Regelbasierte Segmentierungsmethoden

Modul 7. Verarbeitung von Sequenzen unter Verwendung von RNNs
(Rekurrente Neuronale Netze) und CNNs (Convolutional Neural Networks)

- 7.1. Rekurrente Neuronen und Schichten
 - 7.1.1. Typen von rekurrenten Neuronen
 - 7.1.2. Architektur einer rekurrenten Schicht
 - 7.1.3. Anwendungen von rekurrenten Schichten
- 7.2. Training von rekurrenten neuronalen Netzen (RNN)
 - 7.2.1. Backpropagation über die Zeit (BPTT)
 - 7.2.2. Stochastischer abwärtsgerichteter Gradient
 - 7.2.3. Regularisierung beim RNN-Training
- 7.3. Bewertung von RNN-Modellen
 - 7.3.1. Bewertungsmetriken
 - 7.3.2. Kreuzvalidierung
 - 7.3.3. Abstimmung der Hyperparameter
- 7.4. Vortrainierte RNNs
 - 7.4.1. Vortrainierte Netze
 - 7.4.2. Übertragung des Lernens
 - 7.4.3. Feinabstimmung
- 7.5. Vorhersage einer Zeitserie
 - 7.5.1. Statistische Modelle für Prognosen
 - 7.5.2. Modelle von Zeitserien
 - 7.5.3. Auf neuronalen Netzen basierende Modelle
- 7.6. Interpretation der Ergebnisse der Zeitreihenanalyse
 - 7.6.1. Hauptkomponentenanalyse
 - 7.6.2. Cluster-Analyse
 - 7.6.3. Korrelationsanalyse
- 7.7. Umgang mit langen Sequenzen
 - 7.7.1. *Long Short-Term Memory* (LSTM)
 - 7.7.2. *Gated Recurrent Units* (GRU)
 - 7.7.3. 1D-Faltungskontrolle

- 7.8. Partielles Sequenzlernen
 - 7.8.1. Methoden des tiefen Lernens
 - 7.8.2. Generative Modelle
 - 7.8.3. Verstärktes Lernen
- 7.9. Praktische Anwendung von RNN und CNN
 - 7.9.1. Verarbeitung natürlicher Sprache
 - 7.9.2. Mustererkennung
 - 7.9.3. *Computer Vision*
- 7.10. Unterschiede in den klassischen Ergebnissen
 - 7.10.1. Klassische Methoden vs. RNN
 - 7.10.2. Klassische Methoden vs. CNN
 - 7.10.3. Unterschied in der Trainingszeit

Modul 8. Natürliche Sprachverarbeitung (NLP) mit Natürlichen
Rekurrenten Netzen (RNN) und Aufmerksamkeit

- 8.1. Textgenerierung mit RNN
 - 8.1.1. Training eines RNN für die Texterzeugung
 - 8.1.2. Generierung natürlicher Sprache mit RNN
 - 8.1.3. Anwendungen zur Texterzeugung mit RNN
- 8.2. Erstellung von Trainingsdatensätzen
 - 8.2.1. Vorbereitung der Daten für das RNN-Training
 - 8.2.2. Speicherung des Trainingsdatensatzes
 - 8.2.3. Bereinigung und Transformation der Daten
- 8.3. Sentiment-Analyse
 - 8.3.1. Ranking von Meinungen mit RNN
 - 8.3.2. Erkennung von Themen in Kommentaren
 - 8.3.3. Stimmungsanalyse mit *Deep Learning*-Algorithmen
- 8.4. *Encoder-Decoder*-Netz für neuronale maschinelle Übersetzung
 - 8.4.1. Training eines RNN für maschinelle Übersetzung
 - 8.4.2. Verwendung eines *Encoder-Decoder*-Netzes für die maschinelle Übersetzung
 - 8.4.3. Verbesserung der Genauigkeit der maschinellen Übersetzung mit RNNs

- 8.5. Aufmerksamkeitsmechanismen
 - 8.5.1. Implementierung von Aufmerksamkeitsmechanismen in RNN
 - 8.5.2. Verwendung von Betreuungsmechanismen zur Verbesserung der Modellgenauigkeit
 - 8.5.3. Vorteile von Betreuungsmechanismen in neuronalen Netzen
- 8.6. *Transformers*-Modelle
 - 8.6.1. Verwendung von *Transformers* -Modellen für die Verarbeitung natürlicher Sprache
 - 8.6.2. Anwendung von *Transformers*-Modellen für das Sehen
 - 8.6.3. Vorteile von *Transformers*-Modellen
- 8.7. *Transformers* für die Sicht
 - 8.7.1. Verwendung von *Transformers* für Seh-Modelle
 - 8.7.2. Vorverarbeitung von Bilddaten
 - 8.7.3. Training eines *Transformers*-Modells für die Sicht
- 8.8. *Hugging Face Transformers*-Bibliothek
 - 8.8.1. Verwendung der *Hugging Face Transformers*-Bibliothek
 - 8.8.2. Anwendung der *Hugging Face Transformers*-Bibliothek
 - 8.8.3. Vorteile der *Hugging Face Transformers*-Bibliothek
- 8.9. Andere *Transformers*-Bibliotheken. Vergleich
 - 8.9.1. Vergleich zwischen den verschiedenen *Transformers*-Bibliotheken
 - 8.9.2. Verwendung der anderen *Transformers*-Bibliotheken
 - 8.9.3. Vorteile der anderen *Transformers*-Bibliotheken
- 8.10. Entwicklung einer NLP-Anwendung mit RNN und Aufmerksamkeit. Praktische Anwendung
 - 8.10.1. Entwicklung einer Anwendung zur Verarbeitung natürlicher Sprache mit RNN und Aufmerksamkeit
 - 8.10.2. Verwendung von RNN, Aufmerksamkeitsmechanismen und *Transformers*-Modellen in der Anwendung
 - 8.10.3. Bewertung der praktischen Umsetzung
- 9.2. Realisierung von PCA mit einem unvollständigen linearen automatischen Kodierer
 - 9.2.1. Trainingsprozess
 - 9.2.2. Python-Implementierung
 - 9.2.3. Verwendung von Testdaten
- 9.3. Gestapelte automatische Kodierer
 - 9.3.1. Tiefe neuronale Netze
 - 9.3.2. Konstruktion von Kodierungsarchitekturen
 - 9.3.3. Verwendung der Regularisierung
- 9.4. Faltungs-Autokodierer
 - 9.4.1. Entwurf eines Faltungsmodells
 - 9.4.2. Training von Faltungsmodellen
 - 9.4.3. Auswertung der Ergebnisse
- 9.5. Automatische Entrauschung des Encoders
 - 9.5.1. Anwendung von Filtern
 - 9.5.2. Entwurf von Kodierungsmodellen
 - 9.5.3. Anwendung von Regularisierungstechniken
- 9.6. Automatische Verteilkodierer
 - 9.6.1. Steigerung der Kodierungseffizienz
 - 9.6.2. Minimierung der Anzahl von Parametern
 - 9.6.3. Verwendung von Regularisierungstechniken
- 9.7. Automatische Variationskodierer
 - 9.7.1. Verwendung der Variationsoptimierung
 - 9.7.2. Unüberwachtes tiefes Lernen
 - 9.7.3. Tiefe latente Repräsentationen
- 9.8. Modische MNIST-Bilderzeugung
 - 9.8.1. Mustererkennung
 - 9.8.2. Bilderzeugung
 - 9.8.3. Training tiefer neuronaler Netze
- 9.9. Generative Adversarial Networks und Diffusionsmodelle
 - 9.9.1. Bildbasierte Inhaltsgenerierung
 - 9.9.2. Modellierung von Datenverteilungen
 - 9.9.3. Verwendung von adversen Netzen

Modul 9. Autoencoder, GANs und Diffusionsmodelle

- 9.1. Effiziente Datendarstellungen
 - 9.1.1. Reduzierung der Dimensionalität
 - 9.1.2. Tiefes Lernen
 - 9.1.3. Kompakte Repräsentationen

- 9.10. Implementierung der Modelle. Praktische Anwendung
 - 9.10.1. Implementierung der Modelle
 - 9.10.2. Verwendung von realen Daten
 - 9.10.3. Auswertung der Ergebnisse

Modul 10. Reinforcement Learning

- 10.1. Optimierung der Belohnungen und der Richtliniensuche
 - 10.1.1. Algorithmen zur Belohnungsoptimierung
 - 10.1.2. Prozesse der Richtliniensuche
 - 10.1.3. Verstärktes Lernen für Belohnungsoptimierung
- 10.2. OpenAI
 - 10.2.1. OpenAI Gym Umgebung
 - 10.2.2. Erstellung von OpenAI-Umgebungen
 - 10.2.3. Algorithmen für verstärktes Lernen in OpenAI
- 10.3. Richtlinien für neuronale Netze
 - 10.3.1. Faltungsneuronale Netze für die Richtliniensuche
 - 10.3.2. Richtlinien für tiefes Lernen
 - 10.3.3. Erweitern von Richtlinien für neuronale Netze
- 10.4. Aktionsbewertung: das Problem der Kreditvergabe
 - 10.4.1. Risikoanalyse für die Kreditvergabe
 - 10.4.2. Schätzung der Rentabilität von Krediten
 - 10.4.3. Neuronale Netz-basierte Modelle zur Kreditbewertung
- 10.5. Richtliniengradienten
 - 10.5.1. Verstärktes Lernen mit Richtliniengradienten
 - 10.5.2. Optimierung der Richtliniengradienten
 - 10.5.3. Algorithmen der Richtliniengradienten
- 10.6. Markov-Entscheidungsprozesse
 - 10.6.1. Optimierung von Markov-Entscheidungsprozessen
 - 10.6.2. Verstärktes Lernen für Markov-Entscheidungsprozesse
 - 10.6.3. Modelle von Markov-Entscheidungsprozessen
- 10.7. Temporales Differenzlernen und *Q-Learning*
 - 10.7.1. Anwendung von zeitlichen Unterschieden beim Lernen
 - 10.7.2. Anwendung des *Q-Learning* beim Lernen
 - 10.7.3. Optimierung der Parameter des *Q-Learning*
- 10.8. Implementieren von Deep *Q-Learning* und Deep *Q-Learning*-Varianten
 - 10.8.1. Konstruktion von tiefen neuronalen Netzen für Deep *Q-Learning*
 - 10.8.2. Implementierung von Deep *Q-Learning*
 - 10.8.3. Deep *Q-Learning*-Varianten
- 10.9. Algorithmen des Reinforcement Learning
 - 10.9.1. Algorithmen für Verstärktes Lernen
 - 10.9.2. Algorithmen für Belohnungslernen
 - 10.9.3. Algorithmen für Bestrafungslernen
- 10.10. Entwurf einer verstärkenden Lernumgebung. Praktische Anwendung
 - 10.10.1. Entwurf einer verstärkenden Lernumgebung
 - 10.10.2. Implementierung eines verstärkenden Lernalgorithmus
 - 10.10.3. Auswertung eines verstärkenden Lernalgorithmus

“

Spezialisieren Sie sich dank dieses Universitätsabschlusses in Training, Bewertung und Analyse von neuronalen Netzwerkmodellen”

06

Methodik

Dieses Fortbildungsprogramm bietet eine andere Art des Lernens. Unsere Methodik wird durch eine zyklische Lernmethode entwickelt: ***das Relearning***.

Dieses Lehrsystem wird z. B. an den renommiertesten medizinischen Fakultäten der Welt angewandt und wird von wichtigen Publikationen wie dem ***New England Journal of Medicine*** als eines der effektivsten angesehen.



66

Entdecken Sie Relearning, ein System, das das herkömmliche lineare Lernen hinter sich lässt und Sie durch zyklische Lehrsysteme führt: eine Art des Lernens, die sich als äußerst effektiv erwiesen hat, insbesondere in Fächern, die Auswendiglernen erfordern"

Fallstudie zur Kontextualisierung aller Inhalte

Unser Programm bietet eine revolutionäre Methode zur Entwicklung von Fähigkeiten und Kenntnissen. Unser Ziel ist es, Kompetenzen in einem sich wandelnden, wettbewerbsorientierten und sehr anspruchsvollen Umfeld zu stärken.

“

Mit TECH werden Sie eine Art des Lernens erleben, die an den Grundlagen der traditionellen Universitäten auf der ganzen Welt rüttelt"



Sie werden Zugang zu einem Lernsystem haben, das auf Wiederholung basiert, mit natürlichem und progressivem Unterricht während des gesamten Lehrplans.



Der Student wird durch gemeinschaftliche Aktivitäten und reale Fälle lernen, wie man komplexe Situationen in realen Geschäftsumgebungen löst.

Eine innovative und andersartige Lernmethode

Dieses TECH-Programm ist ein von Grund auf neu entwickeltes, intensives Lehrprogramm, das die anspruchsvollsten Herausforderungen und Entscheidungen in diesem Bereich sowohl auf nationaler als auch auf internationaler Ebene vorsieht. Dank dieser Methodik wird das persönliche und berufliche Wachstum gefördert und ein entscheidender Schritt in Richtung Erfolg gemacht. Die Fallmethode, die Technik, die diesem Inhalt zugrunde liegt, gewährleistet, dass die aktuellste wirtschaftliche, soziale und berufliche Realität berücksichtigt wird.

“

Unser Programm bereitet Sie darauf vor, sich neuen Herausforderungen in einem unsicheren Umfeld zu stellen und in Ihrer Karriere erfolgreich zu sein"

Die Fallmethode ist das am weitesten verbreitete Lernsystem an den besten Informatikschulen der Welt, seit es sie gibt. Die Fallmethode wurde 1912 entwickelt, damit Jurastudenten das Recht nicht nur auf der Grundlage theoretischer Inhalte erlernen. Sie bestand darin, ihnen reale komplexe Situationen zu präsentieren, damit sie fundierte Entscheidungen treffen und Werturteile darüber fällen konnten, wie diese zu lösen sind. Sie wurde 1924 als Standardlehrmethode in Harvard etabliert.

Was sollte eine Fachkraft in einer bestimmten Situation tun? Mit dieser Frage konfrontieren wir Sie in der Fallmethode, einer handlungsorientierten Lernmethode.

Während des gesamten Kurses werden die Studenten mit mehreren realen Fällen konfrontiert. Sie müssen ihr gesamtes Wissen integrieren, recherchieren, argumentieren und ihre Ideen und Entscheidungen verteidigen.

Relearning Methodology

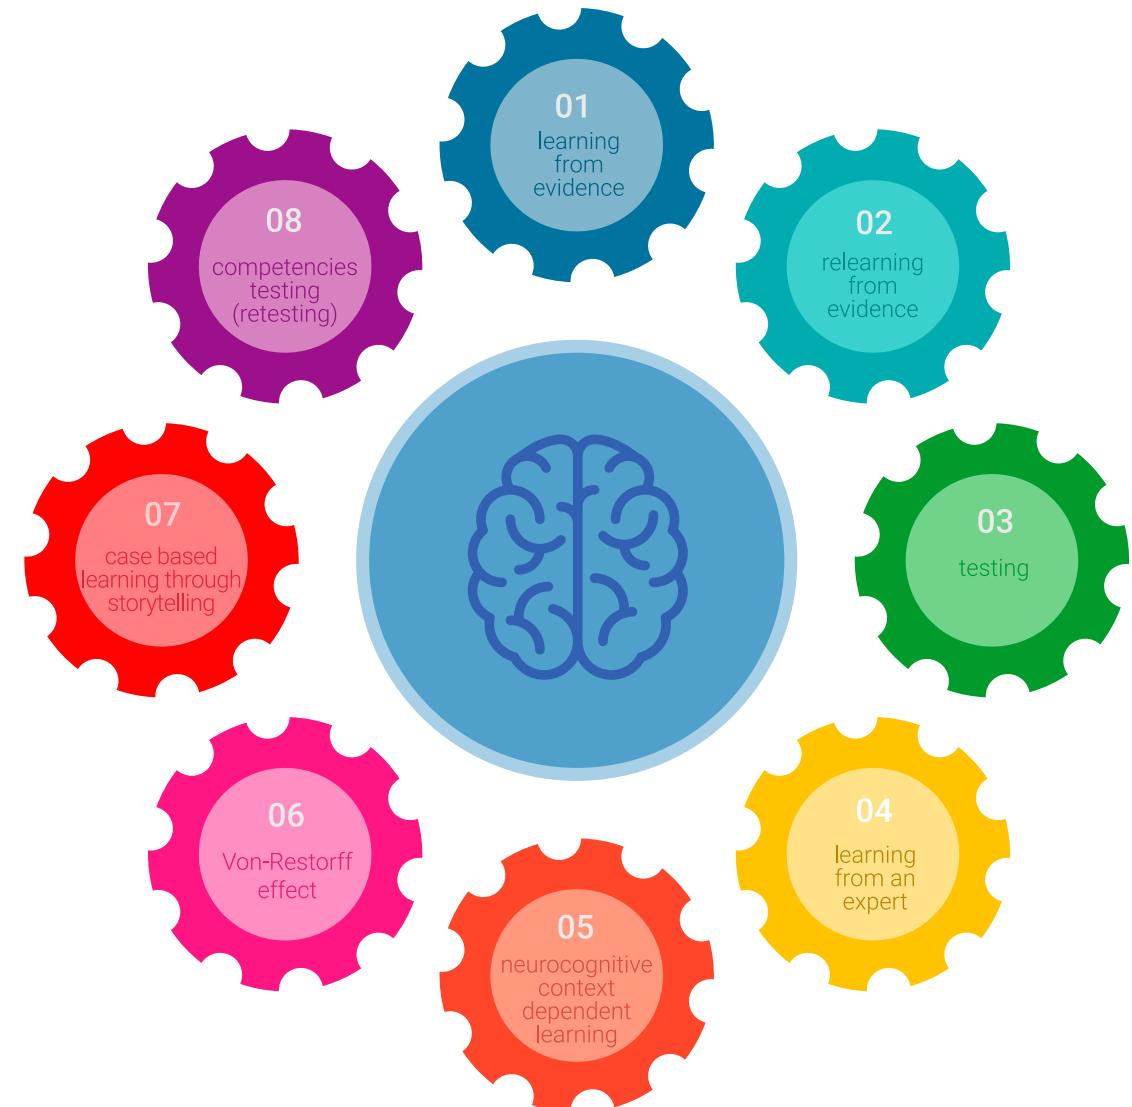
TECH kombiniert die Methodik der Fallstudien effektiv mit einem 100%igen Online-Lernsystem, das auf Wiederholung basiert und in jeder Lektion verschiedene didaktische Elemente kombiniert.

Wir ergänzen die Fallstudie mit der besten 100%igen Online-Lehrmethode: Relearning.

Im Jahr 2019 erzielten wir die besten Lernergebnisse aller spanischsprachigen Online-Universitäten der Welt.

Bei TECH lernen Sie mit einer hochmodernen Methodik, die darauf ausgerichtet ist, die Führungskräfte der Zukunft zu spezialisieren. Diese Methode, die an der Spitze der weltweiten Pädagogik steht, wird Relearning genannt.

Unsere Universität ist die einzige in der spanischsprachigen Welt, die für die Anwendung dieser erfolgreichen Methode zugelassen ist. Im Jahr 2019 ist es uns gelungen, die Gesamtzufriedenheit unserer Studenten (Qualität der Lehre, Qualität der Materialien, Kursstruktur, Ziele...) in Bezug auf die Indikatoren der besten spanischsprachigen Online-Universität zu verbessern.





In unserem Programm ist das Lernen kein linearer Prozess, sondern erfolgt in einer Spirale (lernen, verlernen, vergessen und neu lernen). Daher wird jedes dieser Elemente konzentrisch kombiniert. Mit dieser Methode wurden mehr als 650.000 Hochschulabsolventen mit beispiellosem Erfolg in so unterschiedlichen Bereichen wie Biochemie, Genetik, Chirurgie, internationales Recht, Managementfähigkeiten, Sportwissenschaft, Philosophie, Recht, Ingenieurwesen, Journalismus, Geschichte, Finanzmärkte und -instrumente fortgebildet. Dies alles in einem sehr anspruchsvollen Umfeld mit einer Studentenschaft mit hohem sozioökonomischem Profil und einem Durchschnittsalter von 43,5 Jahren.

Das Relearning ermöglicht es Ihnen, mit weniger Aufwand und mehr Leistung zu lernen, sich mehr auf Ihre Spezialisierung einzulassen, einen kritischen Geist zu entwickeln, Argumente zu verteidigen und Meinungen zu kontrastieren: eine direkte Gleichung zum Erfolg.

Nach den neuesten wissenschaftlichen Erkenntnissen der Neurowissenschaften wissen wir nicht nur, wie wir Informationen, Ideen, Bilder und Erinnerungen organisieren, sondern auch, dass der Ort und der Kontext, in dem wir etwas gelernt haben, von grundlegender Bedeutung dafür sind, dass wir uns daran erinnern und es im Hippocampus speichern können, um es in unserem Langzeitgedächtnis zu behalten.

Auf diese Weise sind die verschiedenen Elemente unseres Programms im Rahmen des so genannten Neurocognitive Context-Dependent E-Learning mit dem Kontext verbunden, in dem der Teilnehmer seine berufliche Praxis entwickelt.

Dieses Programm bietet die besten Lehrmaterialien, die sorgfältig für Fachleute aufbereitet sind:



Studienmaterial

Alle didaktischen Inhalte werden von den Fachleuten, die den Kurs unterrichten werden, speziell für den Kurs erstellt, so dass die didaktische Entwicklung wirklich spezifisch und konkret ist.

Diese Inhalte werden dann auf das audiovisuelle Format angewendet, um die Online-Arbeitsmethode von TECH zu schaffen. All dies mit den neuesten Techniken, die in jedem einzelnen der Materialien, die dem Studenten zur Verfügung gestellt werden, qualitativ hochwertige Elemente bieten.



Meisterklassen

Die Nützlichkeit der Expertenbeobachtung ist wissenschaftlich belegt.

Das sogenannte Learning from an Expert festigt das Wissen und das Gedächtnis und schafft Vertrauen für zukünftige schwierige Entscheidungen.



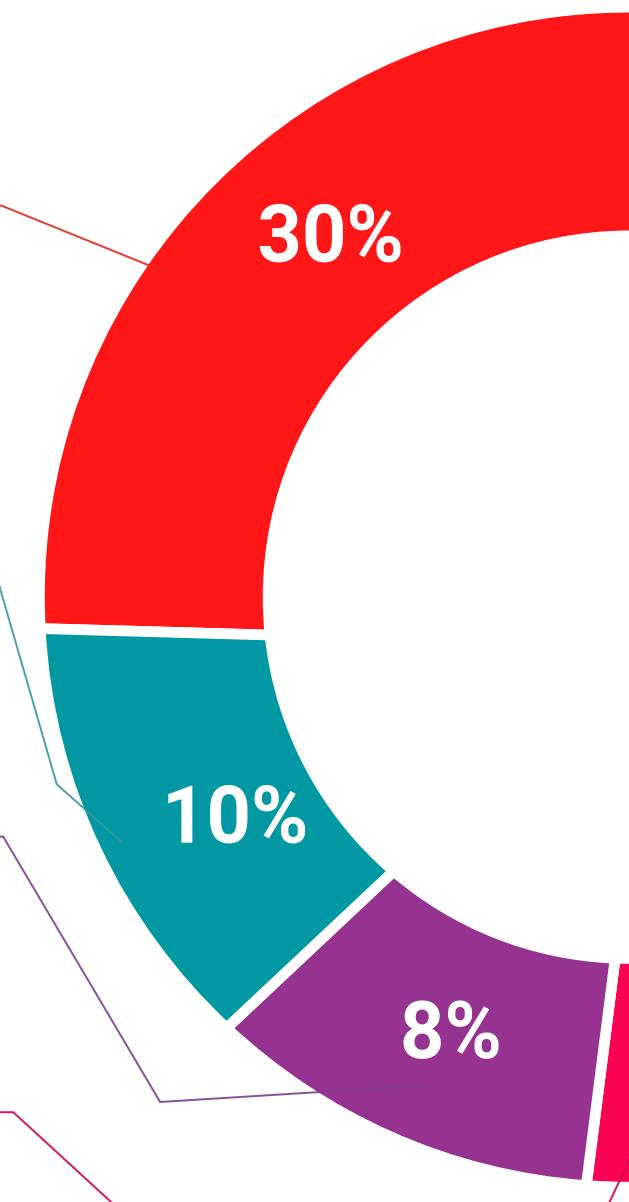
Übungen für Fertigkeiten und Kompetenzen

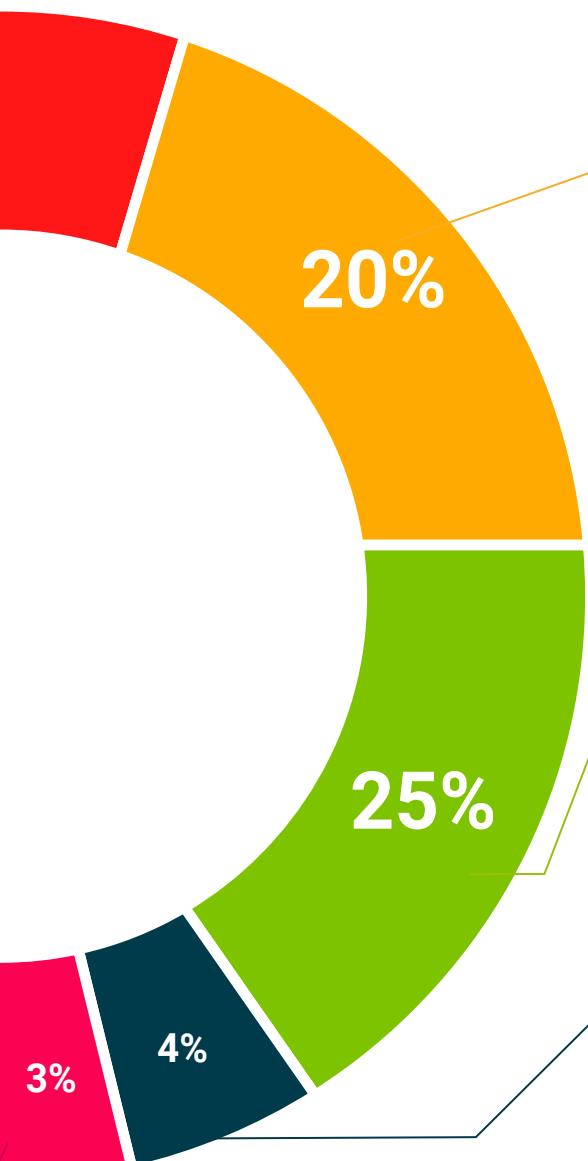
Sie werden Aktivitäten durchführen, um spezifische Kompetenzen und Fertigkeiten in jedem Fachbereich zu entwickeln. Übungen und Aktivitäten zum Erwerb und zur Entwicklung der Fähigkeiten und Fertigkeiten, die ein Spezialist im Rahmen der Globalisierung, in der wir leben, entwickeln muss.



Weitere Lektüren

Aktuelle Artikel, Konsensdokumente und internationale Leitfäden, u. a. In der virtuellen Bibliothek von TECH hat der Student Zugang zu allem, was er für seine Fortbildung benötigt.





Case Studies

Sie werden eine Auswahl der besten Fallstudien vervollständigen, die speziell für diese Qualifizierung ausgewählt wurden. Die Fälle werden von den besten Spezialisten der internationalen Szene präsentiert, analysiert und betreut.



Interaktive Zusammenfassungen

Das TECH-Team präsentiert die Inhalte auf attraktive und dynamische Weise in multimedialen Pillen, die Audios, Videos, Bilder, Diagramme und konzeptionelle Karten enthalten, um das Wissen zu vertiefen.

Dieses einzigartige Bildungssystem für die Präsentation multimedialer Inhalte wurde von Microsoft als "Europäische Erfolgsgeschichte" ausgezeichnet.



Testing & Retesting

Die Kenntnisse des Studenten werden während des gesamten Programms regelmäßig durch Bewertungs- und Selbsteinschätzungsaktivitäten und -übungen beurteilt und neu bewertet, so dass der Student überprüfen kann, wie er seine Ziele erreicht.



07

Qualifizierung

Der Weiterbildender Masterstudiengang in Deep Learning garantiert neben der strengsten und aktuellsten Ausbildung auch den Zugang zu einem von der TECH Global University ausgestellten Diplom.



“

Schließen Sie dieses Programm
erfolgreich ab und erhalten Sie
Ihren Universitätsabschluss ohne
lästige Reisen oder Formalitäten”

Mit diesem Programm erwerben Sie den von **TECH Global University**, der größten digitalen Universität der Welt, bestätigten eigenen Titel **Weiterbildender Masterstudiengang in Deep Learning**.

TECH Global University ist eine offizielle europäische Universität, die von der Regierung von Andorra ([Amtsblatt](#)) öffentlich anerkannt ist. Andorra ist seit 2003 Teil des Europäischen Hochschulraums (EHR). Der EHR ist eine von der Europäischen Union geförderte Initiative, die darauf abzielt, den internationalen Ausbildungsrahmen zu organisieren und die Hochschulsysteme der Mitgliedsländer dieses Raums zu vereinheitlichen. Das Projekt fördert gemeinsame Werte, die Einführung gemeinsamer Instrumente und die Stärkung der Mechanismen zur Qualitätssicherung, um die Zusammenarbeit und Mobilität von Studenten, Forschern und Akademikern zu verbessern.



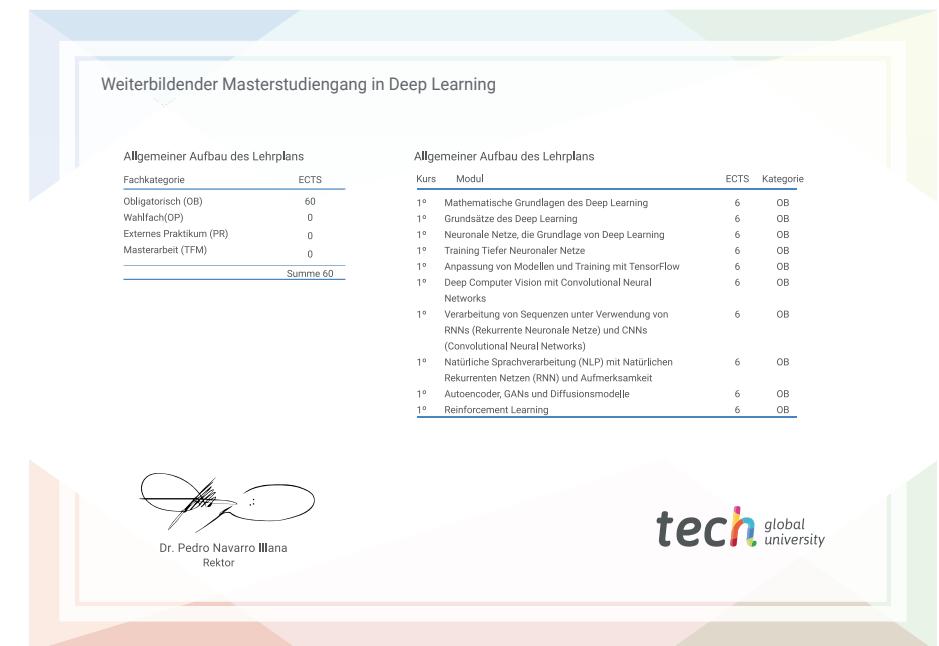
Dieser eigene Abschluss der **TECH Global University** ist ein europäisches Programm zur kontinuierlichen Weiterbildung und beruflichen Fortbildung, das den Erwerb von Kompetenzen in seinem Wissensgebiet garantiert und dem Lebenslauf des Studenten, der das Programm absolviert, einen hohen Mehrwert verleiht.

Titel: **Weiterbildender Masterstudiengang in Deep Learning**

Modalität: **online**

Dauer: **12 monate**

Akkreditierung: **60 ECTS**



zukunft
gesundheit vertrauen menschen
erziehung information tutoren
garantie akkreditierung unterricht
institutionen technologie lernen
gemeinschaft verpflichtungen
persönliche betreuung innovation
wissen gegenwart qualität
online-Ausbildung
entwicklung institutionen
virtuelles Klassenzimmer S



Weiterbildender
Masterstudiengang
Deep Learning

- » Modalität: online
- » Dauer: 12 monate
- » Qualifizierung: TECH Global University
- » Akkreditierung: 60 ECTS
- » Zeitplan: in Ihrem eigenen Tempo
- » Prüfungen: online

Weiterbildender Masterstudiengang

Deep Learning

