

Privater Masterstudiengang Deep Learning



Privater Masterstudiengang Deep Learning

- » Modalität: online
- » Dauer: 12 Monate
- » Qualifizierung: TECH Technische Universität
- » Aufwand: 16 Std./Woche
- » Zeitplan: in Ihrem eigenen Tempo
- » Prüfungen: online

Internetzugang: www.techtitude.com/de/ingenieurwissenschaften/masterstudiengang/masterstudiengang-deep-learning

Index

01

Präsentation

Seite 4

02

Ziele

Seite 8

03

Kompetenzen

Seite 14

04

Kursleitung

Seite 18

05

Struktur und Inhalt

Seite 22

06

Methodik

Seite 32

07

Qualifizierung

Seite 40

01

Präsentation

Von der Spracherkennung und automatischen Übersetzung von YouTube-Videos über die Interpretation von Objekten und Formen in Google Photos bis hin zur Betrugsbekämpfungsmethode von Privatbanken - all dies basiert auf *Deep Learning*. Die Fortschritte in der Automatisierung, der Bildanalyse und -erkennung sowie der Vorhersage für eine schnelle Entscheidungsfindung haben das Profil des professionellen Ingenieurs an Bedeutung gewinnen lassen. Diese Arbeit trägt zum Wachstum anderer Sektoren bei, weshalb es einen Bedarf an echten Spezialisten in diesem Bereich gibt. Aus diesem Grund wurde dieser 100%ige Online-Abschluss geschaffen, um den Studenten fortgeschrittene Kenntnisse zur Entwicklung von Projekten in den Bereichen Künstliche Intelligenz und Deep Learning zu vermitteln. Und das alles mit innovativem und aktuellem Lehrmaterial, das von wirklichen Fachkräften mit langjähriger Erfahrung in diesem Sektor erstellt wurde.



“

Erweitern Sie Ihren Wissensstand im Bereich Deep Learning mit diesem Masterstudiengang über 1.500 Unterrichtsstunden. Schreiben Sie sich jetzt ein"

Einer der am schnellsten wachsenden Sektoren der letzten Jahre ist zweifellos der Technologiesektor, angetrieben durch die technischen Fortschritte, die durch die Entwicklung des *Deep Learning* erzielt wurden. So gibt es immer mehr Chatbots, Gesichtserkennungsanwendungen und die Früherkennung von Krankheiten wie Krebs durch die Identifizierung hochwertiger medizinischer Bilder.

Eine Vielzahl von Möglichkeiten, die eine umfassende Beherrschung von *Deep Learning* durch professionelle Ingenieure erfordern. In diesem Sinne hat TECH die Entwicklung dieses 12-monatigen privaten Masterstudiengangs vorangetrieben, der den Studenten die fortschrittlichsten und aktuellsten Kenntnisse in diesem Bereich vermittelt.

Dieses Programm führt den Studenten in die mathematischen Grundlagen, die Konstruktion von neuronalen Netzen, die Personalisierung von Modellen und das Training mit TensorFlow oder in *Deep Computer Vision* mit *Convolutional Neural Networks* ein. All dies wird ergänzt durch didaktisches Material auf der Grundlage von Videozusammenfassungen zu jedem Thema, detaillierten Videos, spezieller Lektüre und Fallstudien, auf die sie bequem 24 Stunden am Tag von jedem elektronischen Gerät mit Internetanschluss aus zugreifen können.

Ein Lehrplan, der es Ihnen ermöglicht, Ihre Fähigkeiten zu verbessern, um Projekte zu erstellen, die sich auf die Datenanalyse, die Verarbeitung natürlicher Sprache oder ihre direkte Anwendung in Bereichen wie Robotik, Finanzen, *Spiele* oder autonome Autos konzentrieren.

Auf diese Weise eröffnet TECH eine Welt der Möglichkeiten dank eines hochwertigen Hochschulabschlusses, der von ausgewiesenen Experten entwickelt wurde und eine größere Freiheit bei der Selbstverwaltung des Studiums bietet. Die Studenten können jederzeit auf den Lehrplan zugreifen und ihre täglichen Aktivitäten mit einer akademischen Fortbildung auf höchstem Niveau vereinbaren, ohne vor Ort sein zu müssen oder einen engen Zeitplan zu haben.

Dieser **Privater 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 Zugangs zu Inhalten von jedem festen oder tragbaren Gerät mit Internetanschluss



Dieser Hochschulabschluss wird Ihnen den nötigen Schwung geben, um in den großen Technologieunternehmen der Gegenwart mitzuarbeiten. Schreiben Sie sich jetzt ein"

“

Bei diesem Programm müssen Sie sich nicht um die Teilnahme am Unterricht kümmern, Sie müssen nicht in der Klasse sein und Sie haben keinen festen Stundenplan. Greifen Sie auf die Studieninhalte zu, wann und wo immer Sie wollen"


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.

Beherrschen Sie GANS- und Diffusionsmodelle und verbessern Sie Ihre Projekte, um neue, realistische und qualitativ hochwertige Bilder zu erzeugen.

Ein Programm, das es Ihnen ermöglicht, den Backward Pass zu vertiefen und zu erfahren, wie die Ableitungen von Vektorfunktionen beim automatischen Lernen angewendet werden.



02 Ziele

TECH stellt allen Studenten zahlreiche innovative Lehrmaterialien zur Verfügung, damit sie in nur 12 Monaten die notwendigen Kenntnisse im Bereich *Deep Learning* erwerben können, die es ihnen ermöglichen, in einem der modernsten Sektoren der heutigen Zeit zu wachsen. Am Ende dieses Studiums werden die Studenten die notwendigen Fähigkeiten und Fertigkeiten entwickelt haben, um sich an Projekten der künstlichen Intelligenz und des Deep Learning zu beteiligen, die auf die Verbesserung verschiedener sozioökonomischer Bereiche abzielen.






“

Sie werden das Wissen erlangen, das Sie benötigen, um OpenAI-Umgebungen zu schaffen und Ihre Karriere voranzutreiben"



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
- ♦ Untersuchen 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 Optimierung und der Regularisierungsmechanismen, die für das Training tiefer Netze notwendig sind





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 *Backward Pass* 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 Transformer*-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 Trainings 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 vortrainierten Keras-Modellen zur Objektklassifizierung, Lokalisierung, Erkennung und Verfolgung sowie zur semantischen Segmentierung





Modul 7. Verarbeitung von Sequenzen mit RNN und CNN

- ♦ 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 verschiedener Boosting-Algorithmen zur Verbesserung der Leistung eines Agenten

03

Kompetenzen

Dieses fortgeschrittene Universitätsstudium ermöglicht es den Studenten, Systeme der künstlichen Intelligenz zu erforschen, zu entwickeln und zu entwerfen, die Vorhersagemodelle automatisieren. Diese technischen Fähigkeiten und Fertigkeiten können Sie in diesem Studiengang nicht nur durch die theoretische Ausrichtung des Programms, sondern auch durch die praktische Perspektive, die Sie durch die Simulationsszenarien erhalten, verbessern. Eine einzigartige Gelegenheit, die nur von TECH, der weltweit größten digitalen Universität, angeboten wird.





“

Verbessern Sie Ihre Fähigkeiten, um Chatbots zu entwickeln, die die Fragen der Nutzer besser verstehen und beantworten"



Allgemeine Kompetenzen

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

“

Dank dieses Universitätsabschlusses erhalten Sie einen praktischen und realen Einblick in die Anwendung der natürlichen Sprachverarbeitung mit RNN und Aufmerksamkeit"





Spezifische Kompetenzen

- ◆ Lösen von Problemen mit Daten, was die Verbesserung bestehender Prozesse und die Entwicklung neuer Prozesse durch den Einsatz geeigneter technologischer Instrumente beinhaltet
- ◆ Implementieren von datengesteuerten Projekten und Aufgaben
- ◆ Verwenden von Messgrößen 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

Diese akademische Einrichtung hat alle Anstrengungen unternommen, um ein exzellentes Team von Spezialisten für *Deep Learning* und dessen Anwendung in verschiedenen Bereichen zusammenzustellen. Auf diese Weise hat der Ingenieur die Garantie, Zugang zu einem Qualitätsprogramm zu haben, das für sein berufliches Vorankommen in einem wachsenden Sektor von großem Wert ist. Außerdem können die Studenten dank der Nähe der Lehrkräfte während ihrer gesamten akademischen Laufbahn etwaige Zweifel in Bezug auf den Inhalt des Studiengangs ausräumen.



“

*Experten mit umfangreichen Kenntnissen in
Tensorflow, Streaming-Architektur, Machine
Learning oder Big Data sind Teil dieser
exzellenten universitären Qualifizierung"*

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
- ◆ Operativer Geschäftsführer von 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

Dank der *Relearning-Methode*, die auf der kontinuierlichen Wiederholung von Schlüsselkonzepten während des gesamten Studiengangs basiert, wird der Ingenieur einen fortgeschrittenen und effektiven Lernerfolg erzielen, ohne dass er eine große Anzahl von Studienstunden investieren muss. Dadurch erhält er einen umfassenden Lehrplan über die Codierung von *Deep Learning*-Modellen, fortgeschrittene Optimierungstechniken, das Training von tiefen neuronalen Netzen, die Visualisierung der Ergebnisse und die Bewertung von *Deep Learning*-Modellen.





“

Greifen Sie von Ihrem digitalen Gerät mit Internetanschluss auf den fortschrittlichsten und aktuellsten Deep Learning-Lehrplan im akademischen Panorama zu"

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 nichtlinearen Funktionen
 - 1.8.3. Ableitungen von zusammengesetzten Funktionen S

- 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. Rückwärtsverschiebung
 - 3.7.3. Anpassungen 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. Aufbau von Beziehungen zwischen den beiden
- 3.9. Implementierung von MLP (Multilayer Perceptron) mit Keras
 - 3.9.1. Definition der Netzstruktur
 - 3.9.2. Zusammenstellung 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. Anpassung der Gewichte

Modul 4. Training Tiefer Neuronaler Netze

- 4.1. Steigungsprobleme
 - 4.1.1. Techniken der Gradientenoptimierung
 - 4.1.2. Stochastische Gradienten
 - 4.1.3. Techniken zur Initialisierung der Gewichte
- 4.2. Wiederverwendung von vorgefertigten Schichten
 - 4.2.1. Training zur Übertragung des Gelernten
 - 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. Momentane Optimierer
- 4.4. Programmierung der Lernrate
 - 4.4.1. Automatische Lernratenkontrolle
 - 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. Design von Modellen
 - 4.6.2. Auswahl von Metriken und Bewertungsparametern
 - 4.6.3. Hypothesenprüfung
- 4.7. *Transfer Learning*
 - 4.7.1. Training zur Übertragung des Gelernten
 - 4.7.2. Merkmalsextraktion
 - 4.7.3. Tiefes Lernen
- 4.8. *Data Augmentation*
 - 4.8.1. Bildtransformationen
 - 4.8.2. Erzeugung synthetischer Daten
 - 4.8.3. Textumwandlung
- 4.9. Praktische Anwendung von *Transfer Learning*
 - 4.9.1. Training zur Übertragung des Gelernten
 - 4.9.2. Merkmalsextraktion
 - 4.9.3. Tiefes Lernen
- 4.10. Regulierung
 - 4.10.1. L1 und L2
 - 4.10.2. Regulierung mit maximaler Entropie
 - 4.10.3. *Dropout*



Modul 5. Modellanpassung und Training mit TensorFlow

- 5.1. TensorFlow
 - 5.1.1. Verwendung der TensorFlow-Bibliothek
 - 5.1.2. Modelltraining mit TensorFlow
 - 5.1.3. Graphische Operationen in TensorFlow
- 5.2. TensorFlow und NumPy
 - 5.2.1. NumPy-Berechnungsumgebung für TensorFlow
 - 5.2.2. Verwendung von NumPy-Arrays mit TensorFlow
 - 5.2.3. NumPy-Operationen für TensorFlow-Graphiken
- 5.3. Anpassung von Trainingsmodellen und Algorithmen
 - 5.3.1. Eigene Modelle mit TensorFlow erstellen
 - 5.3.2. Verwaltung der Trainingsparameter
 - 5.3.3. Verwenden von Optimierungstechniken für das Training
- 5.4. TensorFlow-Funktionen und Graphiken
 - 5.4.1. Funktionen mit TensorFlow
 - 5.4.2. Verwendung von Graphiken für das Modelltraining
 - 5.4.3. Graphikoptimierung mit TensorFlow-Operationen
- 5.5. Laden und Vorverarbeiten von Daten mit TensorFlow
 - 5.5.1. Laden von Datensätzen mit TensorFlow
 - 5.5.2. Vorverarbeitung von Daten mit TensorFlow
 - 5.5.3. Verwendung von TensorFlow-Werkzeugen zur Datenmanipulation
- 5.6. Die tf.data-API
 - 5.6.1. Verwendung der tf.data-API für die Datenverarbeitung
 - 5.6.2. Aufbau von Datenflüssen mit tf.data
 - 5.6.3. Verwendung der tf.data-API zum Trainieren von Modellen
- 5.7. Das Format TFRecord
 - 5.7.1. Verwendung der TFRecord-API zur 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 Vorverarbeitungs-API
 - 5.8.2. Aufbau der Vorverarbeitung in Pipelines mit Keras
 - 5.8.3. Verwendung der Keras Vorverarbeitungs-API für das Modelltraining

- 5.9. Das TensorFlow Datasets-Projekt
 - 5.9.1. Verwendung von TensorFlow-Datensätzen 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. Modelltraining mit TensorFlow
 - 5.10.3. Nutzung der Anwendung zur Vorhersage von Ergebnissen

Modul 6. *Deep Computer Vision* mit *Convolutional Neural Networks*

- 6.1. Die Architektur des Visual Cortex
 - 6.1.1. Funktionen des Visual Cortex
 - 6.1.2. Theorien des rechnergestützten Sehens
 - 6.1.3. Bildverarbeitungsmodelle
- 6.2. Faltungsschichten
 - 6.2.1. Wiederverwendung von Gewichten bei der Faltung
 - 6.2.2. 2D-Faltung
 - 6.2.3. Aktivierungsfunktionen
- 6.3. Clustering-Schichten und Implementierung von Clustering-Schichten 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 vortrainierten Keras-Modellen
 - 6.6.1. Merkmale der vortrainierten Modelle
 - 6.6.2. Verwendungen der vortrainierten Modelle
 - 6.6.3. Vorteile der vortrainierten Modelle
- 6.7. Vorgefertigte Modelle für *Transfer Learning*
 - 6.7.1. Lernen durch Transfer
 - 6.7.2. Prozesse des Lernens durch Transfer
 - 6.7.3. Vorteile des Lernens durch Transfer
- 6.8. Klassifizierung und Lokalisierung in *Deep Computer Vision*
 - 6.8.1. Klassifizierung von Bildern
 - 6.8.2. Lokalisierung von Objekten in Bildern
 - 6.8.3. Erkennung von Objekten
- 6.9. Objekterkennung und Objektverfolgung
 - 6.9.1. Methoden zur Objekterkennung
 - 6.9.2. Algorithmen zur Objektverfolgung
 - 6.9.3. Tracking- und Tracing-Techniken
- 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 mit Hilfe von RNNs (Recurrent Neural Networks) und CNNs (Convolutional Neural Networks)

- 7.1. Rekurrente Neuronen und Schichten
 - 7.1.1. Typen von rekurrenten Neuronen
 - 7.1.2. Die 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 Netzwerke
 - 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*-Netzwerks 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 NRN
 - 8.5.2. Verwendung von Betreuungsmechanismen zur Verbesserung der Modellgenauigkeit
 - 8.5.3. Vorteile von Betreuungsmechanismen in neuronalen Netzen
- 8.6. *Transformer*-Modelle
 - 8.6.1. Verwendung von *Transformer*-Modellen für die Verarbeitung natürlicher Sprache
 - 8.6.2. Anwendung von *Transformer*-Modellen für das Sehen
 - 8.6.3. Vorteile von *Transformer*-Modellen
- 8.7. Transformatoren für das Sehen
 - 8.7.1. Verwendung von *Transformer* für die Sicht
 - 8.7.2. Vorverarbeitung von Bilddaten
 - 8.7.3. Training eines *Transformer*-Modells für die Sicht

- 8.8. *Hugging Face Transformer*-Bibliothek
 - 8.8.1. Verwendung der *Hugging Face Transformer*-Bibliothek
 - 8.8.2. Anwendung der *Hugging Face Transformer*-Bibliothek
 - 8.8.3. Vorteile der *Hugging Face Transformer*-Bibliothek
- 8.9. Andere *Transformer*-Bibliotheken. Vergleich
 - 8.9.1. Vergleich zwischen den verschiedenen *Transformer*-Bibliotheken
 - 8.9.2. Verwendung der anderen *Transformer*-Bibliotheken
 - 8.9.3. Vorteile der anderen *Transformer*-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 *Transformer*-Modellen in der Anwendung
 - 8.10.3. Bewertung der praktischen Umsetzung

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
- 9.2. 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 Adversarial Networks
- 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. Verstärkendes Lernen für Belohnungsoptimierung
- 10.2. OpenAI
 - 10.2.1. OpenAI Gym-Umgebung
 - 10.2.2. Erstellung von OpenAI-Umgebungen
 - 10.2.3. Algorithmen für verstärkendes Lernen in OpenAI





- 10.3. Richtlinien für neuronale Netze
 - 10.3.1. Neuronale Faltungsnetzwerke für die Politiksuche
 - 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. Verstärkendes 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. Verstärkendes 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 verstärkendes 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

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.





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 von den besten Fakultäten der Welt am häufigsten verwendete Lernsystem. 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 Programms 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 8 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 Privater Masterstudiengang in Deep Learning garantiert neben der präzisesten und aktuellsten Fortbildung auch den Zugang zu einem von der TECH Technologischen Universität ausgestellten Diplom.



“

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

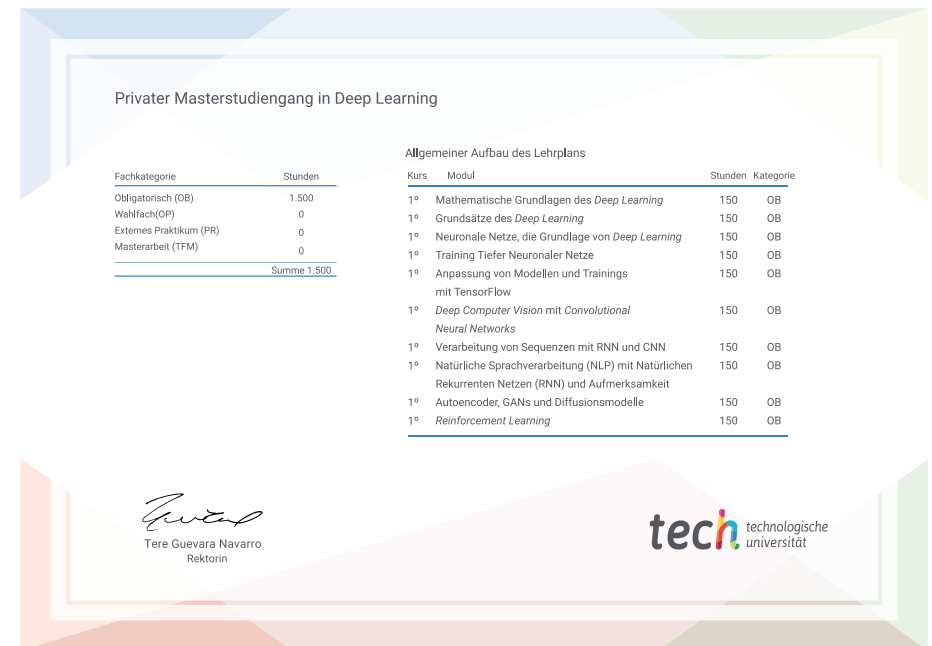
Dieser **Privater Masterstudiengang in Deep Learning** enthält das vollständigste und aktuellste Programm auf dem Markt.

Sobald der Student die Prüfungen bestanden hat, erhält er/sie per Post* mit Empfangsbestätigung das entsprechende Diplom, ausgestellt von der **TECH Technologischen Universität**.

Das von **TECH Technologische Universität** ausgestellte Diplom drückt die erworbene Qualifikation aus und entspricht den Anforderungen, die in der Regel von Stellenbörsen, Auswahlprüfungen und Berufsbildungsausschüssen verlangt werden.

Titel: **Privater Masterstudiengang in Deep Learning**

Anzahl der offiziellen Arbeitsstunden: **1.500 Std.**



*Haager Apostille. Für den Fall, dass der Student die Haager Apostille für sein Papierdiplom beantragt, wird TECH EDUCATION die notwendigen Vorkehrungen treffen, um diese gegen eine zusätzliche Gebühr zu beschaffen.

zukunft

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

tech technologische
universität

Privater Masterstudiengang Deep Learning

- » Modalität: online
- » Dauer: 12 Monate
- » Qualifizierung: TECH Technologische Universität
- » Aufwand: 16 Std./Woche
- » Zeitplan: in Ihrem eigenen Tempo
- » Prüfungen: online

Privater Masterstudiengang Deep Learning

