

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/kunstliche-intelligenz/weiterbildender-masterstudiengang/weiterbildender-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

Deep Learning hat in den letzten Jahren eine technologische Revolution ausgelöst. Diese Variante der künstlichen Intelligenz konzentriert sich auf das Training tiefer neuronaler Netze, um hierarchische Darstellungen von Daten zu lernen. Darüber hinaus gibt es eine breite Palette von Anwendungen, zum Beispiel in der Finanzwelt. So sind die Experten in der Lage, Betrug aufzudecken, Risiken zu analysieren und sogar Aktienkurse vorherzusagen. Es ist daher nicht verwunderlich, dass sich immer mehr Menschen für eine Spezialisierung in diesem Bereich entscheiden. Als Antwort auf diesen Bedarf bietet TECH eine Fortbildung an, die die Besonderheiten des *Deep Machine Learning* im Detail behandelt. Und das alles in einem 100%igen Online-Format, damit die Studenten es leichter haben.





“

Dank dieses 100%igen Online-Masterstudiengangs werden Sie die innovativsten Deep-Learning-Techniken auf Ihre Projekte anwenden"

TensorFlow hat sich zum wichtigsten Tool für die Implementierung und das Training von *Deep-Learning*-Modellen entwickelt. Entwickler nutzen sowohl die verschiedenen Tools als auch die Bibliotheken, um Modelle zu trainieren, die automatische Objekterkennung, Klassifizierung und natürliche Sprachverarbeitung durchführen. Ebenso ist diese Plattform nützlich für die Erkennung von Anomalien in Daten, was in Bereichen wie Cybersicherheit, vorausschauende Wartung und Qualitätskontrolle unerlässlich ist. Ihre Verwendung kann jedoch eine Reihe von Herausforderungen für Fachleute mit sich bringen, darunter die Auswahl der geeigneten Architektur des neuronalen Netzes.

Angesichts dieser Situation hat TECH einen weiterbildenden Masterstudiengang eingeführt, der Experten einen umfassenden Ansatz für *Deep Learning* bietet. Der Lehrplan, der von Spezialisten auf diesem Gebiet entwickelt wurde, wird sich mit den mathematischen Grundlagen und Prinzipien des *Deep Learning* befassen. Dies wird die Absolventen in die Lage versetzen, neuronale Netze zur Informationsverarbeitung aufzubauen, die Mustererkennung, Entscheidungsfindung und Lernen aus Daten beinhalten. Der Lehrplan wird auch das *Reinforcement Learning* vertiefen und dabei Faktoren wie die Optimierung der Belohnung und die Suche nach Strategien berücksichtigen. Darüber hinaus werden die Lehrmaterialien fortgeschrittene Techniken zur Optimierung und Visualisierung von Ergebnissen bieten.

Was das Format des Universitätsabschlusses betrifft, so wird er durch eine 100%ige Online-Methode vermittelt, so dass die Studenten das Programm auf unkomplizierte Weise absolvieren können. Um auf die akademischen Inhalte zuzugreifen, benötigen sie lediglich ein elektronisches Gerät mit Internetzugang, da die Stunden- und Bewertungspläne individuell festgelegt werden. Zudem basiert der Lehrplan auf dem innovativen *Relearning*-Lernsystem, bei dem TECH eine Vorreiterrolle spielt. Dieses Lernsystem besteht aus der Wiederholung der wichtigsten Aspekte, um die Beherrschung der verschiedenen Elemente zu gewährleisten.

Dieser **Weiterbildender Masterstudiengang in Deep Learning** enthält das vollständigste und aktuellste Programm auf dem Markt. Seine herausragendsten 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
- Die praktischen Übungen, bei denen der Selbstbewertungsprozess zur Verbesserung des Lernens durchgeführt 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



Lernen Sie durch innovative multimediale didaktische Formate, die Ihren Aktualisierungsprozess im Deep Learning optimieren werden"



Möchten Sie Ihre Praxis mit den fortschrittlichsten Techniken der Gradientenoptimierung bereichern? Erreichen Sie es mit diesem Programm in nur 12 Monaten"

Das Dozententeam des Programms besteht aus Experten des Sektors, die ihre Berufserfahrung in diese Fortbildung einbringen, sowie aus renommierten Fachleuten von führenden Unternehmen und angesehenen Universitäten.

Die multimedialen Inhalte, die mit der neuesten Bildungstechnologie entwickelt wurden, werden der Fachkraft ein situierendes 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.

Sie werden tiefer in den Backward Pass einsteigen, um die Gradienten der Verlustfunktion in Bezug auf die Netzwerkparameter zu berechnen.

Dank der Relearning-Methode können Sie Ihren Stundenplan frei gestalten.



02 Ziele

Dank dieses weiterbildenden Masterstudiengangs werden die Studenten ihre Fähigkeiten und Kenntnisse auf dem Gebiet des Deep Learning und der künstlichen Intelligenz ausbauen. So werden sie die fortschrittlichsten *Deep-Learning*-Techniken in ihren Projekten einsetzen, um die Leistung der Modelle bei bestimmten Aufgaben zu verbessern. Ebenso werden die Experten in der Lage sein, intelligente Systeme zu entwickeln, die automatisch Aufgaben wie die Mustererkennung in Bildern, die Stimmungsanalyse in Texten oder die Erkennung von Anomalien in Daten durchführen können.



“

Ein Universitätsabschluss, der auf der Grundlage der neuesten Trends im Bereich Deep Learning entwickelt wurde, um Ihnen erfolgreiches Lernen zu garantieren"



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 von Objekten 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 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 Richtlinien eines Agenten
- ♦ Bewerten des Einsatzes neuronaler Netze zur Verbesserung der Entscheidungsgenauigkeit eines Agenten
- ♦ Implementieren verschiedener Boosting-Algorithmen zur Verbesserung der Leistung eines Agenten





“

Eine wichtige, einzigartige und entscheidende Fortbildung, die Ihre berufliche Entwicklung vorantreiben wird"

03

Kompetenzen

Durch den weiterbildenden Masterstudiengang werden die Studenten neue Fähigkeiten erwerben, um die Herausforderungen der künstlichen Intelligenz erfolgreich zu meistern. Nach Abschluss des Studiengangs werden die Fachleute die Verwendung von TensorFlow-Tools zur Datenmanipulation beherrschen. Darüber hinaus werden die Experten das Training von tiefen neuronalen Netzen optimal nutzen, um komplexe Probleme zu lösen und genaue Modelle zu erstellen. Auf diese Weise werden sie innovative Vorschläge unterbreiten, um sich in einem boomenden Technologiesektor abzuheben.



signal 0.95



“

Sie werden fortgeschrittene Fähigkeiten erwerben, um die Visual Cortex-Architektur in Ihren Projekten zu implementieren"



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

“

Sie werden das TensorFlow-Tool verwenden, um Daten zu manipulieren und High-Level-Modelle für maschinelles Lernen zu erstellen"





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

Um eine Fortbildung auf höchstem Niveau anbieten zu können, führt TECH ein strenges Auswahlverfahren für jeden der Lehrkräfte durch, die ihre Hochschulabschlüsse vermitteln. Daher haben Studenten, die diesen weiterbildenden Masterstudiengang belegen, Zugang zu einem Lehrplan, der von den besten Experten auf dem Gebiet des *Deep Learning* entworfen wurde. Außerdem zeichnen sich diese Fachleute nicht nur durch ihr solides Verständnis des Themas aus, sondern auch durch ihre umfangreiche Berufserfahrung in renommierten Institutionen. All dies wird es den Studenten ermöglichen, in eine immersive Erfahrung einzutauchen, die es ihnen ermöglicht, in ihrer beruflichen Laufbahn einen Sprung nach vorne zu machen.



“

Die Vielfalt der Talente des Lehrkörpers ermöglicht es Ihnen, ein absolut dynamisches und bereicherndes Lehrumfeld zu genießen"

Leitung



Hr. Gil Contreras, Armando

- *Lead Big Data Scientist* bei Jhonson Controls
- *Data Scientist-Big Data* bei Opensistemas S.A.
- Wirtschaftsprüfer bei Creatividad y Tecnología S.A. (CYTSA)
- Wirtschaftsprüfer für den öffentlichen Sektor bei PricewaterhouseCoopers Auditors
- Masterstudiengang in *Data Science* am Universitätszentrum für Technologie und Kunst
- Masterstudiengang MBA in Internationale Beziehungen und Wirtschaft am Finanzstudienzentrum (CEF)
- Hochschulabschluss in Wirtschaftswissenschaften am Technologischen Institut von Santo Domingo

Professoren

Fr. Delgado Feliz, Benedit

- Verwaltungsassistentin und Operatorin für elektronische Überwachung bei der Nationalen Drogenkontrollbehörde (DNCD)
- Kundenservice in Cáceres und Geräte
- Reklamationen und Kundendienst bei Express Parcel Services (EPS)
- Spezialistin für Microsoft Office von der Nationalen Schule für Informatik
- Soziale Kommunikatorin von der Katholischen Universität Santo Domingo (UCSD)

Hr. Villar Valor, Javier

- Direktor und Gründungspartner von Impulsa2
- *Chief Operations Officer (COO)* bei Summa Insurance Brokers
- Direktor für Transformation und betriebliche Exzellenz bei Johnson Controls
- Masterstudiengang in Professionelles *Coaching*
- Executive MBA der Emlyon Business School, Frankreich
- Masterstudiengang in Qualitätsmanagement von EOI
- Hochschulabschluss in Computertechnik an der Universität Acción Pro-Educación y Cultura (UNAPEC)



Hr. Matos Rodríguez, Dionis

- ♦ *Data Engineer* bei Wide Agency Sodexo
- ♦ *Data Consultant* bei Tokiota
- ♦ *Data Engineer* bei Devoteam
- ♦ *BI Developer* bei Ibermática
- ♦ *Applications Engineer* bei Johnson Controls
- ♦ *Database Developer* bei Suncapital Spanien
- ♦ *Senior Web Developer* bei Deadlock Solutions
- ♦ *QA Analyst* bei Metaconcept
- ♦ Masterstudiengang in Big Data & Analytics von der EAE Business School
- ♦ Masterstudiengang in Systemanalyse und -design
- ♦ Hochschulabschluss in Computertechnik an der Universität APEC

Fr. Gil de León, María

- ♦ Co-Direktorin für Marketing und Sekretärin bei RAÍZ Magazine
- ♦ Redakteurin bei Gauge Magazine
- ♦ Lektorin des Stork Magazine am Emerson College
- ♦ Hochschulabschluss in Schreibkunst, Literatur und Verlagswesen am Emerson College

05

Struktur und Inhalt

Dieser weiterbildende Masterstudiengang bietet den Studenten eine breite Palette von *Deep-Learning*-Techniken, die ihren beruflichen Horizont auf ein höheres Niveau heben werden. Um dies zu erreichen, wird sich der Studiengang mit der Kodierung von *Deep-Learning*-Modellen befassen. Auf diese Weise werden die Studenten in der Lage sein, die Algorithmen und Architekturen von tiefen neuronalen Netzen effektiv umzusetzen. Darüber hinaus wird der Lehrplan das Training von tiefen neuronalen Netzen sowie die Visualisierung von Ergebnissen und die Bewertung von Lernmodellen im Detail behandeln. Die Studenten werden auch die wichtigsten *Transformer*-Modelle analysieren, um sie zur Erstellung automatischer Übersetzungen zu verwenden.



“

Sie werden die Prinzipien des Deep Learning in Ihren Projekten anwenden, um eine Vielzahl komplexer Probleme in Bereichen wie der Bilderkennung zu lösen"

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
- 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. Rückwärtsausbreitung
 - 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. Herstellung von Beziehungen zwischen den beiden
- 3.9. Implementierung von MLP (Multilayer Perceptron) mit Keras
 - 3.9.1. Definition der Netzstruktur
 - 3.9.2. Modell-Kompilierung
 - 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. *Transfer Learning Training*
 - 4.2.2. Merkmalsextraktion
 - 4.2.3. Tiefes Lernen
- 4.3. Optimierer
 - 4.3.1. Stochastische Gradientenabstiegs-Optimierer
 - 4.3.2. Adam und RMSprop-Optimierer
 - 4.3.3. Moment-Optimierer
- 4.4. Planen der Lernrate
 - 4.4.1. Automatische Steuerung der Lernrate
 - 4.4.2. Lernzyklen
 - 4.4.3. Bedingungen für die Glättung
- 4.5. Überanpassung
 - 4.5.1. Kreuzvalidierung
 - 4.5.2. Regulierung
 - 4.5.3. Bewertungsmetriken
- 4.6. Praktische Leitlinien
 - 4.6.1. Entwurf des Modells
 - 4.6.2. Auswahl der Metriken und Bewertungsparameter
 - 4.6.3. Testen von Hypothesen
- 4.7. *Transfer Learning*
 - 4.7.1. *Transfer Learning Training*
 - 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. Textumwandlung



- 4.9. Praktische Anwendung von *Transfer Learning*
 - 4.9.1. *Transfer Learning Training*
 - 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. 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 Modellen und Trainingsalgorithmen
 - 5.3.1. Eigene Modelle mit TensorFlow erstellen
 - 5.3.2. Verwaltung von Trainingsparametern
 - 5.3.3. Verwendung von Optimierungstechniken für das Training
- 5.4. TensorFlow-Funktionen und Graphiken
 - 5.4.1. Funktionen mit TensorFlow
 - 5.4.2. Verwendung von Graphen 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-API für die Vorverarbeitung
 - 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-*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. Modelltraining mit TensorFlow
 - 5.10.3. Verwendung der Anwendung für die Vorhersage von Ergebnissen

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. Faltungsschichten
 - 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 vortrainierten Keras-Modellen
 - 6.6.1. Merkmale der vortrainierten Modelle
 - 6.6.2. Verwendung von vortrainierten Modellen
 - 6.6.3. Vorteile von vortrainierten Modellen
- 6.7. Vortrainierte 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. Klassifizierung von Bildern
 - 6.8.2. Objekte in Bildern lokalisieren
 - 6.8.3. Objekterkennung
- 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 mit RNN und CNN

- 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 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 RNN
 - 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 die Sicht
 - 8.6.3. Vorteile von *Transformer*-Modellen
- 8.7. *Transformers* für die Sicht
 - 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 *Transformers*-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. *Convolutional Neural Networks* 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. 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. Implementierung 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




Studieren Sie bequem von zu Hause aus und aktualisieren Sie Ihr Wissen online mit TECH, der größten digitalen Universität der Welt

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 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 präzisesten und aktuellsten Fortbildung 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**



tech global university

Hr./Fr. _____ mit der Ausweis-Nr. _____ hat erfolgreich bestanden
und den folgenden Abschluss erworben:

Weiterbildender Masterstudiengang in Deep Learning

Es handelt sich um einen eigenen Abschluss mit einer Dauer von 1.800 Stunden, was 60 ECTS entspricht, mit Anfangsdatum am dd/mm/aaaa und Enddatum am dd/mm/aaaa.

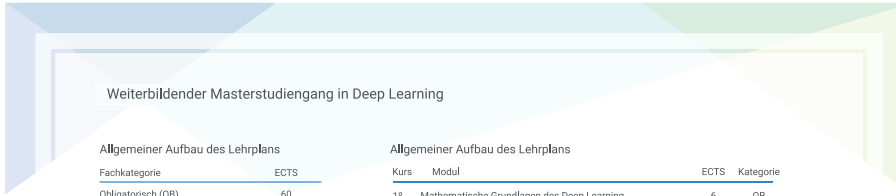
TECH Global University ist eine von der Regierung Andorras am 31. Januar 2024 offiziell anerkannte Universität, die dem Europäischen Hochschulraum (EHR) angehört.

Andorra la Vella, den 28. Februar 2024




Dr. Pedro Navarro Illana
Rektor

einzigartiger Code: TECH: AFWOR235 techinstitute.com/itel




Weiterbildender Masterstudiengang in Deep Learning

Allgemeiner Aufbau des Lehrplans		Allgemeiner Aufbau des Lehrplans			
Fachkategorie	ECTS	Kurs	Modul	ECTS	Kategorie
Obligatorisch (OB)	60	1º	Mathematische Grundlagen des Deep Learning	6	OB
Wahlfach(OP)	0	1º	Grundsätze des Deep Learning	6	OB
Externes Praktikum (PR)	0	1º	Neuronale Netze, die Grundlage von Deep Learning	6	OB
Masterarbeit (TFM)	0	1º	Training Tiefer Neuronaler Netze	6	OB
	Summe 60	1º	Anpassung von Modellen und Trainings mit TensorFlow	6	OB
		1º	Deep Computer Vision mit Convolutional Neural Networks	6	OB
		1º	Verarbeitung von Sequenzen mit RNN und CNN	6	OB
		1º	Natürliche Sprachverarbeitung (NLP) mit RNN und Aufmerksamkei	6	OB
		1º	Autoencoder, GANs und Diffusionsmodelle	6	OB
		1º	Reinforcement Learning	6	OB



Dr. Pedro Navarro Illana
Rektor



*Haager Apostille. Für den Fall, dass der Student die Haager Apostille für sein Papierdiplom beantragt, wird TECH Global University 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 institut
virtuelles Klassenzimmer



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