

Privater Masterstudiengang Künstliche Intelligenz



Privater Masterstudiengang Künstliche Intelligenz

- » Modalität: online
- » Dauer: 12 Monate
- » Qualifizierung: TECH Technische Universität
- » Zeitplan: in Ihrem eigenen Tempo
- » Prüfungen: online

Internetzugang: www.techtitude.com/de/kunstliche-intelligenz/masterstudiengang/masterstudiengang-kunstliche-intelligenz

Index

01

Präsentation

Seite 4

02

Ziele

Seite 8

03

Kompetenzen

Seite 16

04

Kursleitung

Seite 20

05

Struktur und Inhalt

Seite 24

06

Studienmethodik

Seite 38

07

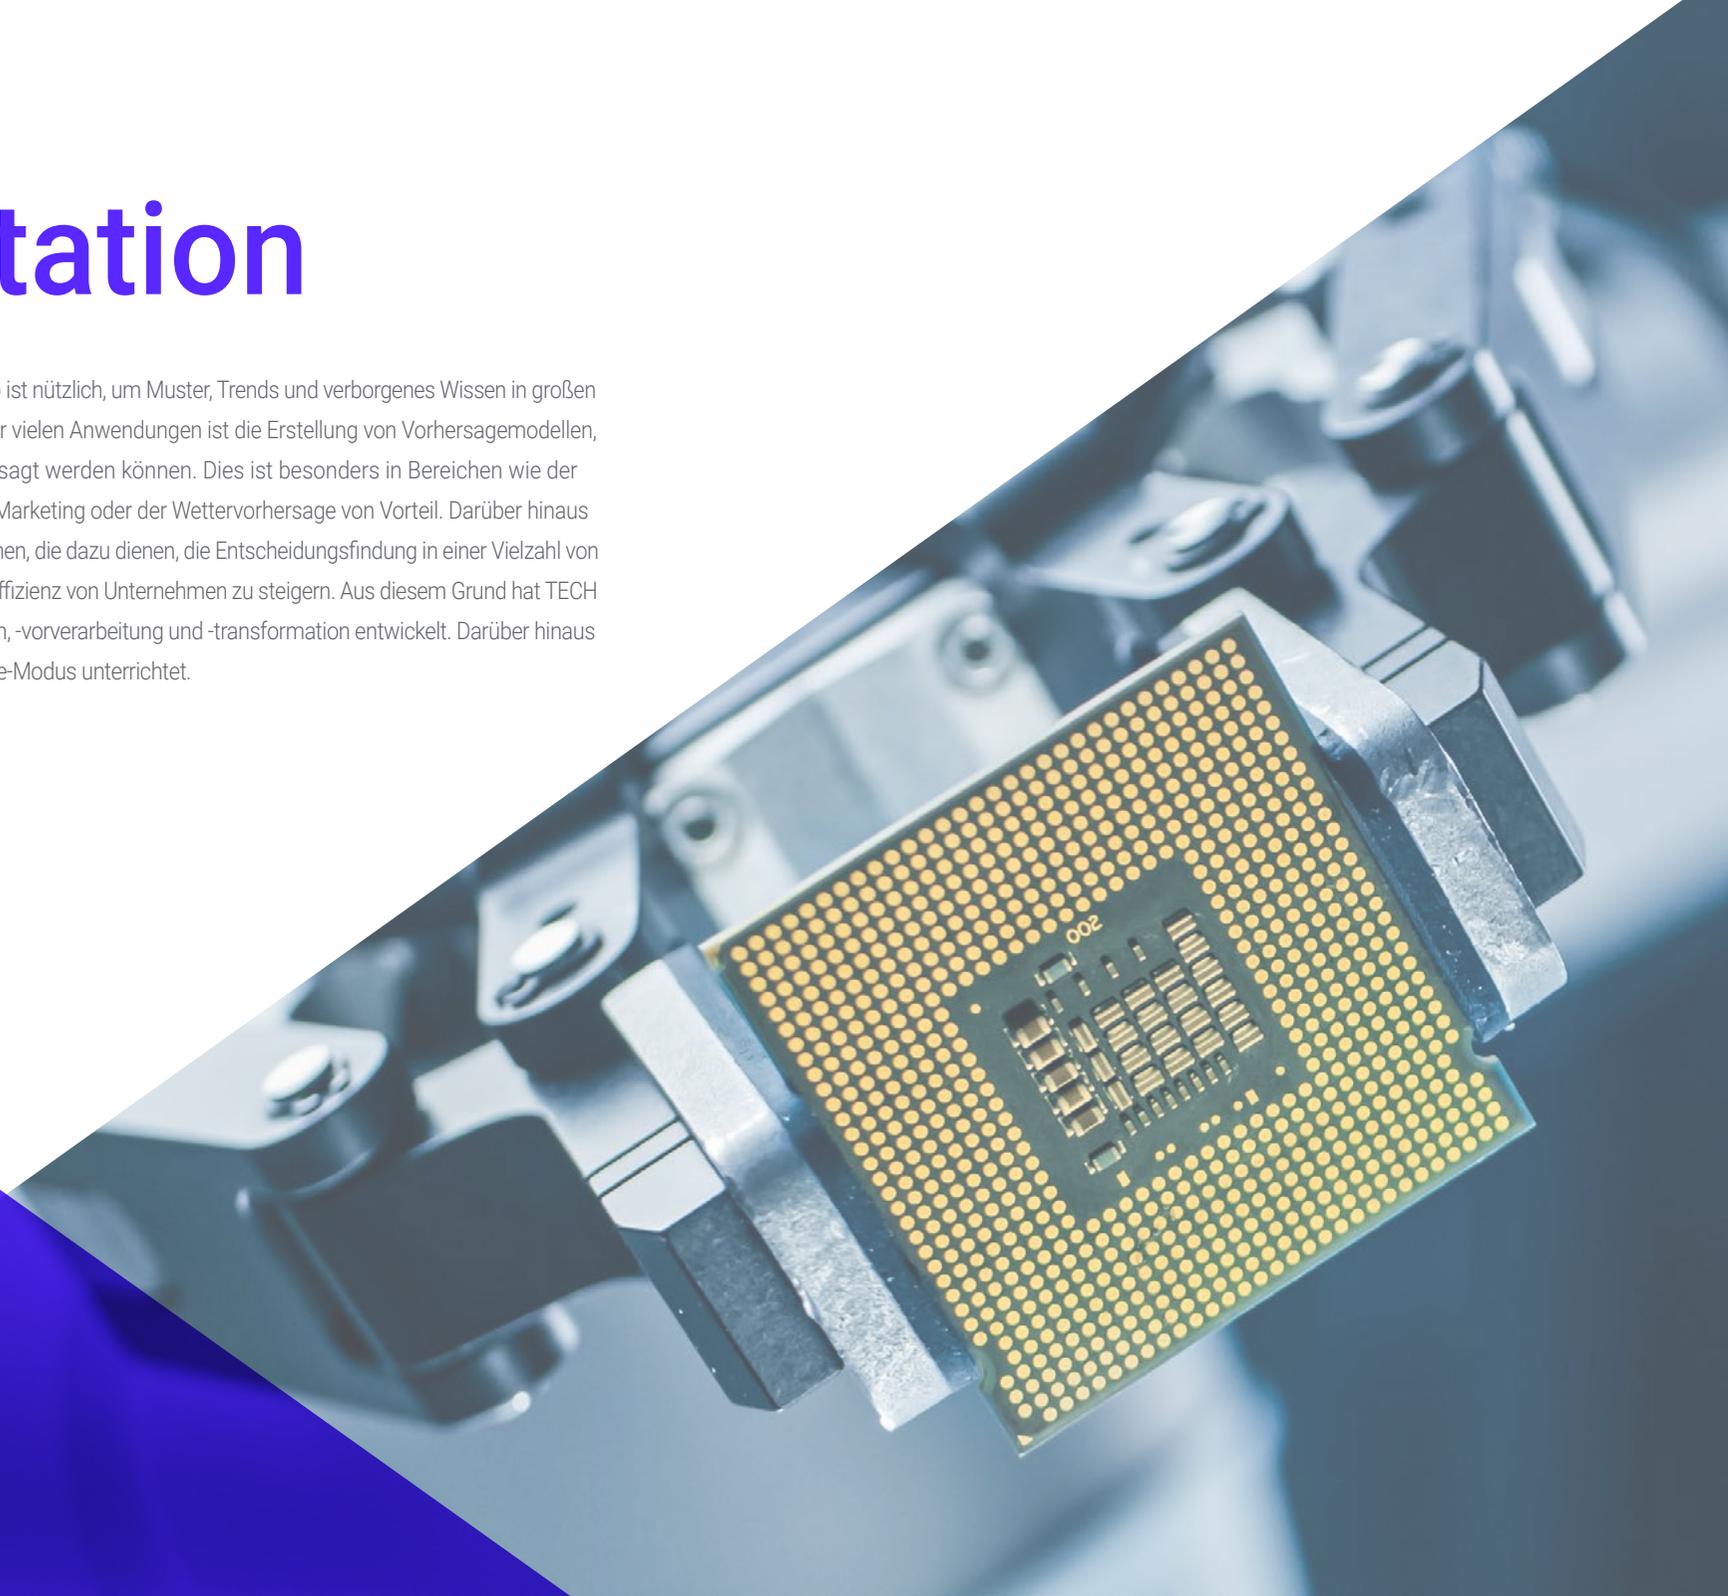
Qualifizierung

Seite 46

01

Präsentation

Data Mining in der künstlichen Intelligenz (KI) ist nützlich, um Muster, Trends und verborgenes Wissen in großen Informationsmengen zu entdecken. Eine der vielen Anwendungen ist die Erstellung von Vorhersagemodellen, mit denen zukünftige Ereignisse vorhergesagt werden können. Dies ist besonders in Bereichen wie der Produktnachfrage, der Konversionsrate im Marketing oder der Wettervorhersage von Vorteil. Darüber hinaus liefert dieses Verfahren wertvolle Informationen, die dazu dienen, die Entscheidungsfindung in einer Vielzahl von Geschäftskontexten zu optimieren und die Effizienz von Unternehmen zu steigern. Aus diesem Grund hat TECH einen Hochschulabschluss in Datenselektion, -vorverarbeitung und -transformation entwickelt. Darüber hinaus wird es in einem bequemen 100%igen Online-Modus unterrichtet.



“

*Dank dieses intensiven Studiengangs von TECH,
der laut Forbes besten digitalen Universität der Welt,
können Sie das Potenzial von Data Warehousing
optimal nutzen"*

Das maschinelle Lernen wächst ständig und wird in verschiedenen Branchen nachgefragt, was zu einer hohen Nachfrage nach in diesem Bereich fortgebildeten Fachleuten führt. Um diese Chancen zu nutzen, müssen sich Spezialisten Wettbewerbsvorteile verschaffen, die sie von anderen Bewerbern abheben. Der beste Weg, sich von der Masse abzuheben, besteht darin, dass die Fachleute über ein solides Verständnis der Materie verfügen und über alle Entwicklungen in diesem Bereich auf dem Laufenden sind. Dementsprechend ist es wichtig, dass sie sich fortgeschrittene Fähigkeiten aneignen, die sie in die Lage versetzen, mit KI-Tools effektiv umzugehen. Nur so können sie sich die Türen zu einer Vielzahl von Beschäftigungsmöglichkeiten in Bereichen wie Technologie, Gesundheitswesen oder Automobilbau öffnen.

Um sie bei dieser Aufgabe zu unterstützen, hat TECH ein Programm entwickelt, das sich mit den wesentlichen Grundlagen der KI befasst. Der Lehrplan, der von Experten auf diesem Gebiet entwickelt wurde, befasst sich mit der Integration von *Cognitive Computing* in massentaugliche Anwendungen. Auf diese Weise werden die Studenten verstehen, wie diese Plattformen dazu dienen, sowohl die Benutzererfahrung als auch die betriebliche Effizienz zu optimieren. Darüber hinaus wird das Training von tiefen neuronalen Netzen unter Anwendung von Techniken zur Gradientenoptimierung und Gewichtsinitialisierung im Detail behandelt. Außerdem werden die Studenten *Autoencoder*, *GANs* und Diffusionsmodelle beherrschen, um eine effiziente Datendarstellung zu ermöglichen.

Dieser Universitätsabschluss basiert auf einer 100%igen Online-Methode, bei der die Studenten nur ein mit dem Internet verbundenes Gerät (z. B. ein Mobiltelefon, ein Tablet oder einen Computer) benötigen, um auf den virtuellen Campus zuzugreifen und die dynamischsten Lehrressourcen auf dem akademischen Markt zu nutzen. Hinzu kommt die innovative Relearning-Methode, die es den Studenten ermöglicht, sich das Wissen auf natürliche Weise anzueignen, verstärkt durch audiovisuelle Ressourcen, um sicherzustellen, dass es im Gedächtnis und über die Zeit erhalten bleibt.

Dieser **Privater Masterstudiengang in Künstliche Intelligenz** enthält das vollständigste und aktuellste Programm auf dem Markt. Die hervorstechendsten Merkmale sind:

- Die Entwicklung von Fallstudien, die von Experten in künstlicher Intelligenz präsentiert werden
- Der anschauliche, schematische und äußerst praxisnahe Inhalt vermittelt alle für die berufliche Praxis unverzichtbaren Informationen
- Praktische Übungen, bei denen der Selbstbewertungsprozess zur Verbesserung des Lernens genutzt werden kann
- Sein besonderer Schwerpunkt liegt auf innovativen Methoden
- Theoretische Lektionen, 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



Wenden Sie die B-Cube-Methode auf Ihre Verfahren an und bewerten Sie effektiv die Qualität der Klassifizierung bei Multi-Label-Problemen“

“

Sie werden Ihre Ziele dank der Lehrmittel von TECH erreichen, darunter erklärende Videos und interaktive Zusammenfassungen"

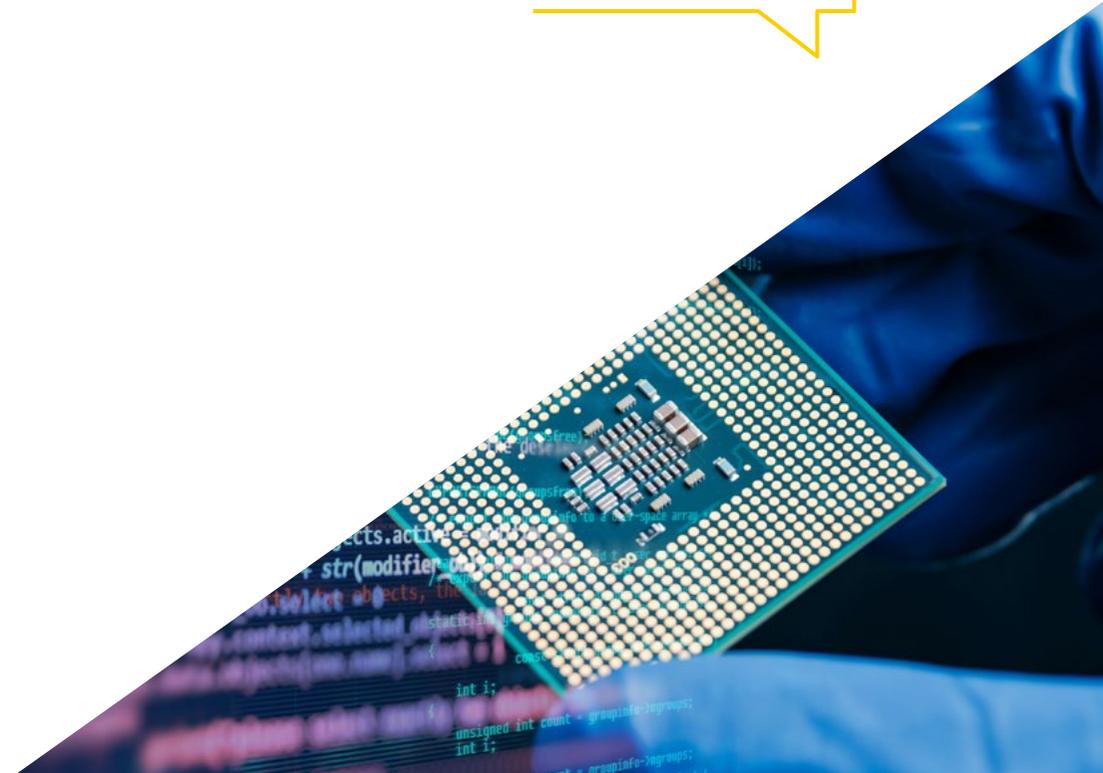
Zu den Dozenten des Programms gehören Fachleute aus der Branche, die ihre Erfahrungen in diese Fortbildung einbringen, sowie anerkannte Spezialisten von führenden Gesellschaften und renommierten Universitäten.

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 die Vorverarbeitung von Daten mit TensorFlow durchführen, um die Qualität und Leistung der endgültigen Modelle zu verbessern.

Die Relearning-Methode, die in diesem Universitätsabschluss verwendet wird, ermöglicht es Ihnen, auf eine autonome und progressive Weise zu lernen.



02 Ziele

Im Rahmen dieses Programms erwerben die Studenten mehrere Kompetenzen, die sie in die Lage versetzen, Systeme des maschinellen Lernens effektiv zu entwickeln und zu implementieren. Auf diese Weise werden die Studenten die verschiedenen KI-Algorithmen beherrschen, um wertvolle Informationen zur Verbesserung der Entscheidungsfindung zu gewinnen. Gleichzeitig werden die Studenten in der Lage sein, KI in einer Vielzahl von Sektoren anzuwenden, darunter im Gesundheitswesen, in der öffentlichen Verwaltung und im Personalwesen. Den Experten steht ein breites Spektrum an Ressourcen zur Verfügung, um innovative Vorschläge zu unterbreiten, mit denen sie sich in einem sich ständig erweiternden Bereich hervorheben können.



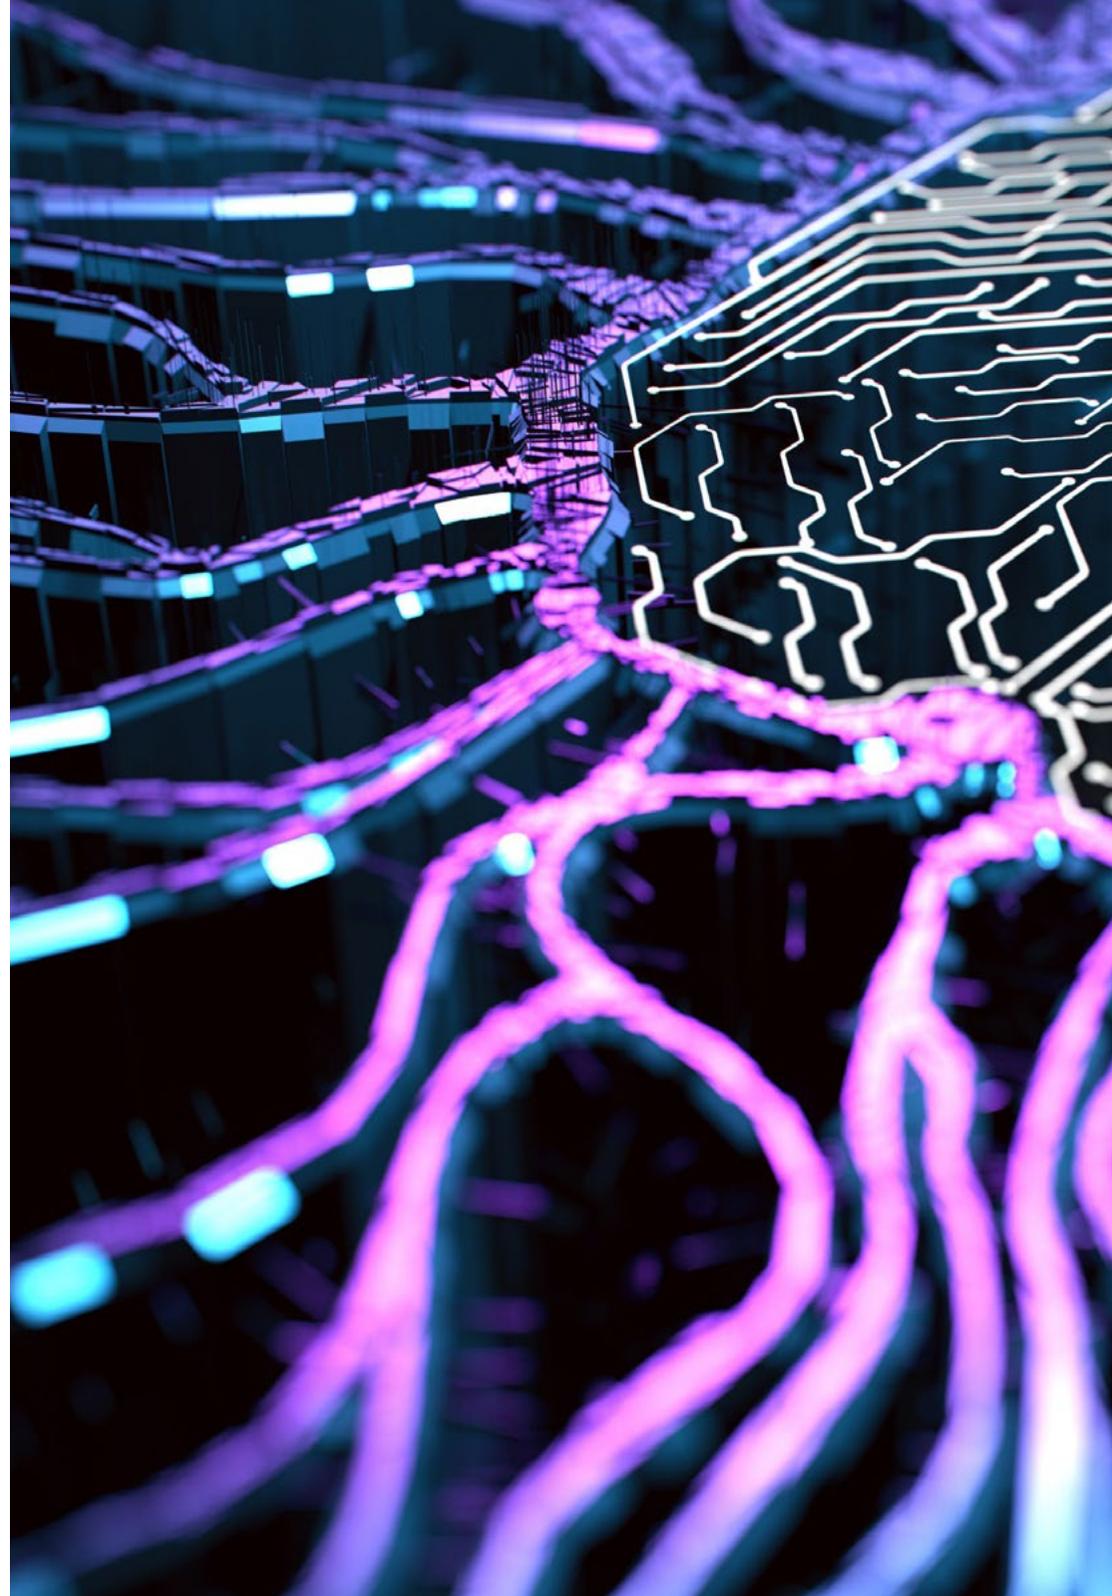
“

Der private Masterstudiengang ermöglicht es Ihnen, in simulierten Umgebungen zu üben, die Ihnen ein immersives Lernprogramm bieten, um Sie in realen Situationen zu trainieren“



Allgemeine Ziele

- ♦ Verstehen der theoretischen Grundlagen der künstlichen Intelligenz
- ♦ Studieren der verschiedenen Arten von Daten und Verstehen des Lebenszyklus von Daten
- ♦ Bewerten der entscheidenden Rolle von Daten bei der Entwicklung und Implementierung von KI-Lösungen
- ♦ Vertiefen des Verständnisses von Algorithmen und Komplexität zur Lösung spezifischer Probleme
- ♦ Erforschen der theoretischen Grundlagen von neuronalen Netzen für die Entwicklung von *Deep Learning*
- ♦ Erforschen des bio-inspirierten Computings und seiner Bedeutung für die Entwicklung intelligenter Systeme





Spezifische Ziele

Modul 1. Grundlagen der künstlichen Intelligenz

- ♦ Analysieren der historischen Entwicklung der künstlichen Intelligenz, von ihren Anfängen bis zu ihrem heutigen Stand, Identifizierung der wichtigsten Meilensteine und Entwicklungen
- ♦ Verstehen der Funktionsweise von neuronalen Netzen und ihrer Anwendung in Lernmodellen der Künstlichen Intelligenz
- ♦ Untersuchen der Prinzipien und Anwendungen von genetischen Algorithmen und analysieren ihren Nutzen bei der Lösung komplexer Probleme
- ♦ Analysieren der Bedeutung von Thesauri, Vokabularen und Taxonomien bei der Strukturierung und Verarbeitung von Daten für KI-Systeme

Modul 2. Datentypen und Datenlebenszyklus

- ♦ Verstehen der grundlegenden Konzepte der Statistik und ihrer Anwendung in der Datenanalyse
- ♦ Identifizieren und Klassifizieren der verschiedenen Arten von statistischen Daten, von quantitativen bis zu qualitativen Daten
- ♦ Analysieren des Lebenszyklus von Daten, von der Erzeugung bis zur Entsorgung, und Identifizieren der wichtigsten Phasen
- ♦ Erkunden der ersten Phasen des Lebenszyklus von Daten, wobei die Bedeutung der Datenplanung und der Datenstruktur hervorgehoben wird
- ♦ Untersuchen der Prozesse der Datenerfassung, einschließlich Methodik, Tools und Erfassungskanäle
- ♦ Untersuchen des *Datawarehouse*-Konzepts mit Schwerpunkt auf den Elementen des Datawarehouse und seinem Design

Modul 3. Daten in der künstlichen Intelligenz

- ♦ Beherrschen der Grundlagen der Datenwissenschaft, einschließlich der Werkzeuge, Typen und Quellen für die Informationsanalyse
- ♦ Erforschen des Prozesses der Umwandlung von Daten in Informationen mithilfe von *Data Mining* und Datenvisualisierungstechniken
- ♦ Studieren der Struktur und der Eigenschaften von *Datasets* und verstehen ihre Bedeutung für die Aufbereitung und Nutzung von Daten für KI-Modelle
- ♦ Verwenden spezifischer Tools und bewährter Verfahren für die Datenverarbeitung, um Effizienz und Qualität bei der Implementierung von künstlicher Intelligenz zu gewährleisten

Modul 4. *Data Mining*. Auswahl, Vorverarbeitung und Transformation

- ♦ Beherrschen statistischer Inferenztechniken, um statistische Methoden im *Data Mining* zu verstehen und anzuwenden
- ♦ Durchführen detaillierter explorativer Analysen von Datensätzen, um relevante Muster, Anomalien und Trends zu erkennen
- ♦ Entwickeln von Fähigkeiten zur Datenaufbereitung, einschließlich Datenbereinigung, -integration und -formatierung für die Verwendung im *Data Mining*
- ♦ Implementieren effektiver Strategien für den Umgang mit fehlenden Werten in Datensätzen, indem je nach Kontext Imputations- oder Eliminierungsmethoden angewendet werden
- ♦ Identifizieren und Entschärfen von Datenrauschen, indem Sie Filter- und Glättungsverfahren anwenden, um die Qualität des Datensatzes zu verbessern
- ♦ Eingehen auf die Datenvorverarbeitung in *Big-Data*-Umgebungen

Modul 5. Algorithmik und Komplexität in der künstlichen Intelligenz

- ♦ Einführen von Algorithmenentwurfsstrategien, die ein solides Verständnis der grundlegenden Ansätze zur Problemlösung vermitteln
- ♦ Analysieren der Effizienz und Komplexität von Algorithmen unter Anwendung von Analysetechniken zur Bewertung der Leistung in Bezug auf Zeit und Raum
- ♦ Untersuchen und Anwenden von Sortieralgorithmen, Verstehen ihrer Leistung und Vergleichen ihrer Effizienz in verschiedenen Kontexten
- ♦ Erforschen von baumbasierten Algorithmen, Verstehen ihrer Struktur und Anwendungen
- ♦ Untersuchen von Algorithmen mit *Heaps*, Analysieren ihrer Implementierung und ihrer Nützlichkeit bei der effizienten Datenmanipulation
- ♦ Analysieren graphenbasierter Algorithmen, wobei ihre Anwendung bei der Darstellung und Lösung von Problemen mit komplexen Beziehungen untersucht wird
- ♦ Untersuchen von *Greedy*-Algorithmen, Verständnis ihrer Logik und Anwendungen bei der Lösung von Optimierungsproblemen
- ♦ Untersuchen und Anwenden der *Backtracking*-Technik für die systematische Problemlösung und Analysieren ihrer Effektivität in verschiedenen Szenarien

Modul 6. Intelligente Systeme

- ♦ Erforschen der Agententheorie, Verstehen der grundlegenden Konzepte ihrer Funktionsweise und ihrer Anwendung in der künstlichen Intelligenz und im *Software Engineering*
- ♦ Studieren der Darstellung von Wissen, einschließlich der Analyse von Ontologien und deren Anwendung bei der Organisation von strukturierten Informationen
- ♦ Analysieren des Konzepts des semantischen Webs und seiner Auswirkungen auf die Organisation und den Abruf von Informationen in digitalen Umgebungen
- ♦ Evaluieren und Vergleichen verschiedener Wissensrepräsentationen und deren Integration zur Verbesserung der Effizienz und Genauigkeit von intelligenten Systemen

Modul 7. Maschinelles Lernen und *Data Mining*

- ♦ Einführen in die Prozesse der Wissensentdeckung und in die grundlegenden Konzepte des maschinellen Lernens
- ♦ Untersuchen von Entscheidungsbäumen als überwachte Lernmodelle, Verstehen ihrer Struktur und Anwendungen
- ♦ Bewerten von Klassifikatoren anhand spezifischer Techniken, um ihre Leistung und Genauigkeit bei der Datenklassifizierung zu messen
- ♦ Studieren neuronaler Netze und Verstehen ihrer Funktionsweise und Architektur, um komplexe Probleme des maschinellen Lernens zu lösen
- ♦ Erforschen von Bayes'schen Methoden und deren Anwendung im maschinellen Lernen, einschließlich Bayes'scher Netzwerke und Bayes'scher Klassifikatoren
- ♦ Analysieren von Regressions- und kontinuierlichen Antwortmodellen zur Vorhersage von numerischen Werten aus Daten
- ♦ Untersuchen von Techniken zum *Clustering*, um Muster und Strukturen in unmarkierten Datensätzen zu erkennen
- ♦ Erforschen von *Text Mining* und natürlicher Sprachverarbeitung (NLP), um zu verstehen, wie maschinelle Lerntechniken zur Analyse und zum Verständnis von Texten eingesetzt werden

Modul 8. Neuronale Netze, die Grundlage von *Deep Learning*

- ♦ Beherrschen der Grundlagen des tiefen Lernens und Verstehen seiner wesentlichen Rolle beim *Deep Learning*
- ♦ Erkunden der grundlegenden Operationen in neuronalen Netzen und Verstehen ihrer Anwendung bei der Konstruktion von Modellen
- ♦ Analysieren der verschiedenen Schichten, die in neuronalen Netzen verwendet werden, und lernen, wie man sie richtig auswählt

- ♦ Verstehen der effektiven Verknüpfung von Schichten und Operationen, um komplexe und effiziente neuronale Netzarchitekturen zu entwerfen
- ♦ Verwenden von Trainern und Optimierern, um die Leistung von neuronalen Netzen abzustimmen und zu verbessern
- ♦ Erforschen der Verbindung zwischen biologischen und künstlichen Neuronen für ein tieferes Verständnis des Modelldesigns

Modul 9. Training Tiefer Neuronaler Netze

- ♦ Lösen von Problemen im Zusammenhang mit Gradienten beim Training von tiefen neuronalen Netzen
- ♦ Erforschen und Anwenden verschiedener Optimierer, um die Effizienz und Konvergenz von Modellen zu verbessern
- ♦ Programmieren der Lernrate zur dynamischen Anpassung der Konvergenzrate des Modells
- ♦ Verstehen und Bewältigen von *Overfitting* durch spezifische Strategien beim Training
- ♦ Anwenden praktischer Richtlinien, um ein effizientes und effektives Training von tiefen neuronalen Netzen zu gewährleisten
- ♦ Implementieren von *Transfer Learning* als fortgeschrittene Technik zur Verbesserung der Modellleistung bei bestimmten Aufgaben
- ♦ Erforschen und Anwenden von Techniken der *Data Augmentation* zur Anreicherung von Datensätzen und Verbesserung der Modellgeneralisierung
- ♦ Entwickeln praktischer Anwendungen mit *Transfer Learning* zur Lösung realer Probleme

Modul 10. Anpassung von Modellen und Training mit *TensorFlow*

- ♦ Beherrschen der Grundlagen von *TensorFlow* und seiner Integration mit NumPy für effiziente Datenverwaltung und Berechnungen
- ♦ Anpassen von Modellen und Trainingsalgorithmen mit den fortgeschrittenen Fähigkeiten von *TensorFlow*
- ♦ Erforschen der tfdata-API zur effektiven Verwaltung und Manipulation von Datensätzen
- ♦ Implementieren des Formats TFRecord, um große Datensätze in *TensorFlow* zu speichern und darauf zuzugreifen
- ♦ Verwenden von Keras-Vorverarbeitungsschichten zur Erleichterung der Konstruktion eigener Modelle
- ♦ Erforschen des *TensorFlow Datasets* Projekts, um auf vordefinierte Datensätze zuzugreifen und die Entwicklungseffizienz zu verbessern
- ♦ Entwickeln einer *Deep Learning*-Anwendung mit *TensorFlow* unter Einbeziehung der im Modul erworbenen Kenntnisse
- ♦ Anwenden aller Konzepte, die bei der Erstellung und dem Training von benutzerdefinierten Modellen mit *TensorFlow* erlernt wurden, auf praktische Art und Weise in realen Situationen

Modul 11. *Deep Computer Vision* mit *Convolutional Neural Networks*

- ♦ Verstehen der Architektur des visuellen Kortex und ihrer Bedeutung für *Deep Computer Vision*
- ♦ Erforschen und Anwenden von Faltungsschichten, um wichtige Merkmale aus Bildern zu extrahieren
- ♦ Implementieren von Clustering-Schichten und ihre Verwendung in *Deep Computer Vision*-Modellen mit Keras
- ♦ Analysieren verschiedener Architekturen von *Convolutional Neural Networks* (CNN) und deren Anwendbarkeit in verschiedenen Kontexten

- ♦ Entwickeln und Implementieren eines CNN ResNet unter Verwendung der Keras-Bibliothek, um die Effizienz und Leistung des Modells zu verbessern
- ♦ Verwenden von vorab trainierten Keras-Modellen, um das Transfer-Lernen für bestimmte Aufgaben zu nutzen
- ♦ Anwenden von Klassifizierungs- und Lokalisierungstechniken in *Deep Computer Vision*-Umgebungen
- ♦ Erforschen von Strategien zur Objekterkennung und -verfolgung mit *Convolutional Neural Networks*

Modul 12. Natürliche Sprachverarbeitung (NLP) mit rekurrenten neuronalen Netzen (RNN) und Aufmerksamkeit

- ♦ Entwickeln von Fähigkeiten zur Texterstellung mit rekurrenten neuronalen Netzen (RNN)
- ♦ Anwenden von RNNs bei der Meinungsklassifizierung zur Stimmungsanalyse in Texten
- ♦ Verstehen und Anwenden von Aufmerksamkeitsmechanismen in Modellen zur Verarbeitung natürlicher Sprache
- ♦ Analysieren und Verwenden von *Transformers*-Modellen in spezifischen NLP-Aufgaben
- ♦ Erkunden der Anwendung von *Transformers*-Modellen im Kontext von Bildverarbeitung und Computer Vision
- ♦ Vertraut sein mit der *Hugging Face Transformers*-Bibliothek für die effiziente Implementierung fortgeschrittener Modelle
- ♦ Vergleichen der verschiedenen *Transformers*-Bibliotheken, um ihre Eignung für bestimmte Aufgaben zu bewerten
- ♦ Entwickeln einer praktischen Anwendung von NLP, die RNN- und Aufmerksamkeitsmechanismen integriert, um reale Probleme zu lösen

Modul 13. Autoencoder, GANs und Diffusionsmodelle

- Entwickeln effizienter Datenrepräsentationen mit *Autoencodern*, *GANs* und Diffusionsmodellen
- Durchführen einer PCA unter Verwendung eines unvollständigen linearen *Autoencoders* zur Optimierung der Datendarstellung
- Implementieren und Verstehen der Funktionsweise von gestapelten *Autoencodern*
- Erforschen und Anwenden von *Convolutional Autoencoders* für effiziente visuelle Datendarstellungen
- Analysieren und Anwenden der Effektivität von *Sparse Autoencodern* bei der Datendarstellung
- Generieren von Modebildern aus dem MNIST-Datensatz mit Hilfe von *Autoencoders*
- Verstehen des Konzepts der *Generative Adversarial Networks* (GANs) und Diffusionsmodelle
- Implementieren und Vergleichen der Leistung von Diffusionsmodellen und *GANs* bei der Datengenerierung

Modul 14. Bio-inspiriertes Computing

- Einführen in die grundlegenden Konzepte des bio-inspirierten Computings
- Analysieren von Strategien zur Erforschung und Ausnutzung des Raums in genetischen Algorithmen
- Untersuchen von Modellen des evolutionären Rechnens im Kontext der Optimierung
- Fortsetzen der detaillierten Analyse von Modellen des evolutionären Rechnens
- Anwenden der evolutionären Programmierung auf spezifische Lernprobleme
- Bewältigen der Komplexität von Multi-Objektiv-Problemen im Rahmen des bio-inspirierten Computings
- Erforschen der Anwendung von neuronalen Netzen im Bereich des bio-inspirierten Computings
- Vertiefen der Implementierung und des Nutzens von neuronalen Netzen im Bereich des bio-inspirierten Computings

Modul 15. Künstliche Intelligenz: Strategien und Anwendungen

- Entwickeln von Strategien für die Implementierung von künstlicher Intelligenz in Finanzdienstleistungen
- Identifizieren und Bewerten der Risiken im Zusammenhang mit dem Einsatz von KI im Gesundheitssektor
- Bewerten der potenziellen Risiken im Zusammenhang mit dem Einsatz von KI in der Industrie
- Anwenden von Techniken der künstlichen Intelligenz in der Industrie zur Verbesserung der Produktivität
- Entwerfen von Lösungen der künstlichen Intelligenz zur Optimierung von Prozessen in der öffentlichen Verwaltung
- Bewerten des Einsatzes von KI-Technologien im Bildungssektor
- Anwenden von Techniken der künstlichen Intelligenz in der Forst- und Landwirtschaft zur Verbesserung der Produktivität
- Optimieren von Personalprozessen durch den strategischen Einsatz von künstlicher Intelligenz



Ein Prozess der beruflichen Entwicklung, der es Ihnen ermöglicht, die Fähigkeiten eines Experten zu erwerben und sich mit den Besten der Branche zu messen"

03

Kompetenzen

Dank dieses Studiengangs erwerben die Studenten solide Fähigkeiten, die sie in die Lage versetzen, Werkzeuge des maschinellen Lernens und deren Anwendung im *Data Mining* zu beherrschen, um die Entscheidungsfindung zu optimieren. Sie werden auch in der Lage sein, *Autoencoder*, *GANs* und Diffusionsmodelle effektiv zu entwickeln. Die Studenten werden hervorragend qualifiziert sein, um innovative Vorschläge zu unterbreiten und gleichzeitig die Herausforderungen zu meistern, mit denen sie im Laufe ihrer Arbeit konfrontiert werden. Fachleute werden von den zahlreichen Möglichkeiten profitieren, die eine Branche bietet, die sich sprunghaft weiterentwickelt.



“

Sie werden fortgeschrittene Data-Mining-Fähigkeiten erwerben, um wertvolle Muster und Trends in komplexen Datenbeständen aufzudecken"



Allgemeine Kompetenzen

- Beherrschen von *Data-Mining*-Techniken, einschließlich Auswahl, Vorverarbeitung und Transformation komplexer Daten
- Entwerfen und Entwickeln intelligenter Systeme, die in der Lage sind, zu lernen und sich an veränderte Umgebungen anzupassen
- Beherrschen von Tools für maschinelles Lernen und deren Anwendung im *Data Mining* zur Entscheidungsfindung
- Verwenden von *Autoencoders*, *GANs* und Diffusionsmodellen zur Lösung spezifischer KI-Herausforderungen
- Implementieren eines Encoder-Decoder-Netzwerks für neuronale maschinelle Übersetzung
- Anwenden der grundlegenden Prinzipien neuronaler Netze zur Lösung spezifischer Probleme



Sie werden eine virtuelle Bibliothek voller multimedialer Ressourcen in verschiedenen audiovisuellen Formaten nutzen können, um Ihre Kenntnisse zu vertiefen“





Spezifische Kompetenzen

- ◆ Anwenden von KI-Techniken und -Strategien zur Verbesserung der Effizienz im Retail
- ◆ Vertiefen des Verständnisses und der Anwendung von genetischen Algorithmen
- ◆ Anwenden von Entrauschungstechniken unter Verwendung von automatischen Kodierern
- ◆ Effektives Erstellen von Trainingsdatensätzen für Aufgaben der natürlichen Sprachverarbeitung (NLP)
- ◆ Ausführen von *Clustering*-Schichten und deren Verwendung in *Deep Computer Vision*-Modellen mit Keras
- ◆ Verwenden von *TensorFlow*-Funktionen und Graphen, um die Leistung von benutzerdefinierten Modellen zu optimieren
- ◆ Optimieren der Entwicklung und Anwendung von *Chatbots* und virtuellen Assistenten, indem man versteht, wie sie funktionieren und welche Anwendungsmöglichkeiten sie bieten
- ◆ Beherrschen der Wiederverwendung von vortrainierten Schichten, um den Trainingsprozess zu optimieren und zu beschleunigen
- ◆ Erstellen eines ersten neuronalen Netzes, indem die erlernten Konzepte in der Praxis angewendet werden
- ◆ Aktivieren eines mehrschichtigen Perzeptrons (MLP) mit der Keras-Bibliothek
- ◆ Anwenden von Datenexplorations- und Vorverarbeitungstechniken zur Identifizierung und Vorbereitung von Daten für die effektive Verwendung in maschinellen Lernmodellen
- ◆ Implementieren effektiver Strategien für den Umgang mit fehlenden Werten in Datensätzen, indem je nach Kontext Imputations- oder Eliminierungsmethoden angewendet werden
- ◆ Untersuchen von Sprachen und Software für die Erstellung von Ontologien unter Verwendung spezifischer Tools für die Entwicklung semantischer Modelle
- ◆ Entwickeln von Techniken zur Datenbereinigung, um die Qualität und Genauigkeit der in der nachfolgenden Analyse verwendeten Informationen zu gewährleisten

04

Kursleitung

Um allen die beste Weiterbildung zu bieten, zeichnet sich TECH dadurch aus, dass sie über eine umfangreiche Gruppe von renommierten Experten für künstliche Intelligenz verfügt, die ein aktuelles und funktionales Lernen gewährleisten, das diesen Hochschulabschluss ausmacht. Diese Fachleute, die für die Leitung dieses Programms verantwortlich sind, verfügen über anerkannte Erfahrungen in diesem Bereich, in dem sie Institutionen von internationalem Prestige innovative Lösungen vorgeschlagen haben. All dies ist eine Garantie für Studenten, die eine fortgeschrittene Fortbildung von den Besten erhalten möchten.



“

Lernen Sie mit den Besten! Die Vielfalt der Talente und Kenntnisse des Lehrpersonals wird ein dynamisches Lernumfeld schaffen"

Leitung



Dr. Peralta Martín-Palomino, Arturo

- ♦ CEO und CTO bei Prometheus Global Solutions
- ♦ CTO bei Korporate Technologies
- ♦ CTO bei AI Shepherds GmbH
- ♦ Berater und strategischer Unternehmensberater bei Alliance Medical
- ♦ Direktor für Design und Entwicklung bei DocPath
- ♦ Promotion in Computertechnik an der Universität von Castilla La Mancha
- ♦ Promotion in Wirtschaftswissenschaften, Unternehmen und Finanzen an der Universität Camilo José Cela
- ♦ Promotion in Psychologie an der Universität von Castilla La Mancha
- ♦ Masterstudiengang Executive MBA von der Universität Isabel I
- ♦ Masterstudiengang in Business und Marketing Management von der Universität Isabel I
- ♦ Masterstudiengang in Big Data bei Formación Hadoop
- ♦ Masterstudiengang in Fortgeschrittene Informationstechnologie von der Universität von Castilla La Mancha
- ♦ Mitglied von: Forschungsgruppe SMILE



05

Struktur und Inhalt

Dieses Programm vermittelt den Studenten ein solides Verständnis des maschinellen Lernens. Der von Experten auf diesem Gebiet konzipierte Lehrplan befasst sich sowohl mit der Entwicklung von Algorithmen als auch mit Modellen, die es Maschinen ermöglichen, sich auf Muster zu konzentrieren und Aufgaben auszuführen, ohne speziell dafür programmiert zu sein. Der Lehrplan befasst sich auch mit neuronalen Netzen, da diese für das Training von Modellen für Aufgaben wie die Verarbeitung natürlicher Sprache wichtig sind. Andererseits werden im Rahmen der Fortbildung fortgeschrittene Strategien zur Erkundung und Ausnutzung des Raums für genetische Algorithmen vermittelt.



“

Sie werden sich mit Graphenalgorithmien befassen, um eine Vielzahl von Problemen zu lösen, die Beziehungen und Verbindungen zwischen Elementen beinhalten“

Modul 1. Grundlagen der künstlichen Intelligenz

- 1.1. Geschichte der künstlichen Intelligenz
 - 1.1.1. Ab wann spricht man von künstlicher Intelligenz?
 - 1.1.2. Referenzen im Kino
 - 1.1.3. Bedeutung der künstlichen Intelligenz
 - 1.1.4. Technologien, die künstliche Intelligenz ermöglichen und unterstützen
- 1.2. Künstliche Intelligenz in Spielen
 - 1.2.1. Spieltheorie
 - 1.2.2. *Minimax* und Alpha-Beta-Beschneidung
 - 1.2.3. Simulation: Monte Carlo
- 1.3. Neuronale Netzwerke
 - 1.3.1. Biologische Grundlagen
 - 1.3.2. Berechnungsmodell
 - 1.3.3. Überwachte und nicht überwachte neuronale Netzwerke
 - 1.3.4. Einfaches Perzeptron
 - 1.3.5. Mehrschichtiges Perzeptron
- 1.4. Genetische Algorithmen
 - 1.4.1. Geschichte
 - 1.4.2. Biologische Grundlage
 - 1.4.3. Problem-Kodierung
 - 1.4.4. Erzeugung der Ausgangspopulation
 - 1.4.5. Hauptalgorithmus und genetische Operatoren
 - 1.4.6. Bewertung von Personen: Fitness
- 1.5. Thesauri, Vokabularien, Taxonomien
 - 1.5.1. Wortschatz
 - 1.5.2. Taxonomie
 - 1.5.3. Thesauri
 - 1.5.4. Ontologien
 - 1.5.5. Wissensrepräsentation: Semantisches Web



- 1.6. Semantisches Web
 - 1.6.1. Spezifizierungen: RDF, RDFS und OWL
 - 1.6.2. Schlussfolgerung/Begründung
 - 1.6.3. *Linked Data*
- 1.7. Expertensysteme und DSS
 - 1.7.1. Expertensysteme
 - 1.7.2. Systeme zur Entscheidungshilfe
- 1.8. *Chatbots* und virtuelle Assistenten
 - 1.8.1. Arten von Assistenten: sprach- und textbasierte Assistenten
 - 1.8.2. Grundlegende Bestandteile für die Entwicklung eines Assistenten: *Intents*, Entitäten und Dialogablauf
 - 1.8.3. Integrationen: Web, *Slack*, Whatsapp, Facebook
 - 1.8.4. Tools für die Entwicklung von Assistenten: *Dialog Flow*, *Watson Assistant*
- 1.9. KI-Implementierungsstrategie
- 1.10. Die Zukunft der künstlichen Intelligenz
 - 1.10.1. Wir wissen, wie man mit Algorithmen Emotionen erkennt
 - 1.10.2. Eine Persönlichkeit schaffen: Sprache, Ausdrücke und Inhalt
 - 1.10.3. Tendenzen der künstlichen Intelligenz
 - 1.10.4. Reflexionen

Modul 2. Datentypen und Datenlebenszyklus

- 2.1. Die Statistik
 - 2.1.1. Statistik: Deskriptive Statistik, statistische Schlussfolgerungen
 - 2.1.2. Population, Stichprobe, Individuum
 - 2.1.3. Variablen: Definition und Mess-Skalen
- 2.2. Arten von statistischen Daten
 - 2.2.1. Je nach Typ
 - 2.2.1.1. Quantitativ: kontinuierliche Daten und diskrete Daten
 - 2.2.1.2. Qualitativ: Binomialdaten, nominale Daten und ordinale Daten
 - 2.2.2. Je nach Form
 - 2.2.2.1. Numerisch
 - 2.2.2.2. Text
 - 2.2.2.3. Logisch

- 2.2.3. Je nach Quelle
 - 2.2.3.1. Primär
 - 2.2.3.2. Sekundär
- 2.3. Lebenszyklus der Daten
 - 2.3.1. Etappen des Zyklus
 - 2.3.2. Meilensteine des Zyklus
 - 2.3.3. FAIR-Prinzipien
- 2.4. Die ersten Phasen des Zyklus
 - 2.4.1. Definition von Zielen
 - 2.4.2. Ermittlung des Ressourcenbedarfs
 - 2.4.3. Gantt-Diagramm
 - 2.4.4. Struktur der Daten
- 2.5. Datenerhebung
 - 2.5.1. Methodik der Erhebung
 - 2.5.2. Erhebungsinstrumente
 - 2.5.3. Kanäle für die Erhebung
- 2.6. Datenbereinigung
 - 2.6.1. Phasen der Datenbereinigung
 - 2.6.2. Qualität der Daten
 - 2.6.3. Datenmanipulation (mit R)
- 2.7. Datenanalyse, Interpretation und Bewertung der Ergebnisse
 - 2.7.1. Statistische Maßnahmen
 - 2.7.2. Beziehungsindizes
 - 2.7.3. *Data Mining*
- 2.8. Datenlager (*Datawarehouse*)
 - 2.8.1. Elemente, aus denen sie bestehen
 - 2.8.2. Design
 - 2.8.3. Zu berücksichtigende Aspekte
- 2.9. Verfügbarkeit von Daten
 - 2.9.1. Zugang
 - 2.9.2. Nützlichkeit
 - 2.9.3. Sicherheit

- 2.10. Regulatorische Aspekte
 - 2.10.1. Datenschutzgesetz
 - 2.10.2. Bewährte Verfahren
 - 2.10.3. Andere regulatorische Aspekte

Modul 3. Daten in der künstlichen Intelligenz

- 3.1. Datenwissenschaft
 - 3.1.1. Datenwissenschaft
 - 3.1.2. Fortgeschrittene Tools für den Datenwissenschaftler
- 3.2. Daten, Informationen und Wissen
 - 3.2.1. Daten, Informationen und Wissen
 - 3.2.2. Datentypen
 - 3.2.3. Datenquellen
- 3.3. Von Daten zu Informationen
 - 3.3.1. Datenanalyse
 - 3.3.2. Arten der Analyse
 - 3.3.3. Extraktion von Informationen aus einem *Dataset*
- 3.4. Extraktion von Informationen durch Visualisierung
 - 3.4.1. Visualisierung als Analyseinstrument
 - 3.4.2. Visualisierungsmethoden
 - 3.4.3. Visualisierung eines Datensatzes
- 3.5. Qualität der Daten
 - 3.5.1. Datenqualität
 - 3.5.2. Datenbereinigung
 - 3.5.3. Grundlegende Datenvorverarbeitung
- 3.6. *Dataset*
 - 3.6.1. *Dataset*-Anreicherung
 - 3.6.2. Der Fluch der Dimensionalität
 - 3.6.3. Ändern unseres Datensatzes

- 3.7. Ungleichgewicht
 - 3.7.1. Ungleichgewicht der Klassen
 - 3.7.2. Techniken zur Begrenzung von Ungleichgewichten
 - 3.7.3. *Dataset*-Abgleich
- 3.8. Unüberwachte Modelle
 - 3.8.1. Unüberwachtes Modell
 - 3.8.2. Methoden
 - 3.8.3. Klassifizierung mit unüberwachten Modellen
- 3.9. Überwachte Modelle
 - 3.9.1. Überwachtes Modell
 - 3.9.2. Methoden
 - 3.9.3. Klassifizierung mit überwachten Modellen
- 3.10. Tools und bewährte Verfahren
 - 3.10.1. Bewährte Praktiken für einen Datenwissenschaftler
 - 3.10.2. Das beste Modell
 - 3.10.3. Nützliche Tools

Modul 4. *Data Mining*. Auswahl, Vorverarbeitung und Transformation

- 4.1. Statistische Inferenz
 - 4.1.1. Deskriptive Statistik vs. Statistische Inferenz
 - 4.1.2. Parametrische Verfahren
 - 4.1.3. Nichtparametrische Verfahren
- 4.2. Explorative Analyse
 - 4.2.1. Deskriptive Analyse
 - 4.2.2. Visualisierung
 - 4.2.3. Vorbereitung der Daten
- 4.3. Vorbereitung der Daten
 - 4.3.1. Datenintegration und -bereinigung
 - 4.3.2. Normalisierung der Daten
 - 4.3.3. Attribute umwandeln
- 4.4. Verlorene Werte
 - 4.4.1. Umgang mit verlorenen Werten
 - 4.4.2. Maximum-Likelihood-Imputationsmethoden
 - 4.4.3. Imputation verlorener Werte durch maschinelles Lernen

- 4.5. Datenrauschen
 - 4.5.1. Lärmklassen und Attribute
 - 4.5.2. Rauschfilterung
 - 4.5.3. Rauscheffekt
- 4.6. Der Fluch der Dimensionalität
 - 4.6.1. *Oversampling*
 - 4.6.2. *Undersampling*
 - 4.6.3. Multidimensionale Datenreduktion
- 4.7. Kontinuierliche zu diskreten Attributen
 - 4.7.1. Kontinuierliche versus diskrete Daten
 - 4.7.2. Prozess der Diskretisierung
- 4.8. Daten
 - 4.8.1. Datenauswahl
 - 4.8.2. Perspektiven und Auswahlkriterien
 - 4.8.3. Methoden der Auswahl
- 4.9. Auswahl der Instanzen
 - 4.9.1. Methoden für die Instanzauswahl
 - 4.9.2. Auswahl der Prototypen
 - 4.9.3. Erweiterte Methoden für die Instanzauswahl
- 4.10. Vorverarbeitung von Daten in *Big-Data*-Umgebungen

Modul 5. Algorithmik und Komplexität in der künstlichen Intelligenz

- 5.1. Einführung in Algorithmus-Design-Strategien
 - 5.1.1. Rekursion
 - 5.1.2. Aufteilen und erobern
 - 5.1.3. Andere Strategien
- 5.2. Effizienz und Analyse von Algorithmen
 - 5.2.1. Maßnahmen zur Steigerung der Effizienz
 - 5.2.2. Messung der Eingabegröße
 - 5.2.3. Messung der Ausführungszeit
 - 5.2.4. Schlimmster, bester und durchschnittlicher Fall
 - 5.2.5. Asymptotische Notation
 - 5.2.6. Kriterien für die mathematische Analyse von nicht-rekursiven Algorithmen
 - 5.2.7. Mathematische Analyse von rekursiven Algorithmen
 - 5.2.8. Empirische Analyse von Algorithmen
- 5.3. Sortieralgorithmen
 - 5.3.1. Konzept der Sortierung
 - 5.3.2. Blase sortieren
 - 5.3.3. Sortieren nach Auswahl
 - 5.3.4. Reihenfolge der Insertion
 - 5.3.5. Sortierung zusammenführen (*Merge_Sort*)
 - 5.3.6. Schnelle Sortierung (*Quick_Sort*)
- 5.4. Algorithmen mit Bäumen
 - 5.4.1. Konzept des Baumes
 - 5.4.2. Binäre Bäume
 - 5.4.3. Baumpfade
 - 5.4.4. Ausdrücke darstellen
 - 5.4.5. Geordnete binäre Bäume
 - 5.4.6. Ausgeglichene binäre Bäume
- 5.5. Algorithmen mit *Heaps*
 - 5.5.1. *Heaps*
 - 5.5.2. Der *Heapsort*-Algorithmus
 - 5.5.3. Prioritätswarteschlangen
- 5.6. Graph-Algorithmen
 - 5.6.1. Vertretung
 - 5.6.2. Lauf in Breite
 - 5.6.3. Lauf in Tiefe
 - 5.6.4. Topologische Anordnung
- 5.7. *Greedy*-Algorithmen
 - 5.7.1. Die *Greedy*-Strategie
 - 5.7.2. Elemente der *Greedy*-Strategie
 - 5.7.3. Währungsumtausch
 - 5.7.4. Das Problem des Reisenden
 - 5.7.5. Problem mit dem Rucksack

5.8. Minimale Pfadsuche

- 5.8.1. Das Problem des minimalen Pfades
- 5.8.2. Negative Bögen und Zyklen
- 5.8.3. Dijkstra-Algorithmus

5.9. Greedy-Algorithmen auf Graphen

- 5.9.1. Der minimal aufspannende Baum
- 5.9.2. Algorithmus von Prim
- 5.9.3. Algorithmus von Kruskal
- 5.9.4. Komplexitätsanalyse

5.10. Backtracking

- 5.10.1. Das Backtracking
- 5.10.2. Alternative Techniken

Modul 6. Intelligente Systeme

6.1. Agententheorie

- 6.1.1. Geschichte des Konzepts
- 6.1.2. Definition von Agent
- 6.1.3. Agenten in der künstlichen Intelligenz
- 6.1.4. Agenten in der Softwareentwicklung

6.2. Agent-Architekturen

- 6.2.1. Der Denkprozess eines Agenten
- 6.2.2. Reaktive Agenten
- 6.2.3. Deduktive Agenten
- 6.2.4. Hybride Agenten
- 6.2.5. Vergleich

6.3. Informationen und Wissen

- 6.3.1. Unterscheidung zwischen Daten, Informationen und Wissen
- 6.3.2. Bewertung der Datenqualität
- 6.3.3. Methoden der Datenerfassung
- 6.3.4. Methoden der Informationsbeschaffung
- 6.3.5. Methoden zum Wissenserwerb

6.4. Wissensrepräsentation

- 6.4.1. Die Bedeutung der Wissensrepräsentation
- 6.4.2. Definition der Wissensrepräsentation durch ihre Rollen
- 6.4.3. Merkmale einer Wissensrepräsentation

6.5. Ontologien

- 6.5.1. Einführung in Metadaten
- 6.5.2. Philosophisches Konzept der Ontologie
- 6.5.3. Computergestütztes Konzept der Ontologie
- 6.5.4. Bereichsontologien und Ontologien auf höherer Ebene
- 6.5.5. Wie erstellt man eine Ontologie?

6.6. Ontologiesprachen und Software für die Erstellung von Ontologien

- 6.6.1. RDF-Tripel, Turtle und N
- 6.6.2. RDF-Schema
- 6.6.3. OWL
- 6.6.4. SPARQL
- 6.6.5. Einführung in die verschiedenen Tools für die Erstellung von Ontologien
- 6.6.6. Installation und Verwendung von Protégé

6.7. Das semantische Web

- 6.7.1. Der aktuelle Stand und die Zukunft des semantischen Webs
- 6.7.2. Anwendungen des semantischen Webs

6.8. Andere Modelle der Wissensdarstellung

- 6.8.1. Wortschatz
- 6.8.2. Globale Sicht
- 6.8.3. Taxonomie
- 6.8.4. Thesauri
- 6.8.5. Folksonomien
- 6.8.6. Vergleich
- 6.8.7. Mind Map

- 6.9. Bewertung und Integration von Wissensrepräsentationen
 - 6.9.1. Logik nullter Ordnung
 - 6.9.2. Logik erster Ordnung
 - 6.9.3. Beschreibende Logik
 - 6.9.4. Beziehung zwischen verschiedenen Arten von Logik
 - 6.9.5. *Prolog*: Programmierung auf Basis der Logik erster Ordnung
- 6.10. Semantische *Reasoner*, wissensbasierte Systeme und Expertensysteme
 - 6.10.1. Konzept des *Reasoners*
 - 6.10.2. Anwendungen eines *Reasoners*
 - 6.10.3. Wissensbasierte Systeme
 - 6.10.4. MYCIN, Geschichte der Expertensysteme
 - 6.10.5. Elemente und Architektur von Expertensystemen
 - 6.10.6. Erstellung von Expertensystemen

Modul 7. Maschinelles Lernen und *Data Mining*

- 7.1. Einführung in die Prozesse der Wissensentdeckung und in die grundlegenden Konzepte des maschinellen Lernens
 - 7.1.1. Schlüsselkonzepte von Prozessen der Wissensentdeckung
 - 7.1.2. Historische Perspektive der Wissensentdeckungsprozesse
 - 7.1.3. Phasen des Wissensentdeckungsprozesses
 - 7.1.4. Techniken, die bei der Wissensentdeckung eingesetzt werden
 - 7.1.5. Merkmale guter Modelle für maschinelles Lernen
 - 7.1.6. Arten von Informationen zum maschinellen Lernen
 - 7.1.7. Grundlegende Lernkonzepte
 - 7.1.8. Grundlegende Konzepte des unüberwachten Lernens
- 7.2. Datenexploration und Vorverarbeitung
 - 7.2.1. Datenverarbeitung
 - 7.2.2. Datenverarbeitung im Datenanalysefluss
 - 7.2.3. Datentypen
 - 7.2.4. Datenumwandlung
 - 7.2.5. Anzeige und Untersuchung von kontinuierlichen Variablen
 - 7.2.6. Anzeige und Erkundung kategorialer Variablen
 - 7.2.7. Korrelationsmaßnahmen

- 7.2.8. Die häufigsten grafischen Darstellungen
- 7.2.9. Einführung in die multivariate Analyse und Dimensionsreduktion
- 7.3. Entscheidungsbaum
 - 7.3.1. ID-Algorithmus
 - 7.3.2. Algorithmus C
 - 7.3.3. Übertraining und Beschneidung
 - 7.3.4. Analyse der Ergebnisse
- 7.4. Bewertung von Klassifikatoren
 - 7.4.1. Konfusionsmatrizen
 - 7.4.2. Numerische Bewertungsmatrizen
 - 7.4.3. Kappa-Statistik
 - 7.4.4. Die ROC-Kurve
- 7.5. Klassifizierungsregeln
 - 7.5.1. Maßnahmen zur Bewertung von Regeln
 - 7.5.2. Einführung in die grafische Darstellung
 - 7.5.3. Sequentieller Überlagerungsalgorithmus
- 7.6. Neuronale Netze
 - 7.6.1. Grundlegende Konzepte
 - 7.6.2. Einfache neuronale Netze
 - 7.6.3. *Backpropagation*-Algorithmus
 - 7.6.4. Einführung in rekurrente neuronale Netze
- 7.7. Bayessche Methoden
 - 7.7.1. Grundlegende Konzepte der Wahrscheinlichkeit
 - 7.7.2. Bayes-Theorem
 - 7.7.3. Naive Bayes
 - 7.7.4. Einführung in Bayessche Netzwerke
- 7.8. Regressions- und kontinuierliche Antwortmodelle
 - 7.8.1. Einfache lineare Regression
 - 7.8.2. Multiple lineare Regression
 - 7.8.3. Logistische Regression
 - 7.8.4. Regressionsbäume
 - 7.8.5. Einführung in *Support Vector Machines* (SVM)
 - 7.8.6. Maße für die Anpassungsgüte

7.9. Clustering

- 7.9.1. Grundlegende Konzepte
- 7.9.2. Hierarchisches Clustering
- 7.9.3. Probabilistische Methoden
- 7.9.4. EM-Algorithmus
- 7.9.5. B-Cubed-Methode
- 7.9.6. Implizite Methoden

7.10. Text Mining und natürliche Sprachverarbeitung (NLP)

- 7.10.1. Grundlegende Konzepte
- 7.10.2. Erstellung eines Korpus
- 7.10.3. Deskriptive Analyse
- 7.10.4. Einführung in die Stimmungsanalyse

Modul 8. Neuronale Netze, die Grundlage von Deep Learning

8.1. Tiefes Lernen

- 8.1.1. Arten von tiefem Lernen
- 8.1.2. Anwendungen von tiefem Lernen
- 8.1.3. Vor- und Nachteile von tiefem Lernen

8.2. Operationen

- 8.2.1. Addition
- 8.2.2. Produkt
- 8.2.3. Transfer

8.3. Ebenen

- 8.3.1. Eingangsebene
- 8.3.2. Ausgeblendete Ebene
- 8.3.3. Ausgangsebene

8.4. Schichtenverbund und Operationen

- 8.4.1. Design-Architekturen
- 8.4.2. Verbindung zwischen Ebenen
- 8.4.3. Vorwärtsausbreitung

8.5. Aufbau des ersten neuronalen Netzes

- 8.5.1. Entwurf des Netzes
- 8.5.2. Festlegen der Gewichte
- 8.5.3. Training des Netzes

8.6. Trainer und Optimierer

- 8.6.1. Auswahl des Optimierers
- 8.6.2. Festlegen einer Verlustfunktion
- 8.6.3. Festlegung einer Metrik

8.7. Anwendung der Prinzipien des neuronalen Netzes

- 8.7.1. Aktivierungsfunktionen
- 8.7.2. Rückwärtsausbreitung
- 8.7.3. Einstellung der Parameter

8.8. Von biologischen zu künstlichen Neuronen

- 8.8.1. Funktionsweise eines biologischen Neurons
- 8.8.2. Wissensübertragung auf künstliche Neuronen
- 8.8.3. Herstellung von Beziehungen zwischen den beiden

8.9. Implementierung von MLP (Multilayer Perceptron) mit Keras

- 8.9.1. Definition der Netzstruktur
- 8.9.2. Modell-Kompilierung
- 8.9.3. Modell-Training

8.10. Feinabstimmung der Hyperparameter von neuronalen Netzen

- 8.10.1. Auswahl der Aktivierungsfunktion
- 8.10.2. Einstellung der Learning Rate
- 8.10.3. Einstellung der Gewichte

Modul 9. Training Tiefer Neuronaler Netze

9.1. Gradienten-Probleme

- 9.1.1. Techniken der Gradientenoptimierung
- 9.1.2. Stochastische Gradienten
- 9.1.3. Techniken zur Initialisierung der Gewichte

9.2. Wiederverwendung von vortrainierten Schichten

- 9.2.1. Transfer Learning Training
- 9.2.2. Merkmalsextraktion
- 9.2.3. Tiefes Lernen

- 9.3. Optimierer
 - 9.3.1. Stochastische Gradientenabstiegs-Optimierer
 - 9.3.2. Adam- und *RMSprop*-Optimierer
 - 9.3.3. Moment-Optimierer
- 9.4. Planen der Lernrate
 - 9.4.1. Automatische Steuerung der Lernrate
 - 9.4.2. Lernzyklen
 - 9.4.3. Bedingungen für die Glättung
- 9.5. Überanpassung
 - 9.5.1. Kreuzvalidierung
 - 9.5.2. Regulierung
 - 9.5.3. Bewertungsmetriken
- 9.6. Praktische Leitlinien
 - 9.6.1. Entwurf des Modells
 - 9.6.2. Auswahl der Metriken und Bewertungsparameter
 - 9.6.3. Testen von Hypothesen
- 9.7. *Transfer Learning*
 - 9.7.1. *Transfer Learning Training*
 - 9.7.2. Merkmalsextraktion
 - 9.7.3. Tiefes Lernen
- 9.8. *Data Augmentation*
 - 9.8.1. Bildtransformationen
 - 9.8.2. Generierung synthetischer Daten
 - 9.8.3. Textumwandlung
- 9.9. Praktische Anwendung von *Transfer Learning*
 - 9.9.1. *Transfer Learning Training*
 - 9.9.2. Merkmalsextraktion
 - 9.9.3. Tiefes Lernen
- 9.10. Regulierung
 - 9.10.1. L und L
 - 9.10.2. Maximale Entropie-Regularisierung
 - 9.10.3. *Dropout*

Modul 10. Anpassung von Modellen und Training mit *TensorFlow*

- 10.1. *TensorFlow*
 - 10.1.1. Verwendung der *TensorFlow*-Bibliothek
 - 10.1.2. Training von Modellen mit *TensorFlow*
 - 10.1.3. Operationen mit Graphen in *TensorFlow*
- 10.2. *TensorFlow* und NumPy
 - 10.2.1. NumPy-Berechnungsumgebung für *TensorFlow*
 - 10.2.2. Verwendung von NumPy-Arrays mit *TensorFlow*
 - 10.2.3. NumPy-Operationen für *TensorFlow*-Graphen
- 10.3. Anpassung von Modellen und Trainingsalgorithmen
 - 10.3.1. Erstellen von benutzerdefinierten Modellen mit *TensorFlow*
 - 10.3.2. Verwaltung von Trainingsparametern
 - 10.3.3. Verwendung von Optimierungstechniken für das Training
- 10.4. *TensorFlow*-Funktionen und -Graphen
 - 10.4.1. Funktionen mit *TensorFlow*
 - 10.4.2. Verwendung von Graphen für das Modelltraining
 - 10.4.3. Optimieren von Graphen mit *TensorFlow*-Operationen
- 10.5. Laden und Vorverarbeiten von Daten mit *TensorFlow*
 - 10.5.1. Laden von Datensätzen mit *TensorFlow*
 - 10.5.2. Vorverarbeiten von Daten mit *TensorFlow*
 - 10.5.3. Verwendung von *TensorFlow*-Tools zur Datenmanipulation
- 10.6. Die *tfddata*-API
 - 10.6.1. Verwendung der *tfddata*-API für die Datenverarbeitung
 - 10.6.2. Konstruktion von Datenströmen mit *tfddata*
 - 10.6.3. Verwendung der *tfddata*-API für das Modelltraining
- 10.7. Das *TFRecord*-Format
 - 10.7.1. Verwendung der *TFRecord*-API für die Datenserialisierung
 - 10.7.2. Laden von *TFRecord*-Dateien mit *TensorFlow*
 - 10.7.3. Verwendung von *TFRecord*-Dateien für das Modelltraining

10.8. Keras Vorverarbeitungsschichten

- 10.8.1. Verwendung der Keras-API für die Vorverarbeitung
- 10.8.2. Aufbau von Keras-Vorverarbeitungs-Pipelines
- 10.8.3. Verwendung der Keras Vorverarbeitungs-API für das Modelltraining

10.9. Das Projekt *TensorFlow Datasets*

- 10.9.1. Verwendung von *TensorFlow Datasets* zum Laden von Daten
- 10.9.2. Vorverarbeitung von Daten mit *TensorFlow Datasets*
- 10.9.3. Verwendung von *TensorFlow Datasets* für das Modelltraining

10.10. Erstellen einer *Deep-Learning*-Anwendung mit *TensorFlow*

- 10.10.1. Praktische Anwendung
- 10.10.2. Aufbau einer *Deep Learning*-Anwendung mit *TensorFlow*
- 10.10.3. Trainieren eines Modells mit *TensorFlow*
- 10.10.4. Verwendung der Anwendung für die Vorhersage von Ergebnissen

Modul 11. *Deep Computer Vision* mit *Convolutional Neural Networks*

11.1. Die *Visual-Cortex*-Architektur

- 11.1.1. Funktionen des visuellen Kortex
- 11.1.2. Theorien des rechnergestützten Sehens
- 11.1.3. Modelle der Bildverarbeitung

11.2. Faltungsschichten

- 11.2.1. Wiederverwendung von Gewichten bei der Faltung
- 11.2.2. Faltung D
- 11.2.3. Aktivierungsfunktionen

11.3. Gruppierungsschichten und Implementierung von Gruppierungsschichten mit Keras

- 11.3.1. *Pooling* und *Striding*
- 11.3.2. *Flattening*
- 11.3.3. Arten des *Pooling*

11.4. CNN-Architektur

- 11.4.1. VGG-Architektur
- 11.4.2. *AlexNet*-Architektur
- 11.4.3. *ResNet*-Architektur

11.5. Implementierung eines *ResNet*-CNN mit Keras

- 11.5.1. Initialisierung der Gewichte
- 11.5.2. Definition der Eingabeschicht
- 11.5.3. Definition der Ausgabe

11.6. Verwendung von vortrainierten Keras-Modellen

- 11.6.1. Merkmale der vortrainierten Modelle
- 11.6.2. Verwendung von vortrainierten Modellen
- 11.6.3. Vorteile von vortrainierten Modellen

11.7. Vortrainierte Modelle für das Transferlernen

- 11.7.1. Transferlernen
- 11.7.2. Prozess des Transferlernens
- 11.7.3. Vorteile des Transferlernens

11.8. Klassifizierung und Lokalisierung in *Deep Computer Vision*

- 11.8.1. Klassifizierung von Bildern
- 11.8.2. Objekte in Bildern lokalisieren
- 11.8.3. Objekterkennung

11.9. Objekterkennung und Objektverfolgung

- 11.9.1. Methoden zur Objekterkennung
- 11.9.2. Algorithmen zur Objektverfolgung
- 11.9.3. Verfolgungs- und Lokalisierungstechniken

11.10. Semantische Segmentierung

- 11.10.1. *Deep Learning* für semantische Segmentierung
- 11.10.2. Kantenerkennung
- 11.10.3. Regelbasierte Segmentierungsmethoden

Modul 12. Natürliche Sprachverarbeitung (NLP) mit rekurrenten neuronalen Netzen (RNN) und Aufmerksamkeit

- 12.1. Textgenerierung mit RNN
 - 12.1.1. Training eines RNN für die Texterzeugung
 - 12.1.2. Generierung natürlicher Sprache mit RNN
 - 12.1.3. Anwendungen zur Texterzeugung mit RNN
- 12.2. Erstellung von Trainingsdatensätzen
 - 12.2.1. Vorbereitung der Daten für das RNN-Training
 - 12.2.2. Speicherung des Trainingsdatensatzes
 - 12.2.3. Bereinigung und Transformation der Daten
 - 12.2.4. Sentiment-Analyse
- 12.3. Ranking von Meinungen mit RNN
 - 12.3.1. Erkennung von Themen in Kommentaren
 - 12.3.2. Stimmungsanalyse mit *Deep-Learning*-Algorithmen
- 12.4. *Encoder-Decoder*-Netz für neuronale maschinelle Übersetzung
 - 12.4.1. Training eines RNN für maschinelle Übersetzung
 - 12.4.2. Verwendung eines *Encoder-Decoder*-Netzes für die maschinelle Übersetzung
 - 12.4.3. Verbesserung der Genauigkeit der maschinellen Übersetzung mit RNNs
- 12.5. Aufmerksamkeitsmechanismen
 - 12.5.1. Implementierung von Aufmerksamkeitsmechanismen in RNN
 - 12.5.2. Verwendung von Betreuungsmechanismen zur Verbesserung der Modellgenauigkeit
 - 12.5.3. Vorteile von Betreuungsmechanismen in neuronalen Netzen
- 12.6. *Transformer*-Modelle
 - 12.6.1. Verwendung von *Transformer*-Modellen für die Verarbeitung natürlicher Sprache
 - 12.6.2. Anwendung von *Transformer*-Modellen für die Sicht
 - 12.6.3. Vorteile von *Transformer*-Modellen
- 12.7. *Transformers* für die Sicht
 - 12.7.1. Verwendung von *Transformer* für die Sicht
 - 12.7.2. Vorverarbeitung von Bilddaten
 - 12.7.3. Training eines *Transformer*-Modells für die Sicht

- 12.8. *Hugging Face Transformers*-Bibliothek
 - 12.8.1. Verwendung der *Hugging Face Transformers*-Bibliothek
 - 12.8.2. Anwendung der *Hugging Face Transformers*-Bibliothek
 - 12.8.3. Vorteile der *Hugging Face Transformers*-Bibliothek
- 12.9. Andere *Transformer*-Bibliotheken. Vergleich
 - 12.9.1. Vergleich zwischen den verschiedenen *Transformer*-Bibliotheken
 - 12.9.2. Verwendung der anderen *Transformer*-Bibliotheken
 - 12.9.3. Vorteile der anderen *Transformer*-Bibliotheken
- 12.10. Entwicklung einer NLP-Anwendung mit RNN und Aufmerksamkeit. Praktische Anwendung
 - 12.10.1. Entwicklung einer Anwendung zur Verarbeitung natürlicher Sprache mit RNN und Aufmerksamkeit
 - 12.10.2. Verwendung von RNN, Aufmerksamkeitsmechanismen und *Transformers*-Modellen in der Anwendung
 - 12.10.3. Bewertung der praktischen Umsetzung

Modul 13. *Autoencoder*, GANs und Diffusionsmodelle

- 13.1. Effiziente Datendarstellungen
 - 13.1.1. Reduzierung der Dimensionalität
 - 13.1.2. Tiefes Lernen
 - 13.1.3. Kompakte Repräsentationen
- 13.2. Realisierung von PCA mit einem unvollständigen linearen automatischen Kodierer
 - 13.2.1. Trainingsprozess
 - 13.2.2. Python-Implementierung
 - 13.2.3. Verwendung von Testdaten
- 13.3. Gestapelte automatische Kodierer
 - 13.3.1. Tiefe neuronale Netze
 - 13.3.2. Konstruktion von Kodierungsarchitekturen
 - 13.3.3. Verwendung der Regularisierung
- 13.4. Faltungs-Autokodierer
 - 13.4.1. Entwurf eines Faltungsmodells
 - 13.4.2. Training von Faltungsmodellen

- 13.4.3. Auswertung der Ergebnisse
- 13.5. Automatische Entrauschung des Encoders
 - 13.5.1. Anwendung von Filtern
 - 13.5.2. Entwurf von Kodierungsmodellen
 - 13.5.3. Anwendung von Regularisierungstechniken
- 13.6. Automatische Verteilkodierer
 - 13.6.1. Steigerung der Kodierungseffizienz
 - 13.6.2. Minimierung der Anzahl von Parametern
 - 13.6.3. Verwendung von Regularisierungstechniken
- 13.7. Automatische Variationskodierer
 - 13.7.1. Verwendung der Variationsoptimierung
 - 13.7.2. Unüberwachtes tiefes Lernen
 - 13.7.3. Tiefe latente Repräsentationen
- 13.8. Modische MNIST-Bilderzeugung
 - 13.8.1. Mustererkennung
 - 13.8.2. Bilderzeugung
 - 13.8.3. Training Tiefer Neuronaler Netze
- 13.9. *Generative Adversarial Networks* und Diffusionsmodelle
 - 13.9.1. Bildbasierte Inhaltsgenerierung
 - 13.9.2. Modellierung von Datenverteilungen
 - 13.9.3. Verwendung von *Adversarial Networks*
- 13.10. Implementierung der Modelle
 - 13.10.1. Praktische Anwendung
 - 13.10.2. Implementierung der Modelle
 - 13.10.3. Verwendung von realen Daten
 - 13.10.4. Auswertung der Ergebnisse

Modul 14. Bio-inspiriertes Computing

- 14.1. Einführung in das bio-inspirierte Computing
 - 14.1.1. Einführung in das bio-inspirierte Computing
- 14.2. Algorithmen zur sozialen Anpassung
 - 14.2.1. Bioinspiriertes Computing auf der Grundlage von Ameisenkolonien
 - 14.2.2. Varianten von Ameisenkolonie-Algorithmen
 - 14.2.3. Cloud-basiertes Computing auf Partikelebene
- 14.3. Genetische Algorithmen
 - 14.3.1. Allgemeine Struktur
 - 14.3.2. Implementierungen der wichtigsten Operatoren
- 14.4. Explorations-Ausbeutungsraum-Strategien für genetische Algorithmen
 - 14.4.1. CHC-Algorithmus
 - 14.4.2. Multimodale Probleme
- 14.5. Evolutionäre Berechnungsmodelle (I)
 - 14.5.1. Evolutionäre Strategien
 - 14.5.2. Evolutionäre Programmierung
 - 14.5.3. Algorithmen auf der Grundlage der differentiellen Evolution
- 14.6. Evolutionäre Berechnungsmodelle (II)
 - 14.6.1. Evolutionäre Modelle auf der Grundlage der Schätzung von Verteilungen (EDA)
 - 14.6.2. Genetische Programmierung
- 14.7. Evolutionäre Programmierung angewandt auf Lernprobleme
 - 14.7.1. Regelbasiertes Lernen
 - 14.7.2. Evolutionäre Methoden bei Instanzauswahlproblemen
- 14.8. Multi-Objektive Probleme
 - 14.8.1. Konzept der Dominanz
 - 14.8.2. Anwendung evolutionärer Algorithmen auf multikriterielle Probleme
- 14.9. Neuronale Netze (I)
 - 14.9.1. Einführung in neuronale Netzwerke
 - 14.9.2. Praktisches Beispiel mit neuronalen Netzwerken
- 14.10. Neuronale Netze
 - 14.10.1. Anwendungsbeispiele für neuronale Netze in der medizinischen Forschung
 - 14.10.2. Anwendungsbeispiele für neuronale Netze in der Wirtschaft
 - 14.10.3. Anwendungsfälle für neuronale Netze in der industriellen Bildverarbeitung

Modul 15. Künstliche Intelligenz: Strategien und Anwendungen

- 15.1. Finanzdienstleistungen
 - 15.1.1. Die Auswirkungen von Künstlicher Intelligenz (KI) auf Finanzdienstleistungen. Chancen und Herausforderungen
 - 15.1.2. Anwendungsbeispiele
 - 15.1.3. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.1.4. Mögliche zukünftige Entwicklungen/Nutzungen von KI
- 15.2. Auswirkungen von künstlicher Intelligenz im Gesundheitswesen
 - 15.2.1. Auswirkungen von KI im Gesundheitswesen. Chancen und Herausforderungen
 - 15.2.2. Anwendungsbeispiele
- 15.3. Risiken im Zusammenhang mit dem Einsatz von KI im Gesundheitswesen
 - 15.3.1. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.3.2. Mögliche zukünftige Entwicklungen/Nutzungen von KI
- 15.4. *Retail*
 - 15.4.1. Auswirkungen von KI im *Retail*. Chancen und Herausforderungen
 - 15.4.2. Anwendungsbeispiele
 - 15.4.3. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.4.4. Mögliche zukünftige Entwicklungen/Nutzungen von KI
- 15.5. Industrie
 - 15.5.1. Auswirkungen von KI in der Industrie. Chancen und Herausforderungen
 - 15.5.2. Anwendungsbeispiele
- 15.6. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI in der Industrie
 - 15.6.1. Anwendungsbeispiele
 - 15.6.2. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.6.3. Mögliche zukünftige Entwicklungen/Nutzungen von KI
- 15.7. Öffentliche Verwaltung
 - 15.7.1. Auswirkungen von KI in der Öffentlichen Verwaltung. Chancen und Herausforderungen
 - 15.7.2. Anwendungsbeispiele
 - 15.7.3. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.7.4. Mögliche zukünftige Entwicklungen/Nutzungen von KI

- 15.8. Bildung
 - 15.8.1. Auswirkungen von KI in der Bildung. Chancen und Herausforderungen
 - 15.8.2. Anwendungsbeispiele
 - 15.8.3. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.8.4. Mögliche zukünftige Entwicklungen/Nutzungen von KI
- 15.9. Forst- und Landwirtschaft
 - 15.9.1. Auswirkungen von KI in der Forst- und Landwirtschaft. Chancen und Herausforderungen
 - 15.9.2. Anwendungsbeispiele
 - 15.9.3. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.9.4. Mögliche zukünftige Entwicklungen/Nutzungen von KI
- 15.10. Personalwesen
 - 15.10.1. Auswirkungen von KI im Personalwesen. Chancen und Herausforderungen
 - 15.10.2. Anwendungsbeispiele
 - 15.10.3. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.10.4. Mögliche zukünftige Entwicklungen/Nutzungen von KI



TECH bietet Ihnen einen einzigartigen privaten Masterstudiengang an, der es Ihnen ermöglicht, Ihre Kompetenzen auf revolutionäre Art und Weise zu erweitern. Warten Sie nicht länger und schreiben Sie sich jetzt ein"

06

Studienmethodik

TECH ist die erste Universität der Welt, die die Methodik der **case studies** mit **Relearning** kombiniert, einem 100%igen Online-Lernsystem, das auf geführten Wiederholungen basiert.

Diese disruptive pädagogische Strategie wurde entwickelt, um Fachleuten die Möglichkeit zu bieten, ihr Wissen zu aktualisieren und ihre Fähigkeiten auf intensive und gründliche Weise zu entwickeln. Ein Lernmodell, das den Studenten in den Mittelpunkt des akademischen Prozesses stellt und ihm die Hauptrolle zuweist, indem es sich an seine Bedürfnisse anpasst und die herkömmlichen Methoden beiseite lässt.



“

TECH bereitet Sie darauf vor, sich neuen Herausforderungen in einem unsicheren Umfeld zu stellen und in Ihrer Karriere erfolgreich zu sein“

Der Student: die Priorität aller Programme von TECH

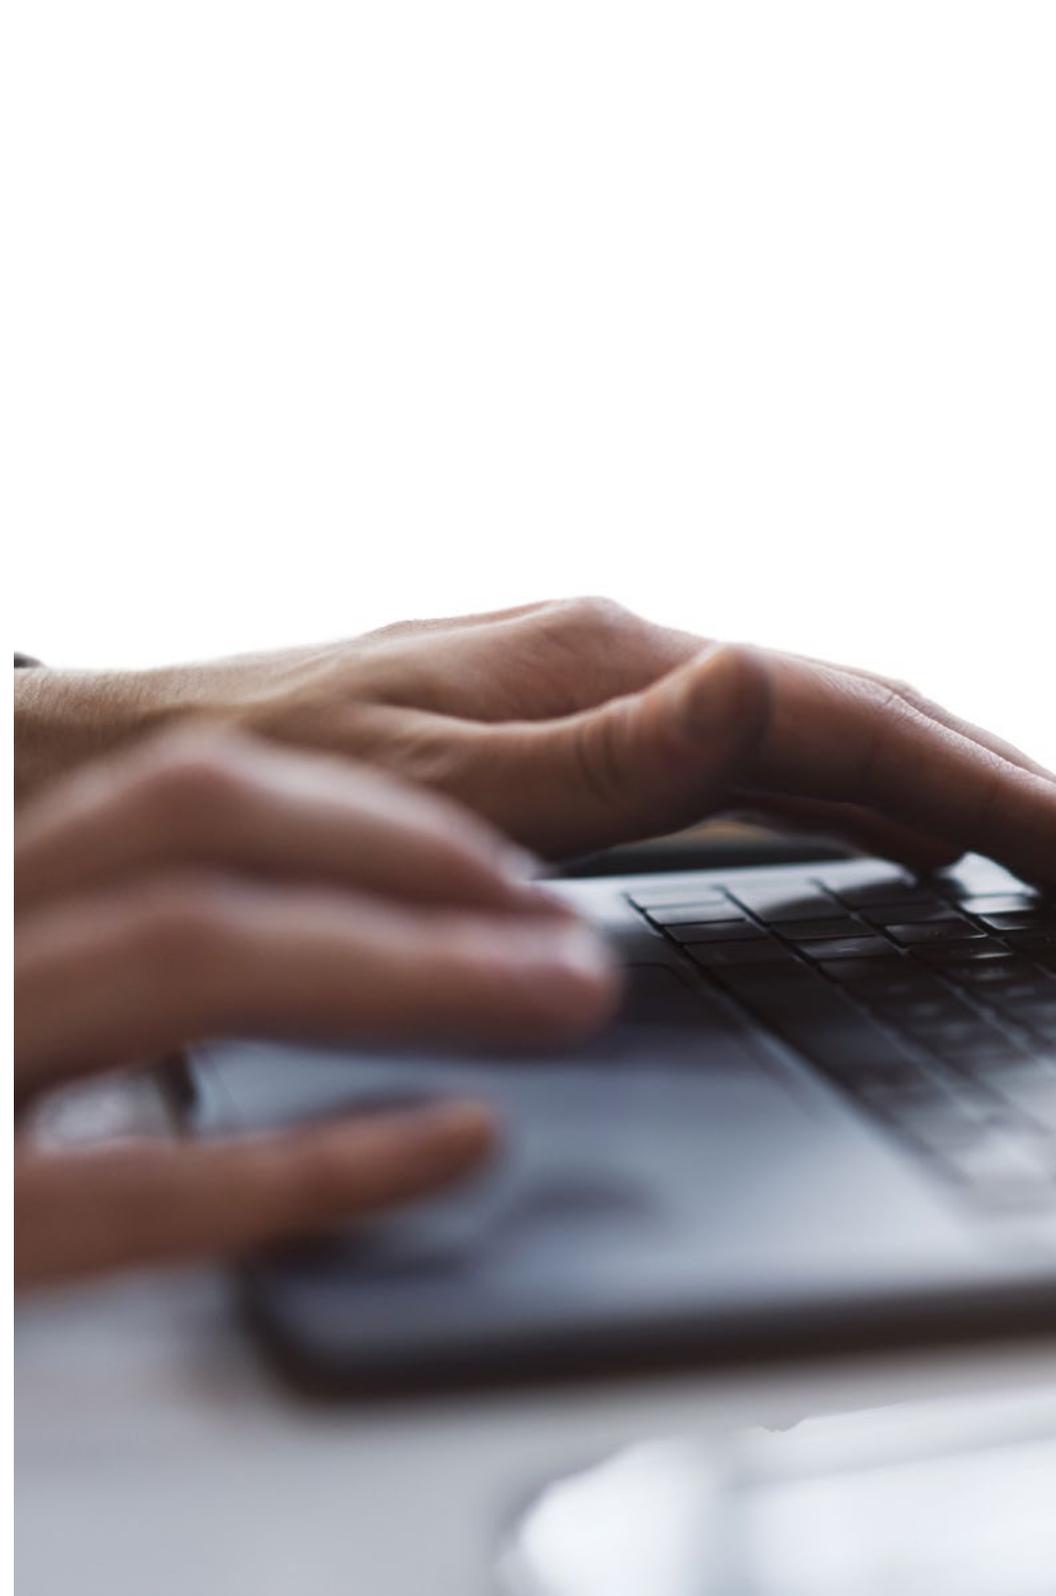
Bei der Studienmethodik von TECH steht der Student im Mittelpunkt.

Die pädagogischen Instrumente jedes Programms wurden unter Berücksichtigung der Anforderungen an Zeit, Verfügbarkeit und akademische Genauigkeit ausgewählt, die heutzutage nicht nur von den Studenten, sondern auch von den am stärksten umkämpften Stellen auf dem Markt verlangt werden.

Beim asynchronen Bildungsmodell von TECH entscheidet der Student selbst, wie viel Zeit er mit dem Lernen verbringt und wie er seinen Tagesablauf gestaltet, und das alles bequem von einem elektronischen Gerät seiner Wahl aus. Der Student muss nicht an Präsenzveranstaltungen teilnehmen, die er oft nicht wahrnehmen kann. Die Lernaktivitäten werden nach eigenem Ermessen durchgeführt. Er kann jederzeit entscheiden, wann und von wo aus er lernen möchte.



*Bei TECH gibt es KEINE Präsenzveranstaltungen
(an denen man nie teilnehmen kann)*



Die international umfassendsten Lehrpläne

TECH zeichnet sich dadurch aus, dass sie die umfassendsten Studiengänge im universitären Umfeld anbietet. Dieser Umfang wird durch die Erstellung von Lehrplänen erreicht, die nicht nur die wesentlichen Kenntnisse, sondern auch die neuesten Innovationen in jedem Bereich abdecken.

Durch ihre ständige Aktualisierung ermöglichen diese Programme den Studenten, mit den Veränderungen des Marktes Schritt zu halten und die von den Arbeitgebern am meisten geschätzten Fähigkeiten zu erwerben. Auf diese Weise erhalten die Studenten, die ihr Studium bei TECH absolvieren, eine umfassende Vorbereitung, die ihnen einen bedeutenden Wettbewerbsvorteil verschafft, um in ihrer beruflichen Laufbahn voranzukommen.

Und das von jedem Gerät aus, ob PC, Tablet oder Smartphone.

“

Das Modell der TECH ist asynchron, d. h. Sie können an Ihrem PC, Tablet oder Smartphone studieren, wo immer Sie wollen, wann immer Sie wollen und so lange Sie wollen“

Case studies oder Fallmethode

Die Fallmethode ist das am weitesten verbreitete Lernsystem an den besten Wirtschaftshochschulen der Welt. Sie wurde 1912 entwickelt, damit Studenten der Rechtswissenschaften das Recht nicht nur auf der Grundlage theoretischer Inhalte erlernten, sondern auch mit realen komplexen Situationen konfrontiert wurden. Auf diese Weise konnten sie fundierte Entscheidungen treffen und Werturteile darüber fällen, wie diese zu lösen sind. Sie wurde 1924 als Standardlehrmethode in Harvard etabliert.

Bei diesem Lehrmodell ist es der Student selbst, der durch Strategien wie *Learning by doing* oder *Design Thinking*, die von anderen renommierten Einrichtungen wie Yale oder Stanford angewandt werden, seine berufliche Kompetenz aufbaut.

Diese handlungsorientierte Methode wird während des gesamten Studiengangs angewandt, den der Student bei TECH absolviert. Auf diese Weise wird er mit zahlreichen realen Situationen konfrontiert und muss Wissen integrieren, recherchieren, argumentieren und seine Ideen und Entscheidungen verteidigen. All dies unter der Prämisse, eine Antwort auf die Frage zu finden, wie er sich verhalten würde, wenn er in seiner täglichen Arbeit mit spezifischen, komplexen Ereignissen konfrontiert würde.



Relearning-Methode

Bei TECH werden die *case studies* mit der besten 100%igen Online-Lernmethode ergänzt: *Relearning*.

Diese Methode bricht mit traditionellen Lehrmethoden, um den Studenten in den Mittelpunkt zu stellen und ihm die besten Inhalte in verschiedenen Formaten zu vermitteln. Auf diese Weise kann er die wichtigsten Konzepte der einzelnen Fächer wiederholen und lernen, sie in einem realen Umfeld anzuwenden.

In diesem Sinne und gemäß zahlreicher wissenschaftlicher Untersuchungen ist die Wiederholung der beste Weg, um zu lernen. Aus diesem Grund bietet TECH zwischen 8 und 16 Wiederholungen jedes zentralen Konzepts innerhalb ein und derselben Lektion, die auf unterschiedliche Weise präsentiert werden, um sicherzustellen, dass das Wissen während des Lernprozesses vollständig gefestigt wird.

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.



Ein 100%iger virtueller Online-Campus mit den besten didaktischen Ressourcen

Um seine Methodik wirksam anzuwenden, konzentriert sich TECH darauf, den Studenten Lehrmaterial in verschiedenen Formaten zur Verfügung zu stellen: Texte, interaktive Videos, Illustrationen und Wissenskarten, um nur einige zu nennen. Sie alle werden von qualifizierten Lehrkräften entwickelt, die ihre Arbeit darauf ausrichten, reale Fälle mit der Lösung komplexer Situationen durch Simulationen, dem Studium von Zusammenhängen, die für jede berufliche Laufbahn gelten, und dem Lernen durch Wiederholung mittels Audios, Präsentationen, Animationen, Bildern usw. zu verbinden.

Die neuesten wissenschaftlichen Erkenntnisse auf dem Gebiet der Neurowissenschaften weisen darauf hin, dass es wichtig ist, den Ort und den Kontext, in dem der Inhalt abgerufen wird, zu berücksichtigen, bevor ein neuer Lernprozess beginnt. Die Möglichkeit, diese Variablen individuell anzupassen, hilft den Menschen, sich zu erinnern und Wissen im Hippocampus zu speichern, um es langfristig zu behalten. Dies ist ein Modell, das als *Neurocognitive context-dependent e-learning* bezeichnet wird und in diesem Hochschulstudium bewusst angewendet wird.

Zum anderen, auch um den Kontakt zwischen Mentor und Student so weit wie möglich zu begünstigen, wird eine breite Palette von Kommunikationsmöglichkeiten angeboten, sowohl in Echtzeit als auch zeitversetzt (internes Messaging, Diskussionsforen, Telefondienst, E-Mail-Kontakt mit dem technischen Sekretariat, Chat und Videokonferenzen).

Darüber hinaus wird dieser sehr vollständige virtuelle Campus den Studenten der TECH die Möglichkeit geben, ihre Studienzeiten entsprechend ihrer persönlichen Verfügbarkeit oder ihren beruflichen Verpflichtungen zu organisieren. Auf diese Weise haben sie eine globale Kontrolle über die akademischen Inhalte und ihre didaktischen Hilfsmittel, in Übereinstimmung mit ihrer beschleunigten beruflichen Weiterbildung.



Der Online-Studienmodus dieses Programms wird es Ihnen ermöglichen, Ihre Zeit und Ihr Lerntempo zu organisieren und an Ihren Zeitplan anzupassen“

Die Wirksamkeit der Methode wird durch vier Schlüsselergebnisse belegt:

1. Studenten, die diese Methode anwenden, nehmen nicht nur Konzepte auf, sondern entwickeln auch ihre geistigen Fähigkeiten durch Übungen zur Bewertung realer Situationen und zur Anwendung ihres Wissens.
2. Das Lernen basiert auf praktischen Fähigkeiten, die es den Studenten ermöglichen, sich besser in die reale Welt zu integrieren.
3. Eine einfachere und effizientere Aufnahme von Ideen und Konzepten wird durch die Verwendung von Situationen erreicht, die aus der Realität entstanden sind.
4. Das Gefühl der Effizienz der investierten Anstrengung wird zu einem sehr wichtigen Anreiz für die Studenten, was sich in einem größeren Interesse am Lernen und einer Steigerung der Zeit, die für die Arbeit am Kurs aufgewendet wird, niederschlägt.

Die von ihren Studenten am besten bewertete Hochschulmethodik

Die Ergebnisse dieses innovativen akademischen Modells lassen sich an der Gesamtzufriedenheit der Absolventen der TECH ablesen.

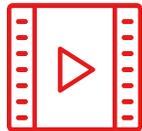
Die Studenten bewerten die Qualität der Lehre, die Qualität der Materialien, die Kursstruktur und die Ziele als hervorragend. So überrascht es nicht, dass die Einrichtung von ihren Studenten auf der Bewertungsplattform Trustpilot mit 4,9 von 5 Punkten am besten bewertet wurde.

Sie können von jedem Gerät mit Internetanschluss (Computer, Tablet, Smartphone) auf die Studieninhalte zugreifen, da TECH in Sachen Technologie und Pädagogik führend ist.

Sie werden die Vorteile des Zugangs zu simulierten Lernumgebungen und des Lernens durch Beobachtung, d. h. Learning from an expert, nutzen können.



In diesem Programm stehen Ihnen die besten Lehrmaterialien zur Verfügung, die sorgfältig vorbereitet wurden:



Studienmaterial

Alle didaktischen Inhalte werden von den Fachkräfte, 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 ein audiovisuelles Format übertragen, das unsere Online-Arbeitsweise mit den neuesten Techniken ermöglicht, die es uns erlauben, Ihnen eine hohe Qualität in jedem der Stücke zu bieten, die wir Ihnen zur Verfügung stellen werden.



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.



Interaktive Zusammenfassungen

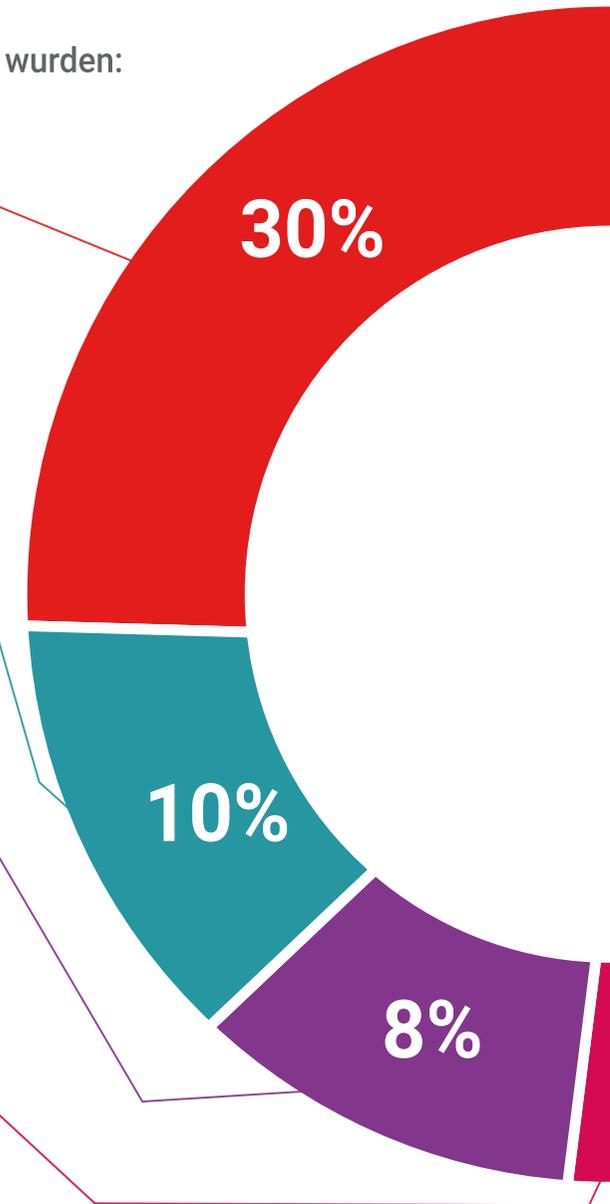
Wir präsentieren die Inhalte auf attraktive und dynamische Weise in multimedialen Pillen, Audios, Videos, Bilder, Diagramme und konzeptionelle Karten enthalten, um das Wissen zu festigen.

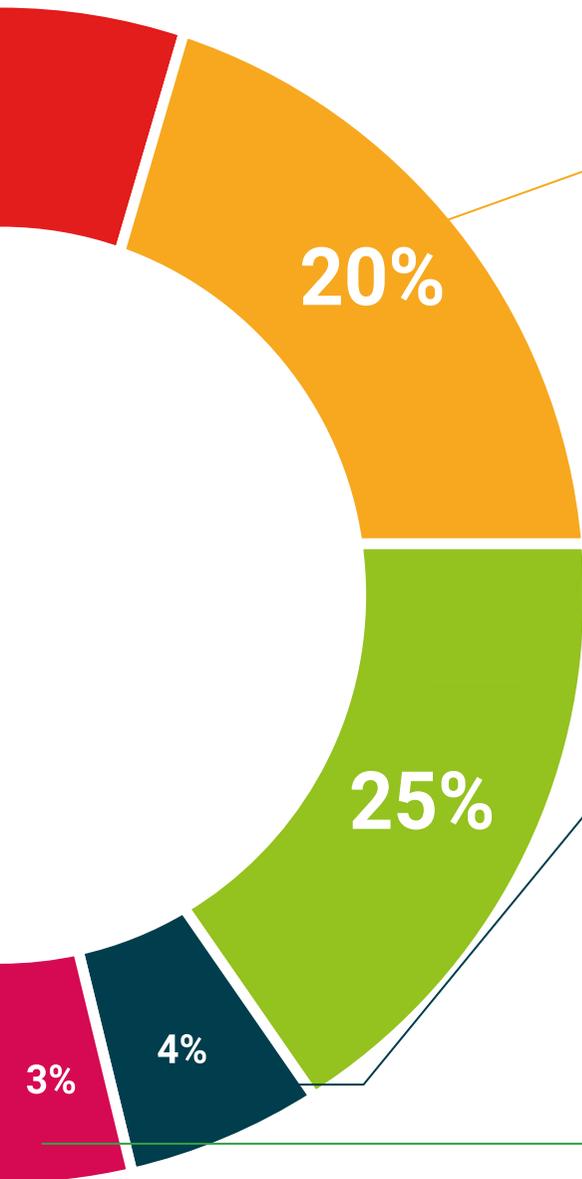
Dieses einzigartige System für die Präsentation multimedialer Inhalte wurde von Microsoft als „Europäische Erfolgsgeschichte“ ausgezeichnet.



Weitere Lektüren

Aktuelle Artikel, Konsensdokumente, internationale Leitfäden... In unserer virtuellen Bibliothek haben Sie Zugang zu allem, was Sie für Ihre Ausbildung benötigen.





Case Studies

Sie werden eine Auswahl der besten case studies zu diesem Thema bearbeiten. Die Fälle werden von den besten Spezialisten der internationalen Szene präsentiert, analysiert und betreut.



Testing & Retesting

Während des gesamten Programms werden Ihre Kenntnisse in regelmäßigen Abständen getestet und wiederholt. Wir tun dies auf 3 der 4 Ebenen der Millerschen Pyramide.



Classes

Die Nützlichkeit der Expertenbeobachtung ist wissenschaftlich belegt. Das sogenannte Learning from an Expert stärkt das Wissen und das Gedächtnis und schafft Vertrauen in unsere zukünftigen schwierigen Entscheidungen.



Quick Action Guides

TECH bietet die wichtigsten Inhalte des Kurses in Form von Arbeitsblättern oder Kurzanleitungen an. Ein synthetischer, praktischer und effektiver Weg, um dem Studenten zu helfen, in seinem Lernen voranzukommen.



07

Qualifizierung

Der Privater Masterstudiengang in Künstliche Intelligenz 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 Künstliche Intelligenz** enthält das vollständigste und aktuellste Programm auf dem Markt.

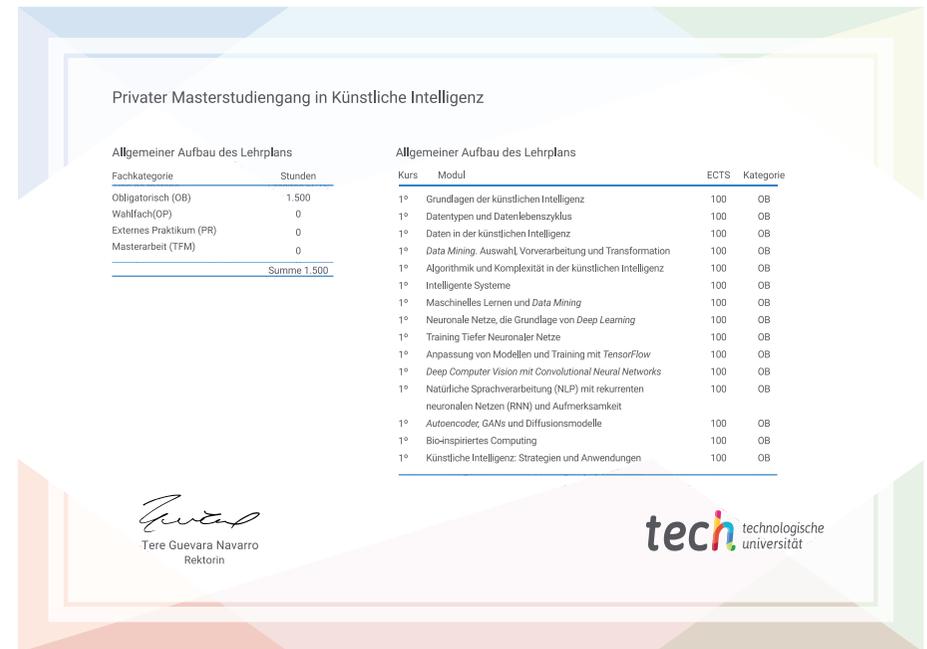
Sobald der Student die Prüfungen bestanden hat, erhält er/sie per Post* mit Empfangsbestätigung das entsprechende Diplom, ausgestellt von der **TECH Technologischen Universität**.

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 Künstliche Intelligenz**

Modalität: **online**

Dauer: **12 Monate**



*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 Künstliche Intelligenz

- » Modalität: online
- » Dauer: 12 Monate
- » Qualifizierung: TECH Technologische Universität
- » Zeitplan: in Ihrem eigenen Tempo
- » Prüfungen: online

Privater Masterstudiengang Künstliche Intelligenz