

Privater Masterstudiengang Künstliche Intelligenz in Börsen und Finanzmärkten



Privater Masterstudiengang Künstliche Intelligenz in Börsen und Finanzmärkten

- » 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-borsen-finanzmarkten

Index

01

Präsentation

Seite 4

02

Ziele

Seite 8

03

Kompetenzen

Seite 18

04

Kursleitung

Seite 22

05

Struktur und Inhalt

Seite 26

06

Methodik

Seite 44

07

Qualifizierung

Seite 52

01

Präsentation

Künstliche Intelligenz (KI) verändert die Welt der Börse und der Finanzmärkte radikal und führt neue Formen der Analyse und Entscheidungsfindung ein. KI-Algorithmen, die auf maschinellem Lernen und der Verarbeitung großer Datenmengen beruhen, ermöglichen es Anlegern, genauere Vorhersagen über Markttrends zu treffen und Chancen zu erkennen, die von menschlichen Analysten unbemerkt bleiben könnten. In diesem Zusammenhang hat TECH ein vollständig virtuelles Programm entwickelt, das sich an den individuellen und beruflichen Zeitplan der Studenten anpasst. Darüber hinaus setzt sie eine innovative Lernmethode ein, die als *Relearning* bekannt ist und die es nur an dieser Universität gibt.



“

Mit diesem 100%igen Online-Masterstudiengang werden Sie verstehen, wie KI die technische und fundamentale Analyse verändern und Anlageentscheidungen mit einer Präzision optimieren kann, die die menschliche Intuition übertrifft“

Der Einsatz von künstlicher Intelligenz (KI) im Finanzwesen hat sich mit der Entwicklung fortschrittlicher Algorithmen für *Machine Learning*, die Anlagestrategien und Risikoanalysen optimieren, intensiviert. Finanzinstitute setzen KI ein, um Abläufe zu automatisieren, Betrug in Echtzeit aufzudecken und Anlageempfehlungen für ihre Kunden zu personalisieren.

Dieser private Masterstudiengang vermittelt ein solides Verständnis dafür, wie fortschrittliche Techniken der künstlichen Intelligenz auf die technische Analyse der Märkte angewendet werden können. So werden Fachleute in der Lage sein, moderne Tools für die Visualisierung und Automatisierung von technischen Indikatoren zu nutzen sowie ausgefeilte Modelle, wie z. B. faltungsneuronalen Netze für die Erkennung von Finanzmustern, zu implementieren.

Experten werden auch mit Techniken des *Machine Learning* und *Deep Learning* sowie mit natürlicher Sprachverarbeitung (NLP) vertraut gemacht, um Finanzberichte und andere relevante Dokumente zu analysieren. Methoden zur Risiko- und Kreditbewertung, ESG-Nachhaltigkeitsanalyse und Erkennung von Finanzbetrug werden ebenfalls behandelt.

Schließlich wird die Verarbeitung großer Mengen von Finanzdaten behandelt, die Verarbeitung und Analyse von *Big Data* mit fortschrittlichen Tools wie Hadoop und Spark. Darüber hinaus werden die Integration, Bereinigung und Visualisierung von Daten sowie die Sicherheit und der Datenschutz im Umgang mit Finanzdaten erforscht. Gleichzeitig werden algorithmische *Trading*-Strategien analysiert, einschließlich des Entwurfs und der Optimierung von automatisierten Systemen und des Risikomanagements.

Auf diese Weise hat TECH ein detailliertes, vollständig online verfügbares Hochschulprogramm geschaffen, das es den Studenten ermöglicht, über jedes elektronische Gerät mit Internetanschluss auf die Lehrmaterialien zuzugreifen. Damit entfällt die Notwendigkeit, an einen physischen Ort zu reisen und sich an einen bestimmten Zeitplan anzupassen. Darüber hinaus ist die revolutionäre *Relearning*-Methode integriert, die auf der Wiederholung wesentlicher Konzepte basiert, um das Verständnis der Inhalte zu verbessern.

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

- Die Entwicklung von Fallstudien, die von Experten für künstliche Intelligenz vorgestellt werden, mit Schwerpunkt auf der Börse und den Finanzmärkten
- Der anschauliche, schematische und äußerst praxisnahe Inhalt vermittelt alle für die berufliche Praxis unverzichtbaren Informationen
- Die praktischen Übungen, bei denen der Selbstbewertungsprozess zur Verbesserung des Lernens durchgeführt 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 Zugriffs auf die Inhalte von jedem festen oder tragbaren Gerät mit Internetanschluss



Sie werden in der Lage sein, große Mengen an Finanzdaten zu verarbeiten und zu analysieren, effektive algorithmische Handelsstrategien zu entwerfen und sich mit komplexen ethischen und regulatorischen Fragen auseinanderzusetzen“

“

Dank einer umfangreichen Bibliothek mit innovativen Multimedia-Ressourcen werden Sie sich mit fortgeschrittenen Methoden wie dem Reinforcement Learning für den algorithmischen Handel und der Zeitreihenmodellierung mit LSTM beschäftigen“

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

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

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

Sie werden in der Lage sein, genaue und effiziente Analysen in einem Umfeld zunehmender Komplexität und Dynamik auf den Finanzmärkten durchzuführen, und zwar mit Hilfe der besten Lehrmaterialien, die an der Spitze von Technologie und Bildung stehen.

Sie werden sich mit Ethik und Regulierung beim Einsatz von KI im Finanzwesen befassen und werden so darauf vorbereitet, sich ethischen und regulatorischen Herausforderungen zu stellen und Technologien im Finanzsektor verantwortungsvoll zu entwickeln.



02 Ziele

Das Programm wird Fachleute mit den notwendigen Fähigkeiten ausstatten, um fortgeschrittene Techniken des *Machine Learning* und *Deep Learning* in der technischen und fundamentalen Analyse anzuwenden und Investitions- und *Trading*-Strategien zu optimieren. Es wird sich auch auf die Entwicklung von Kompetenzen zur Handhabung und Verarbeitung großer Mengen von Finanzdaten, zur Entwicklung und Bewertung von algorithmischen *Trading*-Systemen und zur Behandlung ethischer und regulatorischer Fragen im Zusammenhang mit der Anwendung von KI im Finanzwesen konzentrieren. In diesem Sinne werden die Experten darauf vorbereitet, sich den Herausforderungen zu stellen und die Chancen zu nutzen, die die KI in einem sich ständig verändernden Finanzumfeld bietet.



“

Das Hauptziel dieses privaten Masterstudiengangs besteht darin, hochqualifizierte Fachleute für die Integration von künstlicher Intelligenz in die Analyse und das Management von Finanzmärkten fortzubilden. Worauf warten Sie, um sich einzuschreiben?”



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
- ♦ Entwickeln von Fähigkeiten zur Anwendung fortgeschrittener Techniken der künstlichen Intelligenz in der technischen und fundamentalen Analyse der Finanzmärkte, einschließlich der Verwendung von *Machine Learning*, *Deep Learning* und NLP
- ♦ Befähigen der Studenten, algorithmische Handelsstrategien zu entwerfen, zu implementieren und zu optimieren und dabei Techniken des *Reinforcement Learning* und des *Machine Learning* einzusetzen, um die Effizienz und Rentabilität auf den Finanzmärkten zu verbessern
- ♦ Erwerben von Kompetenzen in der Verarbeitung und Analyse großer Mengen von Finanzdaten unter Verwendung von *Big-Data*-Technologien wie Hadoop und Spark
- ♦ Fördern der Fähigkeit, Modelle der künstlichen Intelligenz zu erstellen und anzuwenden, die erklärbar und transparent sind, um sicherzustellen, dass KI-basierte Finanzentscheidungen verständlich und begründbar sind
- ♦ Entwickeln eines tiefgreifenden Verständnisses der ethischen und regulatorischen Herausforderungen, die mit dem Einsatz von künstlicher Intelligenz im Finanzwesen verbunden sind
- ♦ Vermitteln der notwendigen Werkzeuge und Kenntnisse, um innovative Finanzlösungen zu entwickeln, die künstliche Intelligenz integrieren
- ♦ Erstellen von Vorhersagemodellen mit Hilfe von Techniken des *Machine Learning*, wie z. B. LSTM und Zeitreihenmodelle, um Marktbewegungen zu antizipieren und die Entscheidungsfindung bei Investitionen zu verbessern
- ♦ Entwickeln von Fähigkeiten zur Portfolio-Optimierung und zum Finanzrisikomanagement unter Verwendung genetischer Algorithmen und anderer fortschrittlicher Techniken der künstlichen Intelligenz, um die Erträge zu maximieren und das Anlagerisiko zu minimieren
- ♦ Bereitstellen der erforderlichen Tools und Techniken zur Implementierung und Optimierung von Hochfrequenzhandelsstrategien unter Verwendung von *Machine Learning*-Modellen zur Verbesserung der Geschwindigkeit und Genauigkeit der Auftragsausführung
- ♦ Anwenden von KI-Technologien im Finanzwesen auf ethische und verantwortungsbewusste Weise, unter Berücksichtigung von Fairness, Transparenz und Datenschutz in ihren Lösungen



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 seinen Bestandteilen und seinem Aufbau

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 ihrer 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, durch Anwendung von Filter- und Glättungsverfahren, 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

Modul 16. Technische Analyse von Finanzmärkten mit KI

- ♦ Entwickeln der Fähigkeit, technische Indikatoren mit Hilfe von Tools wie Plotly, Dash und Scikit-learn zu visualisieren und zu optimieren, um eine fundiertere Entscheidungsfindung bei der technischen Analyse von Finanzmärkten zu ermöglichen
- ♦ Implementieren von *Convolutional Neural Networks (CNN)* zur Mustererkennung in Finanzdaten, um die Genauigkeit bei der Identifizierung von *Trading-Chancen* zu verbessern.

- ♦ Erwerben von Kompetenzen in der Entwicklung und Optimierung von algorithmischen Handelsstrategien unter Verwendung von *Reinforcement-Learning*-Techniken mit *TensorFlow*, die auf die Maximierung der Rentabilität ausgerichtet sind

Modul 17. Fundamentalanalyse von Finanzmärkten mit KI

- ♦ Lernen, die finanzielle Performance von Unternehmen mithilfe von Techniken des *Machine Learning* und *Deep Learning* zu modellieren und vorherzusagen, um datengestützte Anlageentscheidungen zu erleichtern
- ♦ Anwenden von Techniken zur Verarbeitung natürlicher Sprache (NLP) wie ChatGPT, um relevante Informationen aus Finanzberichten zu analysieren und zu extrahieren und so die Bewertung der finanziellen Gesundheit von Unternehmen zu verbessern
- ♦ Entwickeln von Fähigkeiten in der Erkennung von Finanzbetrug und der Risikobewertung durch den Einsatz von *Machine Learning*, um mehr Sicherheit und Genauigkeit bei Finanzentscheidungen zu gewährleisten

Modul 18. Verarbeitung von Finanzdaten in großem Maßstab

- ♦ Beherrschen des Einsatzes von *Big-Data*-Technologien wie Hadoop und Spark für die Speicherung und Verarbeitung großer Mengen von Finanzdaten, um die Kapazität für Analysen und Entscheidungsfindung zu optimieren
- ♦ Implementieren von Tools und Techniken für die Echtzeitverarbeitung von Finanzdaten, um schnell und effektiv auf Marktschwankungen reagieren zu können
- ♦ Anwenden von *Best Practices*, um die Sicherheit und den Datenschutz von Finanzdaten zu gewährleisten und die Einhaltung von Branchenvorschriften sicherzustellen. Anwenden von *Best Practices*, um die Sicherheit und den Datenschutz von Finanzdaten zu gewährleisten und die Einhaltung von Branchenvorschriften sicherzustellen



Modul 19. Strategien für algorithmisches *Trading*

- ♦ Erwerben der notwendigen Fähigkeiten, um automatisierte *Trading*-Systeme zu entwerfen und zu entwickeln und dabei Techniken des *Machine Learning* zu integrieren, um die Effizienz und Effektivität der Operationen zu verbessern
- ♦ Lernen, *Trading*-Strategien mit fortgeschrittenen Techniken wie *Backtesting* und *Machine Learning* zu bewerten und zu optimieren, um die Performance auf den Finanzmärkten zu maximieren
- ♦ Entwickeln eines tiefgreifenden Verständnisses von Risikomanagementtechniken für das algorithmische *Trading*, um sicherzustellen, dass die Strategien sowohl profitabel als auch sicher sind

Modul 20. Ethische und regulatorische Aspekte der KI im Finanzwesen

- ♦ Erkunden der ethischen Herausforderungen, die mit dem Einsatz von künstlicher Intelligenz im Finanzwesen verbunden sind, einschließlich Transparenz, Erklärbarkeit und Fairness in Finanzmodelle
- ♦ Verstehen der globalen Vorschriften, die den Einsatz von KI auf den Finanzmärkten betreffen, und lernen, wie man Lösungen entwickelt, die diese Anforderungen erfüllen
- ♦ Fördern einer Kultur der verantwortungsvollen Entwicklung, die Praktiken integriert, die sicherstellen, dass KI-Technologien ethisch, sicher und zum Nutzen des wirtschaftlichen und sozialen Wohlergehens eingesetzt werden

03

Kompetenzen

Fachleute werden erweiterte Fähigkeiten in der Datenanalyse und -visualisierung mit Hilfe von Tools der künstlichen Intelligenz erwerben und große Mengen an Finanzinformationen genau und effizient interpretieren. Sie werden sich auch auf die Entwicklung und Umsetzung von algorithmischen Handelsstrategien spezialisieren und Investitionsentscheidungen durch *Machine-Learning*- und *Deep-Learning*-Techniken optimieren. Darüber hinaus stärken Sie Ihre Fähigkeit, Risiken und Chancen im Rahmen der Fundamentalanalyse zu bewerten sowie ethische und regulatorische Herausforderungen im Zusammenhang mit dem Einsatz von KI anzugehen.



“

Sie werden in die Lage versetzt, die digitale Transformation der Finanzmärkte anzuführen und innovative und strategische Lösungen in einem wettbewerbsintensiven Umfeld anzubieten. Mit allen Garantien der Qualität der TECH!”



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
- Entwerfen und Implementieren von algorithmischen *Trading*-Strategien mit *Machine Learning* und *Deep Learning*
- Durchführen von prädiktiven Finanzzeitreihenanalysen mit LSTM-Modellen und fortgeschrittenen KI-Techniken
- Optimieren von Anlageportfolios durch Anwendung genetischer Algorithmen, um Risiko und Rendite auszugleichen
- Erkennen und Verhindern von Finanzbetrug durch den Einsatz von Modellen der künstlichen Intelligenz und Verbesserung der Transaktionssicherheit





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
- Analysieren von Finanzberichten mit natürlicher Sprachverarbeitung (NLP), um wertvolle Erkenntnisse zu gewinnen und genaue Unternehmensbewertungen durchzuführen
- Verwalten und Verarbeiten großer Mengen von Finanzdaten mit *Big-Data*-Tools wie Hadoop und Spark
- Entwickeln und Bewerten von Strategien für das Hochfrequenz-*Trading* (HFT) und Optimieren der Geschwindigkeit und Genauigkeit der Auftragsausführung
- Anwenden von Techniken der erklärbaren künstlichen Intelligenz (XAI), um die Transparenz und das Verständnis der im Finanzwesen verwendeten Modelle zu gewährleisten
- Einhalten ethischer und regulatorischer Standards bei der Implementierung von KI im Finanzsektor, um verantwortungsvolle und rechtskonforme Praktiken zu gewährleisten
- Fortgeschrittenes Visualisieren von Finanzdaten mit Tools wie Plotly und Dash, um eine fundierte Entscheidungsfindung zu ermöglichen



Setzen Sie auf TECH! Sie werden Fähigkeiten im Umgang mit großen Datenmengen erwerben und Technologien wie Hadoop und Spark einsetzen, um Informationen effizient zu verarbeiten und zu visualisieren“

04

Kursleitung

Der Lehrkörper dieses Universitätsprogramms besteht aus renommierten Fachleuten aus dem Bereich Finanzen und Technologie. Es handelt sich um Experten mit umfangreichem Hintergrundwissen über die Anwendung von künstlicher Intelligenz auf den Finanzmärkten, die praktische und akademische Erfahrungen miteinander verbinden. So reicht ihr fundiertes Wissen von der technischen und fundamentalen Analyse bis hin zur Entwicklung von algorithmischen Handelsstrategien und dem Umgang mit *Big Data*. Darüber hinaus halten sie sich über die neuesten Trends und Entwicklungen in der Branche auf dem Laufenden, wodurch sichergestellt wird, dass die Studenten eine aktuelle und relevante Fortbildung erhalten.



“

Die Erfahrung und das Fachwissen des Lehrkörpers werden das Studium bereichern und den Absolventen wertvolle Perspektiven und Verbindungen innerhalb der globalen Finanzindustrie eröffnen"

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



Professoren

Hr. Sánchez Mansilla, Rodrigo

- *Digital Advisor* bei AI Shepherds GmbH
- *Digital Account Manager* bei Kill Draper
- *Head of Digital* bei Kuarere
- *Digital Marketing Manager* bei Arconi Solutions, Deltoid Energy und Brinery Tech
- *Founder and National Sales and Marketing Manager*
- Masterstudiengang in Digitales Marketing (MDM) von The Power Business School
- Hochschulabschluss in Business Administration (BBA) von der Universität von Buenos Aires

“Nutzen Sie die Gelegenheit, sich über die neuesten Fortschritte auf diesem Gebiet zu informieren und diese in Ihrer täglichen Praxis anzuwenden”

05

Struktur und Inhalt

Dieser akademische Abschluss bietet umfassende Inhalte, die darauf ausgerichtet sind, die Komplexität des modernen Finanzumfelds durch den fortschrittlichen Einsatz von KI-Technologien zu bewältigen. So werden sich die Experten mit der technischen und fundamentalen Analyse der Finanzmärkte befassen und *Machine-Learning*- und *Deep Learning*-Tools anwenden, um Anlageentscheidungen und Handelsstrategien zu optimieren. Sie werden auch Techniken zur Verarbeitung und Visualisierung großer Datenmengen sowie die Entwicklung und Implementierung von hochfrequenten algorithmischen Systemen behandeln.



“

Sie werden sich auf kritische Themen wie Ethik und Regulierung beim Einsatz von KI im Finanzwesen konzentrieren und werden so auf die Bewältigung ethischer und regulatorischer Herausforderungen vorbereitet. Sie profitieren von der laut Forbes besten digitalen Universität der Welt: TECH”

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

Modul 16. Technische Analyse von Finanzmärkten mit KI

- 16.1. Analyse und Visualisierung von technischen Indikatoren mit Plotly und Dash
 - 16.1.1. Implementierung von interaktiven Graphen mit Plotly
 - 16.1.2. Fortgeschrittene Visualisierung von Zeitreihen mit Matplotlib
 - 16.1.3. Erstellen von dynamischen *Dashboards* in Echtzeit mit Dash
- 16.2. Optimierung und Automatisierung von technischen Indikatoren mit Scikit-learn
 - 16.2.1. Automatisierung von Indikatoren mit Scikit-learn
 - 16.2.2. Optimierung der technischen Indikatoren
 - 16.2.3. Erstellen eigener Indikatoren mit Keras
- 16.3. Erkennung von Finanzmustern mit CNN
 - 16.3.1. Verwendung von CNN in TensorFlow zur Erkennung von Mustern in Charts
 - 16.3.2. Verbessern von Erkennungsmodellen mit Techniken des *Transfer Learning*
 - 16.3.3. Validierung von Erkennungsmodellen in Echtzeitmärkten
- 16.4. Quantitative *Trading*-Strategien mit QuantConnect
 - 16.4.1. Aufbau von algorithmischen *Trading*-Systemen mit QuantConnect
 - 16.4.2. Backtesting von Strategien mit QuantConnect
 - 16.4.3. Integration von *Machine Learning* in *Trading*-Strategien mit QuantConnect
- 16.5. Algorithmisches *Trading* mit *Reinforcement Learning* unter Verwendung von TensorFlow
 - 16.5.1. *Reinforcement Learning* für das *Trading*
 - 16.5.2. Erstellen von *Trading*-Agenten mit TensorFlow *Reinforcement Learning*
 - 16.5.3. Simulation und Abstimmung von Agenten in OpenAI Gym
- 16.6. Zeitreihenmodellierung mit LSTM in Keras für Preisprognosen
 - 16.6.1. Anwendung von LSTM für die Preisvorhersage
 - 16.6.2. Implementierung von LSTM-Modellen in Keras für finanzielle Zeitreihen
 - 16.6.3. Optimierung und Parameterabstimmung in Zeitreihenmodellen

- 16.7. Anwendung von *Explainable Artificial Intelligence* (XAI) im Finanzwesen
 - 16.7.1. Anwendung von XAI im Finanzwesen
 - 16.7.2. Anwendung von LIME für *Trading*-Modelle
 - 16.7.3. Anwendung von SHAP für die Analyse des Beitrags von Merkmalen bei KI-Entscheidungen
 - 16.8. *High-Frequency Trading* (HFT) optimiert mit *Machine-Learning*-Modellen
 - 16.8.1. Entwicklung von ML-Modellen für HFT
 - 16.8.2. Implementierung von HFT-Strategien mit TensorFlow
 - 16.8.3. Simulation und Bewertung von HFT in kontrollierten Umgebungen
 - 16.9. Volatilitätsanalyse mit *Machine Learning*
 - 16.9.1. Anwendung von intelligenten Modellen zur Vorhersage der Volatilität
 - 16.9.2. Implementierung von Volatilitätsmodellen mit PyTorch
 - 16.9.3. Integration der Volatilitätsanalyse in das Portfolio-Risikomanagement
 - 16.10. Portfolio-Optimierung mit genetischen Algorithmen
 - 16.10.1. Grundlagen der genetischen Algorithmen für die Optimierung von Investitionen auf den Märkten
 - 16.10.2. Implementierung von genetischen Algorithmen für die Portfolioauswahl
 - 16.10.3. Bewertung von Portfolio-Optimierungsstrategien
- Modul 17. Fundamentalanalyse von Finanzmärkten mit KI**
- 17.1. Prädiktive Modellierung der finanziellen Performance mit Scikit-Learn
 - 17.1.1. Lineare und logistische Regression für Finanzprognosen mit Scikit-Learn
 - 17.1.2. Verwendung neuronaler Netze mit TensorFlow zur Vorhersage von Einnahmen und Gewinnen
 - 17.1.3. Validierung von Prognosemodellen mit Kreuzvalidierung mit Scikit-Learn
 - 17.2. Bewertung von Unternehmen mit *Deep Learning*
 - 17.2.1. Automatisierung des Modells des *Discounted Cash Flow* (DCF) mit TensorFlow
 - 17.2.2. Fortgeschrittene Bewertungsmodelle mit PyTorch
 - 17.2.3. Integration und Analyse von mehreren Bewertungsmodellen mit Pandas
 - 17.3. Analyse von Finanzberichten mit NLP unter Verwendung von ChatGPT
 - 17.3.1. Extraktion von Schlüsselinformationen aus Geschäftsberichten mit ChatGPT
 - 17.3.2. Stimmungsanalyse von Analystenberichten und Finanznachrichten mit ChatGPT
 - 17.3.3. Implementierung von NLP-Modellen mit ChatGPT zur Interpretation von Finanztexten
 - 17.4. Risiko- und Kreditanalyse mit *Machine Learning*
 - 17.4.1. Kreditscoring-Modelle mit SVM und Entscheidungsbäumen in Scikit-Learn
 - 17.4.2. Kreditrisikoanalyse bei Unternehmen und Anleihen mit TensorFlow
 - 17.4.3. Visualisierung von Risikodaten mit Tableau
 - 17.5. Kreditanalyse mit Scikit-Learn
 - 17.5.1. Implementierung von Kreditscoring-Modellen
 - 17.5.2. Kreditrisikoanalyse mit RandomForest in Scikit-Learn
 - 17.5.3. Fortgeschrittene Visualisierung von Kreditscores mit Tableau
 - 17.6. ESG-Nachhaltigkeitsbewertung mit *Data-Mining*-Techniken
 - 17.6.1. ESG-*Data-Mining*-Methoden
 - 17.6.2. ESG-Auswirkungsmodellierung mit Regressionstechniken
 - 17.6.3. Anwendungen der ESG-Analyse bei Investitionsentscheidungen
 - 17.7. Sektor-Benchmarking mit künstlicher Intelligenz unter Verwendung von TensorFlow und Power BI
 - 17.7.1. Vergleichende Analyse von Unternehmen mit KI
 - 17.7.2. Prädiktive Modellierung der Sektorleistung mit TensorFlow
 - 17.7.3. Implementierung von Branchen-*Dashboards* mit Power BI
 - 17.8. Portfoliomanagement mit KI-Optimierung
 - 17.8.1. Portfolio-Optimierung
 - 17.8.2. Einsatz von Techniken des *Machine Learning* zur Portfolio-Optimierung mit Scikit-Optimize
 - 17.8.3. Implementierung und Bewertung der Effektivität von Algorithmen im Portfoliomanagement

- 17.9. Erkennung von Finanzbetrug mit KI unter Verwendung von TensorFlow und Keras
 - 17.9.1. Grundlegende Konzepte und Techniken der Betrugserkennung mit KI
 - 17.9.2. Konstruktion von Erkennungsmodellen mit neuronalen Netzen in TensorFlow
 - 17.9.3. Praktische Implementierung von Betrugserkennungssystemen bei Finanztransaktionen
- 17.10. Analyse und Modellierung bei Fusionen und Übernahmen mit KI
 - 17.10.1. Verwendung von prädiktiven KI-Modellen zur Bewertung von Fusionen und Übernahmen
 - 17.10.2. Simulation von Post-Merger-Szenarien mit Techniken des *Machine Learning*
 - 17.10.3. Bewertung der finanziellen Auswirkungen von M&A mit intelligenten Modellen

Modul 18. Verarbeitung von Finanzdaten in großem Maßstab

- 18.1. *Big Data* im Finanzkontext
 - 18.1.1. Hauptmerkmale von *Big Data* im Finanzwesen
 - 18.1.2. Die Bedeutung der 5 Vs (*Volume, Velocity, Variety, Veracity, Value*) in Finanzdaten
 - 18.1.3. Anwendungsfälle von *Big Data* in der Risiko- und Compliance-Analyse
- 18.2. Technologien für die Speicherung und Verwaltung von *Big Data* im Finanzbereich
 - 18.2.1. NoSQL-Datenbanksysteme für *Financial Warehousing*
 - 18.2.2. Einsatz von *Data Warehouses* und *Data Lakes* im Finanzsektor
 - 18.2.3. Vergleich zwischen *On-Premise*- und *Cloud*-basierten Lösungen
- 18.3. Echtzeit-Verarbeitungstools für Finanzdaten
 - 18.3.1. Einführung in Tools wie Apache Kafka und Apache Storm
 - 18.3.2. Anwendungen zur Echtzeitverarbeitung für die Betrugserkennung
 - 18.3.3. Vorteile der Echtzeitverarbeitung im algorithmischen *Trading*
- 18.4. Datenintegration und -bereinigung im Finanzwesen
 - 18.4.1. Methoden und Tools für die Integration von Daten aus verschiedenen Quellen
 - 18.4.2. Techniken zur Datenbereinigung, um Qualität und Genauigkeit zu gewährleisten
 - 18.4.3. Herausforderungen bei der Standardisierung von Finanzdaten

- 18.5. Auf die Finanzmärkte angewandte *Data-Mining*-Techniken
 - 18.5.1. Klassifizierungs- und Vorhersagealgorithmen für Marktdaten
 - 18.5.2. Stimmungsanalyse in sozialen Netzwerken zur Vorhersage von Marktbewegungen
 - 18.5.3. *Data Mining* zur Ermittlung von *Trading*-Mustern und Anlegerverhalten
- 18.6. Fortgeschrittene Datenvisualisierung für die Finanzanalyse
 - 18.6.1. Visualisierungstools und -software für Finanzdaten
 - 18.6.2. Entwurf interaktiver *Dashboards* für die Marktbeobachtung
 - 18.6.3. Die Rolle der Visualisierung bei der Vermittlung von Risikoanalysen
- 18.7. Nutzung von Hadoop und verwandten Ökosystemen im Finanzwesen
 - 18.7.1. Schlüsselkomponenten des Hadoop-Ökosystems und seine Anwendung im Finanzwesen
 - 18.7.2. Anwendungsfälle von Hadoop für die Analyse großer Transaktionsvolumina
 - 18.7.3. Vorteile und Herausforderungen der Integration von Hadoop in bestehende Finanzinfrastrukturen
- 18.8. Anwendungen von Spark in der Finanzanalyse
 - 18.8.1. Spark für die Echtzeit- und Batch-Datenanalyse
 - 18.8.2. Erstellung prädiktiver Modelle mit Spark MLlib
 - 18.8.3. Integration von Spark mit anderen *Big-Data*-Tools im Finanzwesen
- 18.9. Datensicherheit und Datenschutz im Finanzsektor
 - 18.9.1. Regeln und Vorschriften zum Datenschutz (GDPR, CCPA)
 - 18.9.2. Strategien zur Verschlüsselung und Zugriffsverwaltung für sensible Daten
 - 18.9.3. Auswirkungen von Datenschutzverletzungen auf Finanzinstitute
- 18.10. Auswirkungen von *Cloud Computing* auf groß angelegte Finanzanalysen
 - 18.10.1. Vorteile der *Cloud* für Skalierbarkeit und Effizienz in der Finanzanalyse
 - 18.10.2. Vergleich der *Cloud*-Anbieter und ihrer spezifischen Dienste für das Finanzwesen
 - 18.10.3. Fallstudien zur Migration in die *Cloud* in großen Finanzinstituten

Modul 19. Strategien für algorithmisches Trading

- 19.1. Grundlagen des algorithmischen *Tradings*
 - 19.1.1. Strategien für algorithmisches *Trading*
 - 19.1.2. Wichtigste Technologien und Plattformen für die Entwicklung von *Trading*-Algorithmen
 - 19.1.3. Vorteile und Herausforderungen des automatisierten *Tradings* gegenüber dem manuellen *Trading*
- 19.2. Design von automatisierten *Trading*-Systemen
 - 19.2.1. Struktur und Komponenten eines automatisierten *Trading*-Systems
 - 19.2.2. Algorithmenprogrammierung: von der Idee bis zur Implementierung
 - 19.2.3. Latenz und Hardware-Überlegungen in *Trading*-Systemen
- 19.3. *Backtesting* und Bewertung von *Trading*-Strategien
 - 19.3.1. Methoden für effektives *Backtesting* von algorithmischen Strategien
 - 19.3.2. Bedeutung hochwertiger historischer Daten beim *Backtesting*
 - 19.3.3. Wichtige Leistungsindikatoren für die Bewertung von *Trading*-Strategien
- 19.4. Optimierung von Strategien mit *Machine Learning*
 - 19.4.1. Anwendung von Techniken des überwachten Lernens bei der Verbesserung von Strategien
 - 19.4.2. Einsatz von Partikelschwarm-Optimierung und genetischen Algorithmen
 - 19.4.3. Herausforderungen der Überanpassung bei der Optimierung von *Trading*-Strategien
- 19.5. Hochfrequenz-*Trading* (HFT)
 - 19.5.1. Die Prinzipien und Technologien hinter HFT
 - 19.5.2. Auswirkungen von HFT auf die Marktliquidität und -volatilität
 - 19.5.3. Gängige HFT-Strategien und ihre Effektivität
- 19.6. Algorithmen zur Auftragsausführung
 - 19.6.1. Arten von Ausführungsalgorithmen und ihre praktische Anwendung
 - 19.6.2. Algorithmen zur Minimierung der Auswirkungen auf den Markt
 - 19.6.3. Einsatz von Simulationen zur Verbesserung der Auftragsausführung

- 19.7. Arbitrage-Strategien auf den Finanzmärkten
 - 19.7.1. Statistische Arbitrage und Preisfusionsarbitrage auf Märkten
 - 19.7.2. Index- und ETF-Arbitrage
 - 19.7.3. Technische und rechtliche Herausforderungen der Arbitrage im modernen *Trading*
- 19.8. Risikomanagement im algorithmischen *Trading*
 - 19.8.1. Risikomaßnahmen für das algorithmische *Trading*
 - 19.8.2. Integration von Risikolimits und Stop-Loss in Algorithmen
 - 19.8.3. Spezifische Risiken für das algorithmische *Trading* und wie sie gemindert werden können
- 19.9. Regulatorische und Compliance-Fragen im algorithmischen *Trading*
 - 19.9.1. Globale Vorschriften mit Auswirkungen auf das algorithmische *Trading*
 - 19.9.2. Einhaltung gesetzlicher Vorschriften und Berichterstattung in einer automatisierten Umgebung
 - 19.9.3. Ethische Implikationen des automatisierten *Tradings*
- 19.10. Zukunft des algorithmischen *Tradings* und neue Trends
 - 19.10.1. Einfluss der künstlichen Intelligenz auf die zukünftige Entwicklung des algorithmischen *Tradings*
 - 19.10.2. Neue *Blockchain*-Technologien und ihre Anwendung im algorithmischen *Trading*
 - 19.10.3. Trends in der Anpassungsfähigkeit und Individualisierung von *Trading*-Algorithmen

Modul 20. Ethische und regulatorische Aspekte der KI im Finanzwesen

- 20.1. Ethik in der künstlichen Intelligenz angewandt auf das Finanzwesen
 - 20.1.1. Grundlegende ethische Prinzipien für die Entwicklung und den Einsatz von KI im Finanzwesen
 - 20.1.2. Fallstudien zu ethischen Dilemmas bei KI-Anwendungen im Finanzbereich
 - 20.1.3. Entwicklung von ethischen Verhaltenskodizes für Fachleute der Finanztechnologie
- 20.2. Globale Regelungen, die den Einsatz von KI auf den Finanzmärkten beeinflussen
 - 20.2.1. Überblick über die wichtigsten internationalen KI-Vorschriften im Finanzbereich
 - 20.2.2. Vergleich der KI-Regulierungspolitik in verschiedenen Ländern
 - 20.2.3. Auswirkungen der KI-Regulierung auf die Finanzinnovation

- 20.3. Transparenz und Erklärbarkeit von KI-Modellen im Finanzwesen
 - 20.3.1. Bedeutung von Transparenz in KI-Algorithmen für das Vertrauen der Nutzer
 - 20.3.2. Techniken und Werkzeuge zur Verbesserung der Erklärbarkeit von KI-Modellen
 - 20.3.3. Herausforderungen bei der Implementierung interpretierbarer Modelle in komplexen Finanzumgebungen
- 20.4. Risikomanagement und ethische Compliance bei der Nutzung von KI
 - 20.4.1. Strategien zur Risikominderung im Zusammenhang mit dem Einsatz von KI im Finanzwesen
 - 20.4.2. Ethische Compliance bei der Entwicklung und Anwendung von KI-Technologien
 - 20.4.3. Ethische Aufsicht und Audits von KI-Systemen im Finanzbereich
- 20.5. Soziale und wirtschaftliche Auswirkungen von KI auf die Finanzmärkte
 - 20.5.1. Auswirkungen von KI auf die Stabilität und Effizienz der Finanzmärkte
 - 20.5.2. KI und ihre Auswirkungen auf Beschäftigung und Qualifikation im Finanzwesen
 - 20.5.3. Sozialer Nutzen und Risiken einer groß angelegten Finanzautomatisierung
- 20.6. Datenschutz und -sicherheit bei KI-Anwendungen im Finanzbereich
 - 20.6.1. Datenschutzbestimmungen, die für KI-Technologien im Finanzwesen gelten
 - 20.6.2. Techniken zum Schutz persönlicher Daten in KI-basierten Finanzsystemen
 - 20.6.3. Herausforderungen bei der Verwaltung sensibler Daten in der prädiktiven und analytischen Modellierung
- 20.7. Algorithmische Verzerrungen und Fairness in KI-Finanzmodellen
 - 20.7.1. Identifizierung und Milderung von Verzerrungen in KI-Finanzalgorithmen
 - 20.7.2. Strategien zur Gewährleistung von Fairness in automatisierten Entscheidungsmodellen
 - 20.7.3. Auswirkungen algorithmischer Verzerrungen auf finanzielle Inklusion und finanzielle Gerechtigkeit
- 20.8. Herausforderungen der regulatorischen Aufsicht in der Finanz-KI
 - 20.8.1. Schwierigkeiten bei der Überwachung und Kontrolle fortgeschrittener KI-Technologien
 - 20.8.2. Rolle der Finanzbehörden bei der laufenden Überwachung von KI
 - 20.8.3. Notwendigkeit einer regulatorischen Anpassung angesichts der fortschreitenden KI-Technologie
- 20.9. Strategien für die verantwortungsvolle Entwicklung von KI-Technologien im Finanzwesen
 - 20.9.1. *Best Practices* für eine nachhaltige und verantwortungsvolle Entwicklung von KI im Finanzsektor
 - 20.9.2. Initiativen und *Frameworks* für die ethische Bewertung von KI-Projekten im Finanzwesen
 - 20.9.3. Zusammenarbeit zwischen Regulierungsbehörden und Unternehmen zur Förderung verantwortungsvoller Praktiken
- 20.10. Zukunft der KI-Regulierung im Finanzsektor
 - 20.10.1. Aufkommende Trends und zukünftige Herausforderungen bei der Regulierung von KI im Finanzwesen
 - 20.10.2. Vorbereitung der rechtlichen Rahmenbedingungen für disruptive Innovationen in der Finanztechnologie
 - 20.10.3. Internationaler Dialog und Zusammenarbeit für eine effektive und einheitliche Regulierung von KI im Finanzwesen



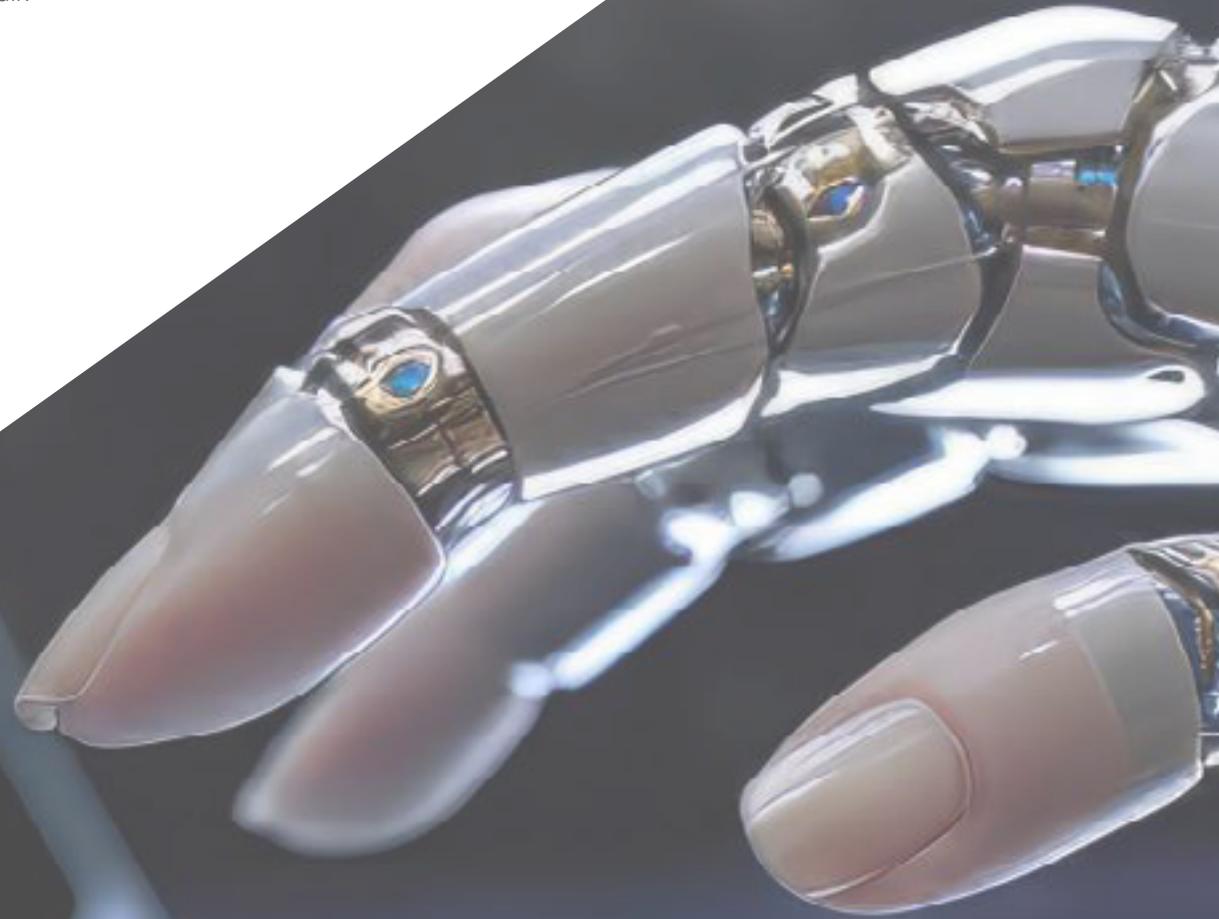
Sie erhalten eine solide, aktuelle Fortbildung, die fortschrittliche Theorie mit praktischen Anwendungen kombiniert, um an der Schnittstelle von künstlicher Intelligenz und Finanzen führend zu sein"

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.

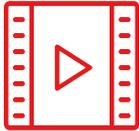
Das Relearning ermöglicht es Ihnen, mit weniger Aufwand und mehr Leistung zu lernen, sich mehr auf Ihre Spezialisierung einzulassen, einen kritischen Geist zu entwickeln, Argumente zu verteidigen und Meinungen zu kontrastieren: eine direkte Gleichung zum Erfolg.

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.



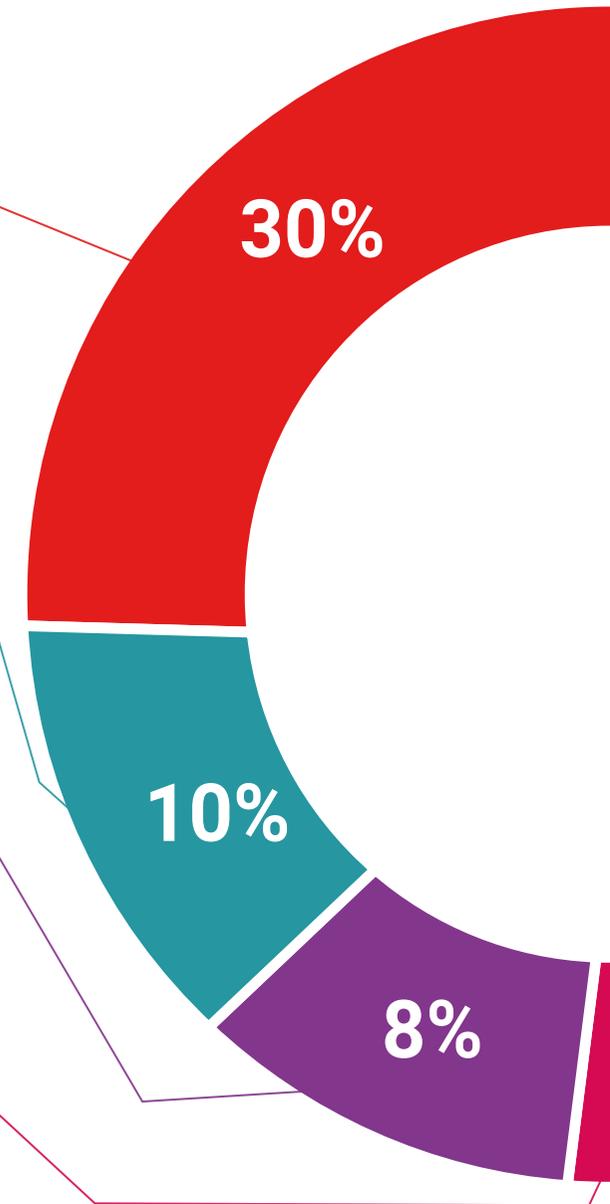
Übungen für Fertigkeiten und Kompetenzen

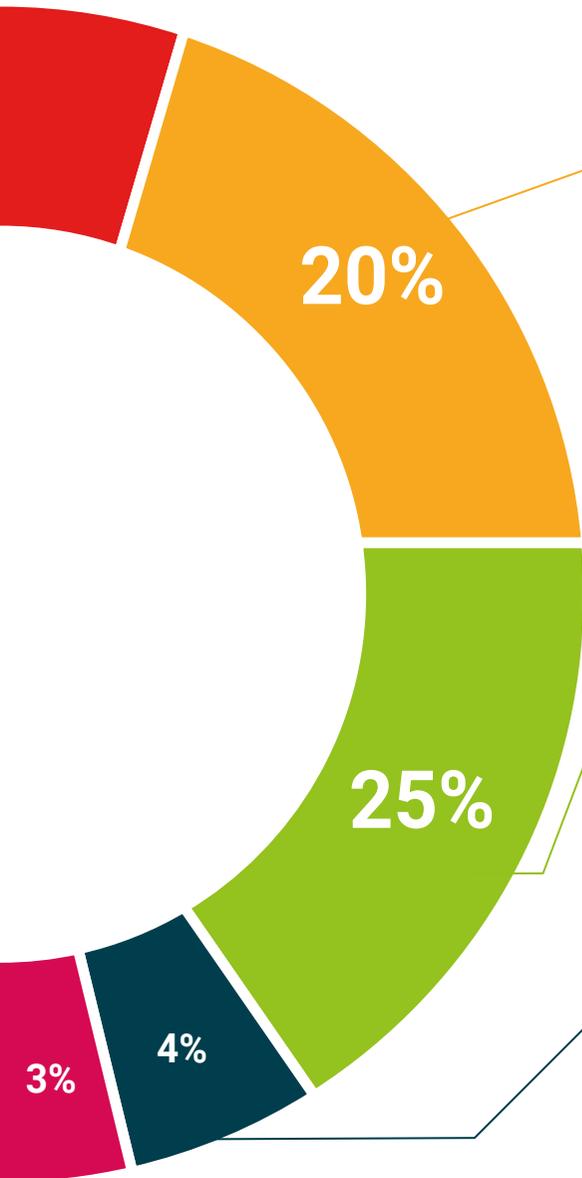
Sie werden Aktivitäten durchführen, um spezifische Kompetenzen und Fertigkeiten in jedem Fachbereich zu entwickeln. Übungen und Aktivitäten zum Erwerb und zur Entwicklung der Fähigkeiten und Fertigkeiten, die ein Spezialist im Rahmen der Globalisierung, in der wir leben, entwickeln muss.



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 Privater Masterstudiengang in Künstliche Intelligenz in Börsen und Finanzmärkten 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 in Börsen und Finanzmärkten** 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**.

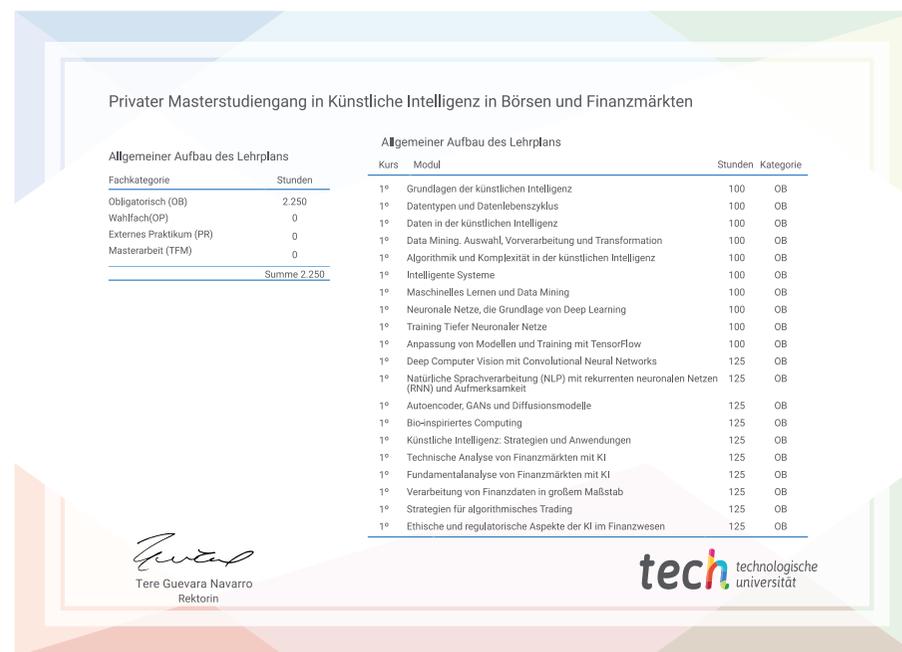


Das von **TECH Technologische Universität** ausgestellte Diplom drückt die erworbene Qualifikation aus und entspricht den Anforderungen, die in der Regel von Stellenbörsen, Auswahlprüfungen und Berufsbildungsausschüssen verlangt werden.

Titel: **Universitätskurs in Dermatologische Phytotherapie für die Krankenpflege**

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 tutoeren
garantie akkreditierung unterricht
institutionen technologie lernen
gemeinschaft verpflichtung
persönliche betreuung innovationen
wissen gegenwart qualität
online-Ausbildung
entwicklung institutionen
virtuelles Klassenzimmer

tech technologische
universität

Privater Masterstudiengang
Künstliche Intelligenz in Börsen
und Finanzmärkten

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

Privater Masterstudiengang Künstliche Intelligenz in Börsen und Finanzmärkten

