

# Privater Masterstudiengang Künstliche Intelligenz in der Finanzabteilung



## Privater Masterstudiengang Künstliche Intelligenz in der Finanzabteilung

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

Internetzugang: [www.techtitute.com/de/kunstliche-intelligenz/masterstudiengang/masterstudiengang-kunstliche-intelligenz-finanzabteilung](http://www.techtitute.com/de/kunstliche-intelligenz/masterstudiengang/masterstudiengang-kunstliche-intelligenz-finanzabteilung)

# 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 revolutioniert den Finanzsektor und verändert die Art und Weise, wie Unternehmen ihre strategischen Operationen verwalten. Dieses Tool bietet Fachleuten zahlreiche Vorteile wie die Möglichkeit, komplexe Prozesse zu automatisieren, vorausschauende Analysen durchzuführen und das Risikomanagement zu optimieren. Allerdings kann die Implementierung von Tools wie *Deep Neural Networks*, *Deep Learning* oder bio-inspiriertes Computing aufgrund ihrer technischen Komplexität für Experten eine Herausforderung darstellen. Um diese Aufgabe zu erleichtern, präsentiert TECH einen hochmodernen Universitätsabschluss, der CFOs die Schlüssel zur effizienten Leitung dieser digitalen Transformation an die Hand gibt. Dieser Studiengang wird zu 100% online angeboten, so dass die Studenten ihren Zeitplan individuell gestalten können.





“

*Dank dieses 100%igen Online-Programms werden Sie das Beste aus Big Data herausholen und Trends analysieren, die die Leistung von Finanzanlagen beeinflussen“*

Laut einer Studie der International Finance Association ist es 70% der Unternehmen, die Lösungen der künstlichen Intelligenz einsetzen, gelungen, die Genauigkeit ihrer wirtschaftlichen Analysen zu verbessern und die Verwaltung ihrer Portfolios zu optimieren. Angesichts dieser Realität fordern immer mehr Unternehmen die Einstellung von Fachleuten, die geschickt mit neuen Tools wie *Big Data*, *Natural Language Processing* oder *Convolutional Neural Networks* umgehen können, um fundiertere strategische Entscheidungen zu treffen und das finanzielle Risikomanagement zu verbessern. Um diese Karrierechancen nutzen zu können, müssen Experten einen Wettbewerbsvorteil haben, der sie von anderen Kandidaten unterscheidet.

Vor diesem Hintergrund führt TECH ein revolutionäres Programm in Künstliche Intelligenz in der Finanzabteilung ein. Der Studiengang wurde von renommierten Experten auf diesem Gebiet entwickelt und wird Fachleuten fortgeschrittene Fähigkeiten im Umgang mit fortschrittlichen Tools vermitteln, die von *Data Mining* oder *Deep Computer Vision* bis hin zu rekurrenten neuronalen Netzwerkmodellen reichen. Auf diese Weise werden die Absolventen hochqualifiziert sein, um prädiktive Modelle im Finanzrisikomanagement einzusetzen, mühsame Aufgaben wie das Kassenmanagement zu optimieren und sogar andere Prozesse wie interne Audits zu automatisieren. Darüber hinaus wird das Lehrmaterial einen detaillierten Einblick in die innovativsten Methoden zur Optimierung verschiedener Anlageportfolios geben. Darüber hinaus bietet der Lehrplan fortgeschrittene Tools für die Gestaltung komplexer wirtschaftlicher Datenvisualisierungen mit Google Data Studio.

Außerdem basiert der Studiengang auf der revolutionären *Relearning*-Methode, die von TECH gefördert wird. Dabei handelt es sich um ein Lernsystem, das aus der schrittweisen Wiederholung der wichtigsten Aspekte besteht, wodurch sichergestellt wird, dass die wesentlichen Konzepte des Lehrplans im Gedächtnis der Absolventen bleiben. Darüber hinaus kann der Student seinen Lehrplan individuell gestalten, da es keine festen Zeit- oder Bewertungspläne gibt. In diesem Sinne wird der virtuelle Campus 24 Stunden am Tag zur Verfügung stehen und es den Fachleuten ermöglichen, die Materialien herunterzuladen und sie zu konsultieren, wann immer sie wollen.

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

- Die Entwicklung von Fallstudien, die von Experten für künstliche Intelligenz vorgestellt werden
- Der anschauliche, schematische und äußerst praxisnahe Inhalt vermittelt alle für die berufliche Praxis unverzichtbaren praktischen Informationen
- Praktische Übungen, anhand derer der Selbstbewertungsprozess zur Verbesserung des Lernens verwendet 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



*Mit Hilfe von Multimedia-Ressourcen in Form von interaktiven Zusammenfassungen, Erklärungsvideos und Fachlektüre werden Sie Ihr Potenzial im Bereich Finanzmanagement voll ausschöpfen"*

“

*Möchten Sie die innovativsten Techniken der natürlichen Sprachverarbeitung in Ihre tägliche Praxis einbeziehen? Mit diesem Universitätsabschluss schaffen Sie das in weniger als einem Jahr“*

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 effizient Machine-Learning-Modelle trainieren, die es Ihnen ermöglichen, verschiedene potenzielle finanzielle Risiken vorherzusehen.*

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



# 02 Ziele

Durch diesen privaten Masterstudiengang werden sich Fachleute durch ihr solides Wissen über die Implementierung von künstlicher Intelligenz in Finanzverfahren auszeichnen. Ebenso werden die Studenten fortgeschrittene Fähigkeiten erwerben, um Vorhersagemodelle zu betreiben, die ein proaktives Risikomanagement und eine genauere Finanzplanung ermöglichen. Darüber hinaus werden die Experten in der Lage sein, Lösungen zur Automatisierung von Roboterprozessen zu implementieren, um sich wiederholende Aufgaben wie Buchhaltung, Treasury Management und interne Audits zu optimieren. Darüber hinaus werden die Studenten sicherstellen, dass diese technologischen Werkzeuge den gesetzlichen Vorschriften entsprechen und somit die Sicherheit der Finanzdaten schützen.





“

*Sie werden die aufkommende Technik des Data Mining beherrschen und zu einer evidenzbasierten finanziellen Entscheidungsfindung beitragen“*



## Allgemeine Ziele

---

- Anwenden von Techniken der künstlichen Intelligenz in der finanziellen Entscheidungsfindung
- Entwickeln von Vorhersagemodellen für das finanzielle Risikomanagement
- Optimieren der Zuweisung von Finanzressourcen mithilfe von KI-Algorithmen
- Automatisierung von Routineprozessen im Finanzbereich durch maschinelles Lernen
- Implementieren von Tools zur Verarbeitung natürlicher Sprache für die Analyse von Finanzdaten
- Entwickeln von Empfehlungssystemen für den Finanzsektor
- Analysieren großer Mengen von Finanzdaten mithilfe von *Big-Data*-Techniken
- Bewerten der Auswirkungen von künstlicher Intelligenz auf die Rentabilität von Unternehmen
- Verbessern der Erkennung von Finanzbetrug durch den Einsatz von KI
- Erstellen von Modellen zur Bewertung von Finanzanlagen mithilfe von künstlicher Intelligenz
- Entwickeln von Finanzsimulationstools auf der Grundlage von KI-Algorithmen
- Anwenden von Data-Mining-Techniken zur Identifizierung finanzieller Muster
- Entwickeln von Optimierungsmodellen für die Finanzplanung
- Nutzen neuronaler Netzwerke zur besseren Vorhersage von Markttrends
- Entwickeln von KI-basierten Lösungen für die Personalisierung von Finanzprodukten
- Implementieren von KI-Systemen für automatisierte Investitionsentscheidungen
- Entwickeln analytischer Fähigkeiten zur Interpretation der Ergebnisse von finanziellen KI-Modellen
- Untersuchen des Einsatzes von künstlicher Intelligenz in der Finanzregulierung und Compliance
- Entwickeln von KI-Lösungen zur Kostensenkung bei Finanzprozessen
- Identifizieren von Möglichkeiten für KI-gestützte Innovationen im Finanzsektor





## 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
- ♦ Verwalten von Automatisierungslösungen, die künstliche Intelligenz nutzen, um die Effizienz bei wichtigen Aufgaben wie der Rechnungsbearbeitung, dem Bankabgleich oder der Bestandsverwaltung zu optimieren
- ♦ Handhaben von Tools wie *TensorFlow* und *Scikit-Learn* zur Unterstützung bei der strategischen Entscheidungsfindung
- ♦ Entwickeln fortgeschrittener Fähigkeiten in der explorativen Analyse von Finanzdaten und der Erstellung von Visualisierungen mit Tools wie *Google Data Studio*
- ♦ Anführen der digitalen Transformation in Finanzunternehmen, um deren operative Leistung zu steigern und das Risikomanagement, z. B. bei der Liquidität, zu verbessern

### 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 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, 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
- ♦ Kennenlernen 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. Automatisierung der Prozesse der Finanzabteilung mit künstlicher Intelligenz

- ♦ Beherrschen der Automatisierung von Finanzprozessen mit Robotic Process Automation, um die Genauigkeit bei Aufgaben wie der Rechnungsbearbeitung zu optimieren
- ♦ Anwenden von *Deep-Learning*-Techniken zur Verbesserung von Liquidität und Betriebskapital
- ♦ Erstellen von automatisierten Finanzberichten mit Power Bi, um die Geschwindigkeit der Berichtserstellung zu erhöhen
- ♦ Implementieren von Systemen, die menschliche Fehler bei der Verarbeitung von Finanzdaten minimieren und so die Zuverlässigkeit von Finanzinformationen erhöhen

### Modul 17. Strategische Planung und Entscheidungsfindung mit künstlicher Intelligenz

- ♦ Verwenden des prädiktiven Modells von Scikit-Learn für die strategische Planung und datengestützte finanzielle Entscheidungsfindung
- ♦ Handhaben von *TensorFlow* zur Entwicklung von Marktstrategien auf der Grundlage von künstlicher Intelligenz, um die Wettbewerbsfähigkeit und Anpassungsfähigkeit von Unternehmen in einem dynamischen Finanzumfeld zu erhöhen

### Modul 18. Fortgeschrittene finanzielle Optimierungstechniken mit OR-Tools

- ♦ Beherrschen von Techniken zur Optimierung von Anlageportfolios durch lineare, nichtlineare und stochastische Programmierung zur Verbesserung von Finanzportfolios
- ♦ Anwenden von genetischen Algorithmen bei der Finanzoptimierung und Erforschung innovativer Lösungen für komplexe Probleme







### **Modul 19. Analyse und Visualisierung von Finanzdaten mit Plotly und Google Data Studio**

- ♦ Entwickeln fortgeschrittener Fähigkeiten zur Verwendung von Tools wie Google Data Studio, um interaktive Visualisierungen zu erstellen, die die Vermittlung von finanziellen *Insights* erleichtern
- ♦ Genaues Analysieren von finanziellen Zeitreihen und Erkennen von historischen Trends und wiederkehrenden Mustern

### **Modul 20. Künstliche Intelligenz für das finanzielle Risikomanagement mit TensorFlow und Scikit-learn**

- ♦ Implementieren modernster Kredit-, Markt- und Liquiditätsrisikomodelle unter Verwendung von *Machine Learning*
- ♦ Durchführen von Simulationstechniken, um die Auswirkungen von Finanzrisiken in verschiedenen Szenarien zu bewerten und zu verwalten

# 03

# Kompetenzen

Nach Abschluss dieses Studiums verfügen die Experten über fortgeschrittene Fähigkeiten zur Anwendung von Tools der künstlichen Intelligenz bei der Automatisierung oder Optimierung von Finanzprozessen. In diesem Sinne werden Fachleute prädiktive Modelle nutzen, um Trends zu antizipieren, Risiken zu managen und die Verwaltung wirtschaftlicher Ressourcen zu verbessern. Des Weiteren werden die Absolventen Lösungen implementieren, die die manuelle Arbeit in Organisationen reduzieren und gleichzeitig die Leistung in Schlüsselbereichen wie Buchhaltung, Finanzmanagement und interne Revision steigern. Die Studenten werden auch hochqualifiziert sein, um Forschungsprojekte zu leiten, die die Weiterentwicklung neuer Methoden zur Verbesserung von Finanzprozessen vorantreiben.



“

*Sie werden die digitale Transformation in Unternehmen anführen und die effektivsten Strategien entwickeln, um die Finanzprozesse deutlich zu optimieren“*



## Allgemeine Kompetenzen

---

- Erwerben fortgeschrittener Fähigkeiten zur Integration von Techniken der künstlichen Intelligenz in die Automatisierung und Optimierung von Finanzprozessen, um die strategische Entscheidungsfindung zu unterstützen
- Analysieren großer Mengen von Finanzdaten mithilfe von Algorithmen, um Prognosen zu erstellen, Trends zu erkennen und finanzielle Risiken zu mindern
- Entwerfen und Implementieren von Systemen zur Automatisierung von Routineaufgaben wie Buchhaltung, Rechnungsprüfung oder Risikomanagement
- Sicherstellen, dass die Lösungen für künstliche Intelligenz mit den geltenden Vorschriften übereinstimmen und gleichzeitig ethische und datenschutzrechtliche Fragen bei der Nutzung von Finanzdaten berücksichtigen





## Spezifische Kompetenzen

---

- Trainieren von *Machine-Learning*-Modellen wie neuronalen Netzen und Klassifizierungsalgorithmen, um Investitionen erheblich zu optimieren
- Erstellen von auf künstlicher Intelligenz basierenden Systemen, die ungewöhnliche Muster in Finanztransaktionen erkennen, um Betrug und andere illegale Aktivitäten in Echtzeit zu verhindern
- Anwenden prädiktiver Finanzanalysetechniken, um *Cashflows* zu prognostizieren, Vermögenswerte zu bewerten und die Rentabilität von Investitionsprojekten zu beurteilen
- Integrieren neuer Automatisierungstechnologien für eine optimale Rechnungsverwaltung



*Die spezialisierte Lektüre, die Sie im virtuellen Campus finden, wird es Ihnen ermöglichen, die fundierten Informationen, die in diesem exklusiven akademischen Angebot enthalten sind, weiter zu vertiefen"*

# 04

## Kursleitung

Die oberste Prämisse von TECH ist es, die vollständigsten und aktuellsten Hochschulprogramme auf dem Bildungsmarkt für jedermann zugänglich zu machen. Um dies zu erreichen, werden die Lehrkräfte in einem sorgfältigen Verfahren ausgewählt. Dank dieser Bemühungen verfügt dieser private Masterstudiengang über die Mitarbeit hochqualifizierter Experten für den Einsatz künstlicher Intelligenz in Finanzabteilungen. Auf diese Weise erhalten die Studenten Zugang zu einer tiefgreifenden Erfahrung, die ihnen einen bedeutenden Qualitätssprung in ihrer beruflichen Laufbahn als Finanzdirektoren ermöglichen wird.



“

*Ein erfahrenes Lehrteam, bestehend aus Experten für den Einsatz von künstlicher Intelligenz im Finanzbereich, wird Sie während des gesamten Lernprozesses begleiten und alle aufkommenden Zweifel ausräumen“*

## 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

### Dr. Carrasco Aguilar, Álvaro

- ♦ *Sales & Marketing Coordinator* bei LionLingo
- ♦ Forscher im Bereich Information Technology Management
- ♦ Promotion in Sozial- und Gesundheitsforschung: Technische und wirtschaftliche Bewertung von Technologien, Interventionen und Maßnahmen zur Verbesserung der Gesundheit an der Universität von Castilla La Mancha
- ♦ Masterstudiengang in Sozial- und Gesundheitsforschung an der Universität von Castilla La Mancha
- ♦ Hochschulabschluss in Politikwissenschaft und Verwaltung an der Universität von Granada
- ♦ Preis für den „Besten wissenschaftlichen Artikel zur technologischen Innovation für die Effizienz der Gesundheitsausgaben“
- ♦ Regelmäßiger Redner auf internationalen wissenschaftlichen Konferenzen

“ *Eine einzigartige, wichtige und entscheidende Fortbildungserfahrung, die Ihre berufliche Entwicklung fördert* ”

# 05

# Struktur und Inhalt

In diesem Studiengang werden Fachleute mit den wichtigsten Werkzeugen der künstlichen Intelligenz umgehen, um Finanzprozesse zu optimieren und strategische Entscheidungen zu verbessern. Der Lehrplan befasst sich mit Aspekten wie dem Lebenszyklus von Daten, Algorithmen und dem Training von tiefen neuronalen Netzen. Die Absolventen werden in die Lage versetzt, Vorhersagemodelle zu nutzen, um finanzielle Risiken zu managen, die Planung bei Aufgaben wie dem Treasury Management zu verbessern und Revisionsaufgaben zu automatisieren. Der Lehrplan bietet auch moderne Techniken zur Optimierung von Anlageportfolios und zur Visualisierung komplexer Wirtschaftsdaten mit Google Data Studio.





“

*Sie werden Automatisierungslösungen entwerfen, die die Effizienz bei wichtigen Aufgaben wie Buchhaltung, Treasury Management und interner Revision erhöhen"*

## 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. *Fine Tuning* 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 *tfdata*-API
  - 10.6.1. Verwendung der *tfdata*-API für die Datenverarbeitung
  - 10.6.2. Konstruktion von Datenströmen mit *tfdata*
  - 10.6.3. Verwendung der *tfdata*-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. Erstellen 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*-Netzwerks 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. Automatisierung der Prozesse der Finanzabteilung mit künstlicher Intelligenz

- 16.1. Automatisierung von Finanzprozessen mit künstlicher Intelligenz und Robotic Process Automation (RPA)
  - 16.1.1. KI und RPA zur Automatisierung und Robotisierung von Prozessen
  - 16.1.2. RPA-Plattformen für Finanzprozesse: UiPath, Blue Prism und Automation Anywhere
  - 16.1.3. Bewertung von RPA-Anwendungsfällen im Finanzwesen und erwarteter ROI
- 16.2. Automatisierte Rechnungsverarbeitung mit KI mit Kofax
  - 16.2.1. Konfiguration von KI-Lösungen für die Rechnungsverarbeitung mit Kofax
  - 16.2.2. Anwendung von *Machine-Learning*-Techniken zur Rechnungsklassifizierung
  - 16.2.3. Automatisierung des Kreditorenbuchhaltungszyklus mit KI-Technologien
- 16.3. Zahlungsautomatisierung mit KI-Plattformen
  - 16.3.1. Implementierung von automatisierten Zahlungssystemen mit Stripe Radar und KI
  - 16.3.2. Einsatz von prädiktiven KI-Modellen für effizientes Kassenmanagement
  - 16.3.3. Sicherheit in automatisierten Zahlungssystemen: Betrugsprävention mit KI
- 16.4. Bankabstimmung mit KI und *Machine Learning*
  - 16.4.1. Automatisierung der Bankabstimmung mithilfe von KI mit Plattformen wie Xero
  - 16.4.2. Implementierung von Machine-Learning-Algorithmen zur Verbesserung der Genauigkeit
  - 16.4.3. Fallstudien: Effizienzverbesserungen und Fehlerreduzierung
- 16.5. *Cashflow*-Management mit *Deep Learning* und *TensorFlow*
  - 16.5.1. Prädiktive *Cashflow*-Modellierung mit LSTM-Netzen unter Verwendung von *TensorFlow*
  - 16.5.2. Implementierung von LSTM-Modellen in Python für Finanzprognosen
  - 16.5.3. Integration von prädiktiven Modellen in Finanzplanungstools
- 16.6. Bestandsautomatisierung mit Predictive Analytics
  - 16.6.1. Einsatz von prädiktiven Techniken zur Optimierung der Bestandsverwaltung
  - 16.6.2. Anwendung von prädiktiven Modellen mit Microsoft Azure *Machine Learning*
  - 16.6.3. Integration von Bestandsverwaltungssystemen mit ERP
- 16.7. Erstellung von automatisierten Finanzberichten mit Power BI
  - 16.7.1. Automatisierung der Erstellung von Finanzberichten mit Power BI
  - 16.7.2. Entwicklung von dynamischen *Dashboards* für die Finanzanalyse in Echtzeit
  - 16.7.3. Fallstudien über Verbesserungen bei der finanziellen Entscheidungsfindung mit automatisierter Berichterstattung

- 16.8. Optimierung der Beschaffung mit IBM Watson
  - 16.8.1. Prädiktive Analysen zur Einkaufsoptimierung mit IBM Watson
  - 16.8.2. KI-Modelle für Verhandlungen und Preisgestaltung
  - 16.8.3. Integration von KI-Empfehlungen in Beschaffungsplattformen
- 16.9. Kundenservice mit Finanz-*Chatbots* und Google DialogFlow
  - 16.9.1. Implementierung von Finanz-*Chatbots* mit Google Dialogflow
  - 16.9.2. Integration von *Chatbots* in CRM-Plattformen für die Finanzbetreuung
  - 16.9.3. Kontinuierliche Verbesserung von *Chatbots* auf der Grundlage von Benutzerfeedback
- 16.10. KI-unterstützte Finanzprüfung
  - 16.10.1. KI-Anwendungen in der internen Prüfung: Analyse von Transaktionen
  - 16.10.2. Implementierung von KI für die Ordnungsmäßigkeitsprüfung und die Aufdeckung von Diskrepanzen
  - 16.10.3. Verbesserungen der Prüfungseffizienz mit KI-Technologien

## Modul 17. Strategische Planung und Entscheidungsfindung mit künstlicher Intelligenz

- 17.1. Prädiktive Modellierung für die strategische Planung mit Scikit-Learn
  - 17.1.1. Erstellung prädiktiver Modelle mit Python und Scikit-Learn
  - 17.1.2. Anwendung der Regressionsanalyse bei der Projektbewertung
  - 17.1.3. Validierung von Vorhersagemodellen mit Kreuzvalidierungstechniken in Python
- 17.2. Szenario-Analyse mit Monte-Carlo-Simulationen
  - 17.2.1. Implementierung von Monte-Carlo-Simulationen mit Python für die Risikoanalyse
  - 17.2.2. Einsatz von KI für die Automatisierung und Verbesserung von Szenariosimulationen
  - 17.2.3. Interpretation und Anwendung der Ergebnisse für die strategische Entscheidungsfindung
- 17.3. Investitionsbeurteilung mit KI
  - 17.3.1. KI-Techniken für die Bewertung von Vermögenswerten und Unternehmen
  - 17.3.2. *Machine-Learning*-Modelle für die Wertbestimmung mit Python
  - 17.3.3. Fallanalyse: Einsatz von KI bei der Bewertung von Technologie-Start-ups
- 17.4. Optimierung von Fusionen und Übernahmen mit *Machine Learning* und *TensorFlow*
  - 17.4.1. Prädiktive Modellierung zur Bewertung von M&A-Synergien mit *TensorFlow*
  - 17.4.2. Simulation von Post-M&A-Integrationen mit KI-Modellen
  - 17.4.3. Verwendung von NLP für die automatisierte Due-Diligence-Analyse





- 17.5. Portfoliomanagement mit genetischen Algorithmen
  - 17.5.1. Einsatz von genetischen Algorithmen zur Portfolio-Optimierung
  - 17.5.2. Implementierung von Auswahl- und Allokationsstrategien mit Python
  - 17.5.3. Analyse der Effektivität von KI-optimierten Portfolios
- 17.6. Künstliche Intelligenz für die Nachfolgeplanung
  - 17.6.1. Einsatz von KI zur Identifizierung und Entwicklung von Talenten
  - 17.6.2. Vorhersagemodelle für die Nachfolgeplanung mit Python
  - 17.6.3. Verbesserungen im Änderungsmanagement durch die Integration von KI
- 17.7. Entwicklung von Marktstrategien mit KI und *TensorFlow*
  - 17.7.1. Anwendung von *Deep-Learning*-Techniken für die Marktanalyse
  - 17.7.2. Verwendung von *TensorFlow* und *Keras* für die Modellierung von Markttrends
  - 17.7.3. Entwicklung von Markteintrittsstrategien auf der Grundlage von *KI-Insights*
- 17.8. Konkurrenzfähigkeit und Wettbewerbsanalyse mit KI und IBM Watson
  - 17.8.1. Wettbewerbsbeobachtung mit NLP und *Machine Learning*
  - 17.8.2. Automatisierte Wettbewerbsanalyse mit IBM Watson
  - 17.8.3. Umsetzung von Wettbewerbsstrategien aus der KI-Analyse
- 17.9. KI-unterstützte strategische Verhandlungen
  - 17.9.1. Anwendung von KI-Modellen bei der Vorbereitung von Verhandlungen
  - 17.9.2. Einsatz von KI-basierten Verhandlungssimulatoren zum Training
  - 17.9.3. Bewertung der Auswirkungen von KI auf die Verhandlungsergebnisse
- 17.10. Umsetzung von KI-Projekten in der Finanzstrategie
  - 17.10.1. Planung und Verwaltung von KI-Projekten
  - 17.10.2. Verwendung von Projektmanagement-Tools wie Microsoft Project
  - 17.10.3. Präsentation von Fallstudien und Analyse von Erfolg und Lernprozess

## Modul 18. Fortgeschrittene finanzielle Optimierungstechniken mit OR-Tools

- 18.1. Einführung in die Finanzoptimierung
  - 18.1.1. Grundlegende Konzepte der Optimierung
  - 18.1.2. Optimierungswerkzeuge und -techniken im Finanzwesen
  - 18.1.3. Anwendungen der Optimierung im Finanzwesen
- 18.2. Optimierung von Anlageportfolios
  - 18.2.1. Markowitz-Modelle zur Portfolio-Optimierung
  - 18.2.2. Eingeschränkte Portfolio-Optimierung
  - 18.2.3. Implementierung von Optimierungsmodellen mit OR-Tools in Python

- 18.3. Genetische Algorithmen im Finanzwesen
  - 18.3.1. Einführung in genetische Algorithmen
  - 18.3.2. Anwendung von genetischen Algorithmen in der Finanzoptimierung
  - 18.3.3. Praktische Beispiele und Fallstudien
- 18.4. Lineare und nichtlineare Programmierung im Finanzwesen
  - 18.4.1. Grundlagen der linearen und nichtlinearen Programmierung
  - 18.4.2. Anwendungen im Portfoliomanagement und in der Ressourcenoptimierung
  - 18.4.3. Werkzeuge zur Lösung von Problemen der linearen Programmierung
- 18.5. Stochastische Optimierung im Finanzwesen
  - 18.5.1. Konzepte der stochastischen Optimierung
  - 18.5.2. Anwendungen im Risikomanagement und bei Finanzderivaten
  - 18.5.3. Stochastische Optimierungsmodelle und -techniken
- 18.6. Robuste Optimierung und ihre Anwendung im Finanzwesen
  - 18.6.1. Grundlagen der robusten Optimierung
  - 18.6.2. Anwendungen in unsicheren Finanzumgebungen
  - 18.6.3. Fallstudien und Beispiele für robuste Optimierung
- 18.7. Mehrzieloptimierung im Finanzwesen
  - 18.7.1. Einführung in die Mehrzieloptimierung
  - 18.7.2. Anwendungen in der Diversifizierung und Vermögensallokation
  - 18.7.3. Techniken und Werkzeuge für die Mehrzieloptimierung
- 18.8. *Machine Learning* für die Finanzoptimierung
  - 18.8.1.1. Anwendung von *Machine-Learning*-Techniken in der Optimierung
  - 18.8.1.2. Optimierungsalgorithmen auf der Grundlage von *Machine Learning*
  - 18.8.1.3. Implementierung und Fallstudien
- 18.9. Optimierungswerkzeuge in Python und OR-Tools
  - 18.9.1. Python Optimierungswerkzeuge und Bibliotheken (SciPy, OR-Tools)
  - 18.9.2. Praktische Umsetzung von Optimierungsproblemen
  - 18.9.3. Beispiele für Finanzanwendungen

- 18.10. Projekte und praktische Anwendungen der Finanzoptimierung
  - 18.10.1. Entwicklung von Projekten zur Finanzoptimierung
  - 18.10.2. Umsetzung von Optimierungslösungen im Finanzsektor
  - 18.10.3. Auswertung und Präsentation der Projektergebnisse

## Modul 19. Analyse und Visualisierung von Finanzdaten mit Plotly und Google Data Studio

- 19.1. Grundlagen der Analyse von Finanzdaten
  - 19.1.1. Einführung in die Datenanalyse
  - 19.1.2. Werkzeuge und Techniken für die Analyse von Finanzdaten
  - 19.1.3. Bedeutung der Datenanalyse im Finanzwesen
- 19.2. Techniken für die explorative Analyse von Finanzdaten
  - 19.2.1. Deskriptive Analyse von Finanzdaten
  - 19.2.2. Visualisierung von Finanzdaten mit Python und R
  - 19.2.3. Erkennen von Mustern und Trends in Finanzdaten
- 19.3. Finanzielle Zeitreihenanalyse
  - 19.3.1. Grundlagen von Zeitserien
  - 19.3.2. Zeitreihenmodelle für Finanzdaten
  - 19.3.3. Zeitreihenanalyse und -prognose
- 19.4. Korrelations- und Kausalanalyse im Finanzwesen
  - 19.4.1. Methoden der Korrelationsanalyse
  - 19.4.2. Techniken zur Identifizierung kausaler Beziehungen
  - 19.4.3. Anwendungen in der Finanzanalyse
- 19.5. Fortgeschrittene Visualisierung von Finanzdaten
  - 19.5.1. Fortgeschrittene Techniken zur Datenvisualisierung
  - 19.5.2. Interaktive Visualisierungstools (Plotly, Dash)
  - 19.5.3. Anwendungsfälle und praktische Beispiele
- 19.6. Clusteranalyse in Finanzdaten
  - 19.6.1. Einführung in die Clusteranalyse
  - 19.6.2. Anwendungen in der Markt- und Kundensegmentierung
  - 19.6.3. Werkzeuge und Techniken für die Clusteranalyse


- 19.7. Netzwerk- und Graphenanalyse im Finanzwesen
    - 19.7.1. Grundlagen der Netzwerkanalyse
    - 19.7.2. Anwendungen der Netzwerkanalyse im Finanzwesen
    - 19.7.3. Werkzeuge zur Netzwerkanalyse (NetworkX, Gephi)
  - 19.8. Text- und Stimmungsanalyse im Finanzwesen
    - 19.8.1. Natürliche Sprachverarbeitung (NLP) im Finanzwesen
    - 19.8.2. Stimmungsanalyse in Nachrichten und sozialen Netzwerken
    - 19.8.3. Tools und Techniken für die Textanalyse
  - 19.9. Tools zur Visualisierung und Analyse von Finanzdaten mit KI
    - 19.9.1. Python Datenanalyse-Bibliotheken (Pandas, NumPy)
    - 19.9.2. Visualisierungstools in R (ggplot2, Shiny)
    - 19.9.3. Praktische Umsetzung von Analyse und Visualisierung
  - 19.10. Projekte und praktische Anwendungen der Analyse und Visualisierung
    - 19.10.1. Entwicklung von Projekten zur Analyse von Finanzdaten
    - 19.10.2. Implementierung von interaktiven Visualisierungslösungen
    - 19.10.3. Auswertung und Präsentation der Projektergebnisse
- Modul 20. Künstliche Intelligenz für das finanzielle Risikomanagement mit TensorFlow und Scikit-learn**
- 20.1. Grundlagen des finanziellen Risikomanagements
    - 20.1.1. Grundlagen des Risikomanagements
    - 20.1.2. Arten von finanziellen Risiken
    - 20.1.3. Die Bedeutung des Risikomanagements im Finanzwesen
  - 20.2. Kreditrisikomodelle mit KI
    - 20.2.1. *Machine-Learning*-Techniken für die Bewertung des Kreditrisikos
    - 20.2.2. Modelle zur Kreditbewertung (Scikit-Learn)
    - 20.2.3. Implementierung von Kreditrisikomodellen mit Python
  - 20.3. Marktrisikomodelle mit KI
    - 20.3.1. Analyse und Management von Marktrisiken
    - 20.3.2. Anwendung von prädiktiven Marktrisikomodellen
    - 20.3.3. Implementierung von Marktrisikomodellen
  - 20.4. Operationelles Risiko und sein Management mit KI
    - 20.4.1. Konzepte und Arten des operationellen Risikos
    - 20.4.2. Anwendung von KI-Techniken für das Management des operationellen Risikos
    - 20.4.3. Tools und praktische Beispiele
  - 20.5. Liquiditätsrisikomodelle mit KI
    - 20.5.1. Grundlagen des Liquiditätsrisikos
    - 20.5.2. *Machine-Learning*-Techniken für die Analyse des Liquiditätsrisikos
    - 20.5.3. Praktische Implementierung von Liquiditätsrisikomodellen
  - 20.6. Systemische Risikoanalyse mit KI
    - 20.6.1. Konzepte des systemischen Risikos
    - 20.6.2. Anwendungen der KI bei der Bewertung des systemischen Risikos
    - 20.6.3. Fallstudien und praktische Beispiele
  - 20.7. Portfolio-Optimierung unter Berücksichtigung von Risiken
    - 20.7.1. Techniken der Portfolio-Optimierung
    - 20.7.2. Einbeziehung von Risikomaßen in die Optimierung
    - 20.7.3. Tools zur Portfolio-Optimierung
  - 20.8. Simulation von finanziellen Risiken
    - 20.8.1. Simulationsmethoden für das Risikomanagement
    - 20.8.2. Anwendung von Monte-Carlo-Simulationen im Finanzwesen
    - 20.8.3. Implementierung von Simulationen mit Python
  - 20.9. Kontinuierliche Risikobewertung und -überwachung
    - 20.9.1. Kontinuierliche Risikobewertungstechniken
    - 20.9.2. Instrumente zur Überwachung und Berichterstattung von Risiken
    - 20.9.3. Implementierung von Systemen zur kontinuierlichen Überwachung
  - 20.10. Projekte und praktische Anwendungen im Risikomanagement
    - 20.10.1. Entwicklung von Projekten zum finanziellen Risikomanagement
    - 20.10.2. Implementierung von KI-Lösungen für das Risikomanagement
    - 20.10.3. Auswertung und Präsentation der Projektergebnisse

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 der Finanzabteilung 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 der Finanzabteilung** 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 in der Finanzabteilung**

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 Vorkerhungen 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 innovativ  
wissen gegenwart qualität  
online-Ausbildung  
entwicklung institutionen  
virtuelles Klassenzimmer

**tech** technologische  
universität

Privater Masterstudiengang  
Künstliche Intelligenz  
in der Finanzabteilung

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

# Privater Masterstudiengang Künstliche Intelligenz in der Finanzabteilung