

# Privater Masterstudiengang

Künstliche Intelligenz  
in der Klinischen Praxis



## Privater Masterstudiengang Künstliche Intelligenz in der Klinischen Praxis

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

Internetzugang: [www.techtitude.com/de/medizin/masterstudiengang/masterstudiengang-kunstliche-intelligenz-klinischen-praxis](http://www.techtitude.com/de/medizin/masterstudiengang/masterstudiengang-kunstliche-intelligenz-klinischen-praxis)

# 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 42

07

Qualifizierung

---

Seite 50

# 01

# Präsentation

Die Anwendung von künstlicher Intelligenz (KI) in der klinischen Praxis ermöglicht die Integration fortschrittlicher Algorithmen und Datenanalysen, wodurch die medizinische Diagnose beschleunigt und verbessert wird und subtile Muster erkannt werden, die dem menschlichen Auge möglicherweise verborgen bleiben. Darüber hinaus erleichtert die KI die Vorhersage von Krankheiten und trägt so zu einer früheren Erkennung und zur Durchführung personalisierter präventiver Behandlungen bei. Diese Technologie optimiert auch die Verwaltung medizinischer Daten und ermöglicht so eine effizientere und genauere Patientenversorgung, während sie gleichzeitig durch die Analyse umfangreicher wissenschaftlicher Daten eine fundierte klinische Entscheidungsfindung unterstützt. Aus diesen Gründen hat TECH ein Programm ins Leben gerufen, das Ärzte in die Spitzentechnologie einführt und dabei die revolutionäre Methodik des *Relearning* nutzt.



“

*KI in der klinischen Praxis verspricht, die Qualität der medizinischen Versorgung zu verbessern, Fehler zu reduzieren und neue Grenzen für die personalisierte Medizin und die biomedizinische Forschung zu eröffnen"*



Künstliche Intelligenz kann in der medizinischen Praxis eingesetzt werden, indem große medizinische Datensätze analysiert werden, um Muster und Trends zu erkennen und genauere und frühere Diagnosen zu ermöglichen. Darüber hinaus kann KI im Patientenmanagement potenzielle Komplikationen vorhersehen, Behandlungen personalisieren und die Ressourcenzuweisung optimieren, was die Effizienz und Qualität der Versorgung verbessert. Die Automatisierung von Routineaufgaben verschafft den Fachkräften Zeit, sich auf komplexere und menschlichere Aspekte der Pflege zu konzentrieren, was zu bedeutenden Fortschritten in der Medizin führt.

Aus diesem Grund hat TECH diesen Privaten Masterstudiengang in Künstliche Intelligenz in der Klinischen Praxis mit einem umfassenden und spezialisierten Ansatz entwickelt. Die spezifischen Module reichen von der Beherrschung praktischer KI-Tools bis hin zum kritischen Verständnis ihrer ethischen und rechtlichen Anwendung in der Medizin. Durch die Konzentration auf spezifische medizinische Anwendungen, wie KI-gestützte Diagnose und Schmerzmanagement, werden Fachleute mit fortgeschrittenen Fähigkeiten und Kenntnissen in Schlüsselbereichen der Gesundheitsversorgung ausgestattet.

Auch die multidisziplinäre Zusammenarbeit wird gefördert, um die Absolventen auf die Arbeit in verschiedenen Teams im klinischen Umfeld vorzubereiten. Darüber hinaus wird der Fokus auf Ethik, Recht und Governance ein verantwortungsvolles Verständnis und eine praktische Anwendung bei der Entwicklung und Umsetzung von KI-Lösungen im Gesundheitswesen gewährleisten. Die Kombination aus theoretischem und praktischem Lernen sowie die Anwendung von *Big Data* im Gesundheitswesen wird Ärzte in die Lage versetzen, aktuelle und zukünftige Herausforderungen in diesem Bereich umfassend und kompetent anzugehen.

Auf diese Weise hat TECH ein umfassendes Programm entwickelt, das auf der innovativen *Relearning*-Methode basiert, um hochkompetente KI-Experten fortzubilden. Diese Form des Lernens konzentriert sich auf die Wiederholung von Schlüsselkonzepten, um ein solides Verständnis zu gewährleisten. Es wird lediglich ein elektronisches Gerät mit Internetanschluss benötigt, um jederzeit auf die Inhalte zugreifen zu können, so dass die Teilnehmer nicht an einen festen Zeitplan oder eine persönliche Anwesenheit gebunden sind.

Dieser **Privater Masterstudiengang in Künstliche Intelligenz in der Klinischen Praxis** enthält das vollständigste und aktuellste wissenschaftliche Programm auf dem Markt. Die wichtigsten Merkmale sind:

- Die Entwicklung von Fallstudien, die von Experten für künstliche Intelligenz in der klinischen Praxis vorgestellt werden
- Der anschauliche, schematische und äußerst praxisnahe Inhalt vermittelt alle für die berufliche Praxis unverzichtbaren wissenschaftlichen und praktischen Informationen
- Praktische Übungen, bei denen der Selbstbewertungsprozess zur Verbesserung des Lernens genutzt werden kann
- Sein besonderer Schwerpunkt liegt auf innovativen Methoden
- Theoretische Vorträge, Fragen an den Experten, Diskussionsforen zu kontroversen Themen und individuelle Reflexionsarbeit
- Die Verfügbarkeit des Zugangs zu Inhalten von jedem festen oder tragbaren Gerät mit Internetanschluss



*Der modulare Aufbau des Programms ermöglicht Ihnen eine kohärente Progression von den Grundlagen bis zu den fortgeschrittensten Anwendungen"*

“

*Sie werden in die KI-gestützte Gesundheitsdatenwissenschaft eintauchen und Biostatistik und Big-Data-Analytik in 2.250 Stunden innovativer Inhalte erforschen“*

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

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

*In diesem 100%igen Online-Programm werden Sie analysieren, wie KI genetische Daten interpretiert, um spezifische therapeutische Strategien zu entwickeln.*

*Sie werden Data Mining und maschinelles Lernen im Kontext der Gesundheit anwenden. Worauf warten Sie, um sich einzuschreiben?*



# 02 Ziele

Der Private Masterstudiengang in Künstliche Intelligenz in der Klinischen Praxis zielt darauf ab, Fachkräfte im Gesundheitswesen fortzubilden, um die medizinische Versorgung durch den strategischen Einsatz von KI zu verändern. Dieses innovative Programm wird die Studenten mit soliden Fähigkeiten in den Bereichen medizinische Datenanalyse, KI-gestützte Diagnose, Behandlungspersonalisierung und effizientes Management der Patientenversorgung ausstatten. Nach Abschluss des Studiums werden die Fachleute darauf vorbereitet sein, Veränderungen anzuführen, die Diagnosegenauigkeit zu verbessern, Behandlungsprotokolle zu optimieren und eine zugänglichere und effektivere medizinische Versorgung zu fördern.





“


*TECH wird Sie fortbilden, um die klinische Praxis zu verändern, die Diagnostik zu verbessern und präzise und personalisierte Behandlungen zu entwickeln"*




## 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*
- ♦ Analysieren des bio-inspirierten Computings und seiner Bedeutung für die Entwicklung intelligenter Systeme
- ♦ Analysieren aktueller Strategien der Künstlichen Intelligenz in verschiedenen Bereichen und Erkennen von Gelegenheiten und Herausforderungen
- ♦ Kritisches Beurteilen der Vorteile und Grenzen von KI im Gesundheitswesen und Erkennen potenzieller Fallstricke sowie fundierte Bewertung ihrer klinischen Anwendung
- ♦ Erkennen der Bedeutung der interdisziplinären Zusammenarbeit bei der Entwicklung effektiver KI-Lösungen
- ♦ Erwerben eines umfassenden Überblicks über aufkommende Trends und technologische Innovationen im Bereich der KI für das Gesundheitswesen
- ♦ Erwerben solider Kenntnisse in der Erfassung, Filterung und Vorverarbeitung von medizinischen Daten
- ♦ Verstehen der ethischen Grundsätze und rechtlichen Bestimmungen, die für die Anwendung von KI in der Medizin gelten, und Fördern ethischer Praktiken, Fairness und Transparenz





## 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
- ♦ Erforschen des Konzepts des semantischen Webs und seines Einflusses auf die Organisation und das Verständnis von Informationen in digitalen Umgebungen

### Modul 2. Typen und Lebenszyklus von Daten

- ♦ 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
- ♦ Analysieren der rechtlichen Aspekte im Zusammenhang mit der Datenverwaltung, der Einhaltung von Datenschutz- und Sicherheitsvorschriften sowie von Best Practices

### Modul 3. Daten in der künstlichen Intelligenz

- ♦ Beherrschen der Grundlagen der Datenwissenschaft, einschließlich der Werkzeuge, Typen und Quellen für die Informationsanalyse
- ♦ Erforschen des Prozesses der Umwandlung von Daten in Informationen mithilfe von Data Mining und Datenvisualisierungstechniken
- ♦ Studieren der Struktur und der Eigenschaften von *Datasets* und verstehen ihre Bedeutung für die Aufbereitung und Nutzung von Daten für KI-Modelle
- ♦ Analysieren von überwachten und unüberwachten Modellen, einschließlich Methoden und Klassifizierung
- ♦ 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
- ♦ Studieren semantischer *Reasoner*, wissensbasierter Systeme und Expertensysteme und Verstehen ihrer Funktionalität und Anwendungen in der intelligenten Entscheidungsfindung

### **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
- ♦ Feinabstimmen von Hyperparametern für das *Fine Tuning* neuronaler Netze, um ihre Leistung bei bestimmten Aufgaben zu optimieren

### **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
- ♦ Verstehen und Anwenden von Regularisierungstechniken zur Verbesserung der Generalisierung und zur Vermeidung von *Overfitting* in tiefen neuronalen Netzen

#### **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*
- ♦ Implementieren von semantischen Segmentierungstechniken, um Objekte in Bildern im Detail zu verstehen und zu klassifizieren

## 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-Auto-Encodern 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
- ♦ Erforschen sozialer Anpassungsalgorithmen als wichtiger Ansatz im bioinspirierten Computing
- ♦ 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 in die 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
- ♦ Analysieren der Auswirkungen von künstlicher Intelligenz auf die Erbringung von Dienstleistungen im Gesundheitswesen
- ♦ 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. KI-Anwendungen im Gesundheitswesen: Grundsätze und Anwendungsfälle

- ♦ Kritisches Analysieren der Vorteile und Grenzen von KI im Gesundheitswesen
- ♦ Identifizieren potenzieller Fallstricke und fundierte Bewertung ihrer Anwendung im klinischen Umfeld
- ♦ Identifizieren potenzieller Fallstricke und fundierte Bewertung ihrer Anwendung im klinischen Umfeld





### **Modul 17. Klinische Umsetzung von künstlicher Intelligenz**

- ♦ Interpretieren der Ergebnisse für die Erstellung ethischer *Datensets* und die strategische Anwendung in gesundheitlichen Notfällen
- ♦ Erwerben fortgeschrittener Fähigkeiten in der Präsentation, Visualisierung und Verwaltung von KI-Gesundheitsdaten
- ♦ Erwerben eines umfassenden Überblicks über aufkommende Trends und technologische Innovationen im Bereich der KI für das Gesundheitswesen

### **Modul 18. Personalisierung der Gesundheit durch KI**

- ♦ Verstehen der sich abzeichnenden Trends im Bereich der KI für personalisierte Gesundheit und ihrer künftigen Auswirkungen

### **Modul 19. Big Data-Analyse im Gesundheitssektor mit KI**

- ♦ Erwerben solider Kenntnisse in der Beschaffung, Filterung und Vorverarbeitung von medizinischen Daten
- ♦ Nutzen des erworbenen Wissens in Anwendungsfällen und praktischen Anwendungen, die Sie in die Lage versetzen, branchenspezifische Herausforderungen zu verstehen und zu lösen, von der Textanalyse über die Datenvisualisierung bis hin zur medizinischen Informationssicherheit

### **Modul 20. Ethik und Regulierung in der medizinischen KI**

- ♦ Verstehen der grundlegenden ethischen Prinzipien und rechtlichen Bestimmungen, die für den Einsatz von KI in der Medizin gelten
- ♦ Beherrschen der Grundsätze der **Data Governance**
- ♦ Verstehen der internationalen und lokalen rechtlichen Rahmenbedingungen
- ♦ Sicherstellen der Einhaltung von Vorschriften bei der Nutzung von KI-Daten und -Tools im Gesundheitssektor

# 03

# Kompetenzen

Der Private Masterstudiengang in Künstliche Intelligenz in der Klinischen Praxis wird Fachleuten helfen, entscheidende Kompetenzen zu erwerben, um sich auf die Konvergenz von Medizin und Technologie vorzubereiten. Von der fortgeschrittenen medizinischen Datenanalyse bis hin zur strategischen Implementierung von Algorithmen für präzise Diagnosen stärkt dieser Studiengang die Fähigkeiten der Studenten bei der Personalisierung von Behandlungen und der Optimierung der medizinischen Versorgung, was sie in die Lage versetzt, innovativ zu sein und den Wandel in der Medizin mit Vision und Exzellenz anzuführen.






“


*Aktualisieren Sie Ihre Fähigkeiten mit TECH!  
Sie werden Ihre Fähigkeiten im Bereich der  
medizinischen Datenanalyse, der KI-gestützten  
Diagnose und der Personalisierung von  
Behandlungen verbessern"*



## 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
- Implementieren von KI-Tools im klinischen Umfeld, mit Schwerpunkt auf unterstützter Diagnose, medizinischer Bildanalyse und KI-Modellierungsergebnissen
- Anwenden von KI-Algorithmen zur Personalisierung medizinischer Behandlungen, von der Genomanalyse bis zur Schmerzbehandlung
- Erwerben fortgeschrittener Fähigkeiten in der Präsentation, Visualisierung und Verwaltung von KI-Gesundheitsdaten
- Entwickeln von KI-Algorithmen für spezifische Anwendungen in der Medizin, z. B. Medikamentenentwicklung, Gesundheitsüberwachung und chirurgische Robotik
- Verwenden gesundheitspezifischer *Big Data*-Techniken, einschließlich Textverarbeitung, Qualitätsbewertung und Anwendung von Algorithmen des maschinellen Lernens





## 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 Vorbereiten 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
- ♦ Anwenden von KI-Tools im klinischen Kontext mit Schwerpunkt auf unterstützter Diagnose, Analyse medizinischer Bilder und Interpretation der Ergebnisse von KI-Modellen
- ♦ Anwenden und Bewerten von KI-Algorithmen in realen medizinischen Umgebungen
- ♦ Verwenden von KI zur Personalisierung medizinischer Behandlungen, von der Genomanalyse bis zum Schmerzmanagement
- ♦ Verwenden von KI-Algorithmen für spezifische Anwendungen, wie z. B. Medikamentenentwicklung, Gesundheitsüberwachung und chirurgische Robotik
- ♦ Beherrschen von *Big Data*-Techniken speziell für den Gesundheitssektor, einschließlich Textverarbeitung, Qualitätsbewertung und Anwendung von Algorithmen des maschinellen Lernens für Personalisierung und Analyse
- ♦ Entwerfen von auf den Menschen ausgerichteten KI-Systemen unter Förderung von Fairness und Transparenz beim maschinellen Lernen und Gewährleistung der Sicherheit und Qualität von Modellen durch umfassende Richtlinien und Bewertungen



# 04

## Kursleitung

Der Lehrkörper des Privaten Masterstudiengangs in Künstliche Intelligenz in der Klinischen Praxis vereint führende Experten auf dem Gebiet der Medizin und Technologie und bietet eine außergewöhnlich umfassende und aktuelle Perspektive. Diese Fachleute verfügen nicht nur über fundierte Kenntnisse in der Anwendung von KI in der klinischen Praxis, sondern auch über umfangreiche praktische Erfahrung in der Entwicklung und Umsetzung innovativer Lösungen im medizinischen Bereich. Ihr Engagement für eine hervorragende Weiterbildung stellt sicher, dass die Studenten nicht nur theoretisches Wissen, sondern auch ein gründliches praktisches Verständnis erwerben.



“

*Lernen Sie von den Besten! Das Dozententeam  
bereitet Sie auf die aktuellen und künftigen  
Herausforderungen im Gesundheitswesen vor"*




## 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 fortgeschrittener Informationstechnologie von der Universität von Castilla La Mancha
- ♦ Mitglied von: Forschungsgruppe SMILE



# 05

## Struktur und Inhalt

Dieser private Masterstudiengang wurde sorgfältig konzipiert, um klinische Exzellenz mit technologischer Innovation zu verbinden. Seine Struktur basiert auf spezialisierten Modulen, die von den Grundlagen der KI bis zu spezifischen Anwendungen im medizinischen Umfeld reichen. Die Inhalte bieten ein perfektes Gleichgewicht zwischen fortgeschrittener Theorie und praktischer Anwendung, so dass Fachleute in der Lage sind, alles von der Datenanalyse bis zur Personalisierung von Behandlungen zu bewältigen. Auf diese Weise werden die Studenten darauf vorbereitet, mit einer fortschrittlichen Vision und soliden technischen Fähigkeiten einen Unterschied in der Medizin zu machen.





“

*Bringen Sie Ihre tägliche klinische Praxis auf den neuesten Stand, um an der Spitze der technologischen Revolution im Gesundheitswesen zu stehen und zur Weiterentwicklung der klinischen Praxis beizutragen"*



## 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. Experten-Systeme
  - 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. Wizard-Entwicklungswerkzeuge: *Dialog Flow*, *Watson Assistant*
- 1.9. AI-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. Typen und Lebenszyklus von Daten

- 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. Nicht-parametrische 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 Wirkstoffe
  - 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. Darstellung von Wissen
  - 6.4.1. Die Bedeutung der Wissensdarstellung
  - 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. Korrelation Maßnahmen
  - 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 Preprocessing-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. Erkennung von Objekten
- 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 NRN
    - 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 das Sehen
    - 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 *Transformers*-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
  - 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
- 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

- 13.10. 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. Bio-inspiriertes 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. KI-Anwendungen im Gesundheitswesen: Grundsätze und Anwendungsfälle

- 16.1. KI in der medizinischen Praxis: Überblick
- 16.2. Innovationen und zukünftige Trends in der medizinischen KI
- 16.3. Grundlagen der Datenwissenschaft in der KI-gestützten Medizin
- 16.4. KI-gestützte Diagnostik: Medizinische Bildanalyse
- 16.5. Mustererkennung und *Machine Learning* in der klinischen Diagnostik
- 16.6. Kritische Bewertung von KI im Gesundheitswesen: Nutzen und Grenzen
- 16.7. Multidisziplinäre Synergie bei der Entwicklung von KI-Lösungen für das Gesundheitswesen
- 16.8. Integration von KI-Technologien in die medizinische Praxis
- 16.9. Anpassung von KI-Tools im klinischen Umfeld
- 16.10. Erfolgreiche Erfahrungen mit KI in der medizinischen Praxis: Fallstudien

## Modul 17. Klinische Umsetzung von künstlicher Intelligenz

- 17.1. Interpretation und Entscheidungsfindung in der medizinischen KI
- 17.2. Visualisierung und Verwaltung von Gesundheitsdaten mit KI
- 17.3. Entwicklung und Validierung von KI-Algorithmen in medizinischen Kontexten
- 17.4. Auswirkungen von Deep Learning in der klinischen Praxis
- 17.5. Erstellung und Analyse von Datensätzen im Gesundheitswesen mit KI
- 17.6. KI und Biobanken in der klinischen Forschung
- 17.7. Verbesserung des Gesundheitswesens und der öffentlichen Gesundheit durch KI
- 17.8. KI in der Notfallversorgung
- 17.9. Optimierung von Gesundheitsdiensten mit KI-Technologie
- 17.10. Zukünftige Trends und Entwicklungen im Bereich KI für die Gesundheit

## Modul 18. Personalisierung der Gesundheit durch KI

- 18.1. KI-Anwendungen in der Genomik für die personalisierte Medizin
- 18.2. KI in der Pharmakogenomik und Arzneimittelentwicklung
- 18.3. Personalisierte Überwachung mit intelligenten Geräten und KI
- 18.4. Klinische Entscheidungshilfesysteme mit KI
- 18.5. Trends in der Gesundheitspersonalisierung mit KI
- 18.6. KI in der personalisierten Diagnose: Anamnese und Bildanalyse
- 18.7. Fortschritte in der KI-unterstützten chirurgischen Robotik
- 18.8. Prädiktive Analytik im öffentlichen Gesundheitswesen mit KI
- 18.9. KI in der personalisierten Schmerzbehandlung und -therapie
- 18.10. Integration von KI in elektronische Krankenakten

## Modul 19. *Big Data*-Analyse im Gesundheitssektor mit KI

- 19.1. Grundlagen von *Big Data* im Gesundheitswesen
- 19.2. Textverarbeitung und Analyse von Gesundheitsdaten
- 19.3. Fortgeschrittene Methoden des Datenabrufs im Gesundheitswesen
- 19.4. Qualitätsbewertung bei der Analyse von Gesundheitsdaten
- 19.5. Data Mining und maschinelles Lernen im Gesundheitswesen
- 19.6. Innovative Bereiche von *Big Data* und KI im Gesundheitswesen
- 19.7. Erfassung und Vorverarbeitung von medizinischen Daten
- 19.8. Datenvisualisierung und -kommunikation im Gesundheitswesen
- 19.9. Datensicherheit und -verwaltung im Gesundheitswesen
- 19.10. Praktische Anwendungen von *Big Data* im Gesundheitswesen



## Modul 20. Ethik und Regulierung in der medizinischen KI

- 20.1. Ethische Grundsätze für den Einsatz von KI in der Medizin
- 20.2. Datenschutz und Einwilligung in medizinischen Kontexten
- 20.3. Internationale Vorschriften und Einhaltung von Bestimmungen in der medizinischen KI
- 20.4. Soziale Auswirkungen und Verantwortlichkeit in der medizinischen KI
- 20.5. Nachhaltige Entwicklung von KI im Gesundheitswesen
- 20.6. *Data Governance* und rechtliche Rahmenbedingungen in der medizinischen KI
- 20.7. Wirtschaftliche Aspekte der KI im Gesundheitswesen
- 20.8. Menschenzentrierte Gestaltung von medizinischen KI-Systemen
- 20.9. Gleichheit und Transparenz beim maschinellen Lernen in der Medizin
- 20.10. Sicherheit und Politik bei der Implementierung von KI in der Medizin





“

*Ein einzigartiges, wichtiges und entscheidendes  
Fortbildungserlebnis zur Förderung Ihrer  
beruflichen Entwicklung“*

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"*

## Bei TECH verwenden wir die Fallmethode

Was sollte eine Fachkraft in einer bestimmten Situation tun? Während des gesamten Programms werden die Studenten mit mehreren simulierten klinischen Fällen konfrontiert, die auf realen Patienten basieren und in denen sie Untersuchungen durchführen, Hypothesen aufstellen und schließlich die Situation lösen müssen. Es gibt zahlreiche wissenschaftliche Belege für die Wirksamkeit der Methode. Fachkräfte lernen mit der Zeit besser, schneller und nachhaltiger.

*Mit TECH werden Sie eine Art des Lernens erleben, die an den Grundlagen der traditionellen Universitäten auf der ganzen Welt rüttelt.*



Nach Dr. Gérvas ist der klinische Fall die kommentierte Darstellung eines Patienten oder einer Gruppe von Patienten, die zu einem "Fall" wird, einem Beispiel oder Modell, das eine besondere klinische Komponente veranschaulicht, sei es wegen seiner Lehrkraft oder wegen seiner Einzigartigkeit oder Seltenheit. Es ist wichtig, dass der Fall auf dem aktuellen Berufsleben basiert und versucht, die tatsächlichen Bedingungen in der beruflichen Praxis des Arztes nachzustellen.



“

*Wussten Sie, dass diese Methode im Jahr 1912 in Harvard, für Jurastudenten entwickelt wurde? Die Fallmethode bestand darin, ihnen reale komplexe Situationen zu präsentieren, in denen sie Entscheidungen treffen und begründen mussten, wie sie diese lösen könnten. Sie wurde 1924 als Standardlehrmethode in Harvard etabliert“*

Die Wirksamkeit der Methode wird durch vier Schlüsselergebnisse belegt:

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



## Relearning Methodology

TECH kombiniert die Methodik der Fallstudien effektiv mit einem 100%igen Online-Lernsystem, das auf Wiederholung basiert und in jeder Lektion 8 verschiedene didaktische Elemente kombiniert.

Wir ergänzen die Fallstudie mit der besten 100%igen Online-Lehrmethode: Relearning.



*Die Fachkraft lernt durch reale Fälle und die Lösung komplexer Situationen in simulierten Lernumgebungen. Diese Simulationen werden mit modernster Software entwickelt, die ein immersives Lernen ermöglicht.*

Die Relearning-Methode, die an der Spitze der weltweiten Pädagogik steht, hat es geschafft, die Gesamtzufriedenheit der Fachleute, die ihr Studium abgeschlossen haben, im Hinblick auf die Qualitätsindikatoren der besten spanischsprachigen Online-Universität (Columbia University) zu verbessern.

Mit dieser Methodik wurden mehr als 250.000 Ärzte mit beispiellosem Erfolg in allen klinischen Fachbereichen fortgebildet, unabhängig von der chirurgischen Belastung. Unsere Lehrmethodik wurde in einem sehr anspruchsvollen Umfeld entwickelt, mit einer Studentenschaft, die ein hohes sozioökonomisches Profil und ein Durchschnittsalter von 43,5 Jahren aufweist.

*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.*

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.

Die Gesamtnote des TECH-Lernsystems beträgt 8,01 und entspricht den höchsten internationalen Standards.





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.



#### Chirurgische Techniken und Verfahren auf Video

TECH bringt dem Studenten die neuesten Techniken, die neuesten pädagogischen Fortschritte und die aktuellsten medizinischen Verfahren näher. All dies in der ersten Person, mit äußerster Präzision, erklärt und detailliert, um zur Assimilation und zum Verständnis des Studenten beizutragen. Und das Beste ist, dass Sie es sich so oft anschauen können, wie Sie möchten.



#### 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.



#### 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.





#### Von Experten entwickelte und geleitete Fallstudien

Effektives Lernen muss notwendigerweise kontextabhängig sein. Aus diesem Grund stellt TECH die Entwicklung von realen Fällen vor, in denen der Experte den Studenten durch die Entwicklung der Aufmerksamkeit und die Lösung verschiedener Situationen führt: ein klarer und direkter Weg, um den höchsten Grad an Verständnis zu erreichen.



#### 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.



#### 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.



#### Kurzanleitungen zum Vorgehen

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





07

# Qualifizierung

Der Privater Masterstudiengang in Künstliche Intelligenz in der Klinischen Praxis 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"*

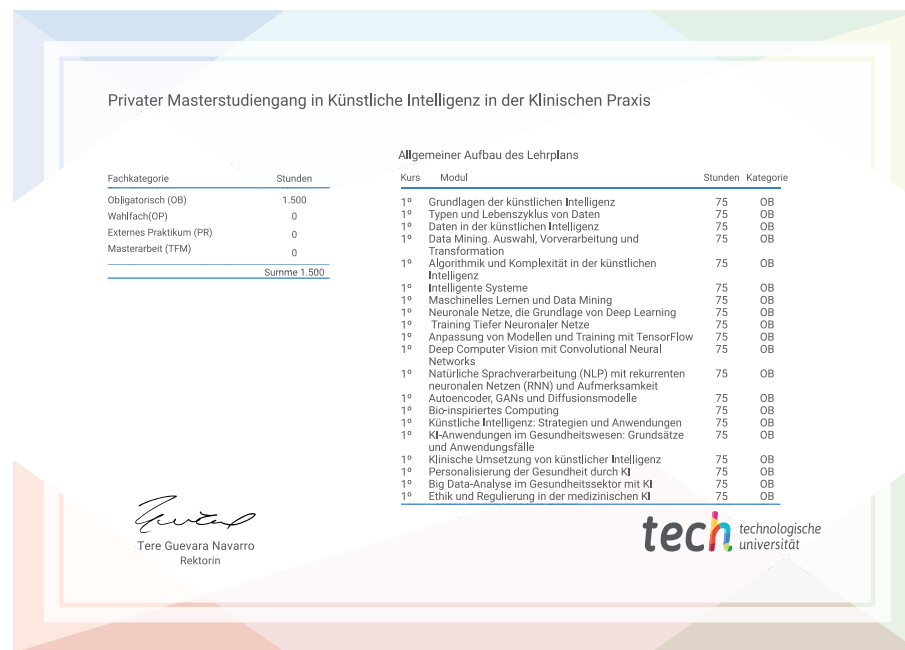
Dieser **Privater Masterstudiengang in Künstliche Intelligenz in der Klinischen Praxis** enthält das vollständigste und aktuellste wissenschaftliche Programm auf dem Markt.

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 Klinischen Praxis**

Anzahl der offiziellen Arbeitsstunden: **2.250 Std.**



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

zukunft

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

**tech** technologische  
universität

**Privater Masterstudiengang**  
Künstliche Intelligenz  
in der Klinischen Praxis

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



# Privater Masterstudiengang

Künstliche Intelligenz in der  
Klinischen Praxis