

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.techtute.com/de/kunstliche-intelligenz/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 44

07

Qualifizierung

Seite 52

01

Präsentation

Künstliche Intelligenz (KI) spielt sowohl in der klinischen Forschung als auch in der medizinischen Versorgung eine immer wichtigere Rolle. Einer der Gründe dafür ist, dass diese Systeme durch die Analyse medizinischer Bilder (wie Röntgenaufnahmen oder CT-Scans) helfen, Pathologien zu erkennen. Auf diese Weise können Spezialisten Anomalien genauer und schneller erkennen. Dies wiederum bedeutet eine frühere Diagnose und sogar die Erkennung von Krankheiten in ihren frühen Stadien. In diesem Zusammenhang hat TECH einen Studiengang ins Leben gerufen, der die Integration des maschinellen Lernens in klinische Belange vertiefen soll. Außerdem basiert er auf einer 100%igen Online-Methode, so dass die Studenten ihr Studium mit dem Rest ihrer täglichen Aktivitäten verbinden können.



“

Sie werden analysieren, wie KI genetische Daten interpretiert, um spezifische therapeutische Strategien zu entwickeln, dank dieses 100%igen Online-Programms"

Die Analyse von *Big Data* verbessert die medizinische Versorgung und die Gesundheitsforschung erheblich. Solche fortschrittlichen Systeme geben Experten die Möglichkeit, Behandlungen zu personalisieren. Patienteninformationen wie Krankengeschichte, Genetik und Lebensstil werden genutzt, um Behandlungspläne und Medikamente individuell anzupassen. Darüber hinaus tragen diese Tools zur kontinuierlichen Überwachung von Patienten außerhalb des klinischen Umfelds bei, was insbesondere für Nutzer mit chronischen Erkrankungen von Vorteil ist. So tragen die KI-Ressourcen zur Entwicklung effektiverer Verfahren und einer sichereren Versorgung bei.

Aus diesem Grund hat TECH einen privaten Masterstudiengang konzipiert, der sich mit der Analyse von *Big Data* und maschinellem Lernen in der klinischen Forschung befasst. Der Lehrplan wird Aspekte wie *Data Mining* in klinischen und biomedizinischen Aufzeichnungen behandeln, wobei der Schwerpunkt auf Algorithmen und prädiktiven Analysetechniken liegt. Darüber hinaus werden in der Fortbildung die Wechselwirkungen untersucht, die in biologischen Netzwerken zur Identifizierung von Krankheitsmustern auftreten. Zusätzlich wird der Lehrplan den ethischen und rechtlichen Faktoren der KI im medizinischen Kontext besondere Aufmerksamkeit schenken. Auf diese Weise werden die Studenten ein verantwortungsbewusstes Gewissen bei der Durchführung ihrer Verfahren entwickeln.

Es ist hervorzuheben, dass TECH zur Konsolidierung all dieser Inhalte auf die revolutionäre *Relearning*-Methode zurückgreift. Dieses Lehrsystem basiert auf der Wiederholung der wichtigsten Konzepte, um ein optimales Verständnis zu festigen. Die einzige Voraussetzung für die Studenten ist ein elektronisches Gerät (z. B. ein Mobiltelefon, ein Computer oder ein Tablet), das mit dem Internet verbunden ist, damit sie jederzeit auf den virtuellen Campus zugreifen und die Inhalte ansehen können. Auf diese Weise können sie bequem von zu Hause aus lernen und müssen sich nicht mehr um persönliche Anwesenheit und vorgegebene Stundenpläne kümmern.

Dieser **Privater Masterstudiengang in Künstliche Intelligenz in der Klinischen Praxis** enthält das vollständigste und aktuellste Bildungsprogramm auf dem Markt. Seine herausragendsten Merkmale sind:

- Die Entwicklung von Fallstudien, die von Experten für künstliche Intelligenz in der klinischen Forschung 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



Sie werden TensorFlow-Datensätze zum Laden von Daten beherrschen und dank dieses Programms eine effiziente Vorverarbeitung medizinischer Daten erreichen"



Sie werden an der Spitze des medizinischen Bereichs stehen! Dieses Programm verbindet klinische Exzellenz mit der technologischen Revolution des maschinellen Lernens"

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

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

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

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

Vergessen Sie das Auswendiglernen! Mit dem Relearning-System werden Sie die Konzepte auf natürliche und progressive Weise integrieren.



02 Ziele

Dieser private Masterstudiengang wird die Studenten zu echten Führungskräften machen, die in der Lage sind, aktuelle und künftige Herausforderungen in der Medizin zu bewältigen. Sie werden über ein umfassendes Verständnis der KI verfügen, das zur Entwicklung innovativer Lösungen für die Umgestaltung der medizinischen Versorgung beitragen wird. So werden die Fachleute Techniken der medizinischen Datenanalyse, die Entwicklung von Vorhersagemodellen für klinische Studien und die Umsetzung innovativer Lösungen für die Personalisierung von Behandlungen anwenden.






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"



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
- ♦ Erlangen eines umfassenden Überblicks über den Wandel der klinischen Forschung durch KI, von den historischen Grundlagen bis hin zu aktuellen Anwendungen
- ♦ Lernen von effektiven Methoden zur Integration heterogener Daten in die klinische Forschung, einschließlich natürlicher Sprachverarbeitung und fortschrittlicher Datenvisualisierung
- ♦ Erwerben eines soliden Verständnisses von Modellvalidierung und Simulationen im biomedizinischen Bereich, wobei die Verwendung synthetischer *Datasets* und praktische Anwendungen von KI in der Gesundheitsforschung untersucht werden
- ♦ Verstehen und Anwenden genomischer Sequenzierungstechnologien, Datenanalyse mit KI und Einsatz von KI in der biomedizinischen Bildgebung
- ♦ Erwerben von Fachwissen in Schlüsselbereichen wie der Personalisierung von Therapien, Präzisionsmedizin, KI-gestützte Diagnostik und Management klinischer Studien
- ♦ Erwerben eines soliden Verständnisses der Konzepte von *Big Data* im klinischen Umfeld und Kennenlernen der wichtigsten Tools für die Datenanalyse
- ♦ Vertiefen von ethischen Dilemmata, Überprüfen rechtlicher Erwägungen, Erforschen der sozioökonomischen Auswirkungen und der Zukunft der KI im Gesundheitswesen sowie Fördern von Innovation und Unternehmertum im Bereich der klinischen KI






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. 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, Tool 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



Justification

Standard list of comment

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
- ♦ 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, durch Anwendung von Filter- und Glättungsverfahren, um die Qualität des Datensatzes zu verbessern
- ♦ Eingehen auf die Datenvorverarbeitung in *Big Data*-Umgebungen

Modul 5. Algorithmik und Komplexität in der künstlichen Intelligenz

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

Modul 6. Intelligente Systeme

- ♦ Erforschen der Agententheorie, Verstehen der grundlegenden Konzepte ihrer Funktionsweise und ihrer Anwendung in der künstlichen Intelligenz und im Software Engineering
- ♦ Studieren der Darstellung von Wissen, einschließlich der Analyse von Ontologien und deren Anwendung bei der Organisation von strukturierten Informationen

- ♦ Analysieren des Konzepts des semantischen Webs und seiner Auswirkungen auf die Organisation und den Abruf von Informationen in digitalen Umgebungen
- ♦ Evaluieren und Vergleichen verschiedener Wissensrepräsentationen und deren Integration zur Verbesserung der Effizienz und Genauigkeit von intelligenten Systemen
- ♦ 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 Modelleistung 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
- ♦ 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-Auto-Encodern* bei der Datendarstellung
- ♦ Generieren von Modebildern aus dem MNIST-Datensatz mit Hilfe von *Autoencodern*
- ♦ 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 bio-inspirierten 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 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
- ♦ 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. Diagnose in der klinischen Praxis mit KI

- ♦ Kritisches Analysieren der Vorteile und Grenzen von KI im Gesundheitswesen
- ♦ Identifizieren potenzieller Fehler und fundiertes Bewerten ihrer Anwendung im klinischen Umfeld
- ♦ Erkennen der Bedeutung der interdisziplinären Zusammenarbeit bei der Entwicklung effektiver KI-Lösungen
- ♦ Entwickeln von Kompetenzen für die Anwendung von KI-Tools im klinischen Kontext und sich dabei auf Aspekte wie die unterstützte Diagnose, die Analyse medizinischer Bilder und die Interpretation der Ergebnisse konzentrieren
- ♦ Identifizieren potenzieller Fehler bei der Anwendung von KI im Gesundheitswesen, um einen fundierten Überblick über deren Einsatz im klinischen Umfeld zu erhalten

Modul 17. Behandlung und Management von Patienten mit KI

- ♦ Interpretieren der Ergebnisse für die Erstellung ethischer *Datasets* 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
- ♦ Entwickeln von KI-Algorithmen für spezifische Anwendungen wie die Gesundheitsüberwachung, um die effektive Umsetzung von Lösungen in der medizinischen Praxis zu erleichtern
- ♦ Entwerfen und Umsetzen individualisierter medizinischer Behandlungen durch Analyse der klinischen und genomischen Daten von Patienten mit KI

Modul 18. Personalisierung der Gesundheit durch KI

- ♦ Vertiefen der sich abzeichnenden Trends im Bereich der KI für personalisierte Gesundheit und ihrer künftigen Auswirkungen
- ♦ Definieren der KI-Anwendungen für die Personalisierung medizinischer Behandlungen, die von der Genomanalyse bis zur Schmerzbehandlung reichen
- ♦ Differenzieren spezifischer KI-Algorithmen für die Entwicklung von Anwendungen im Zusammenhang mit der Entwicklung von Medikamenten oder chirurgischer Robotik
- ♦ Beschreiben der sich abzeichnenden Trends im Bereich der KI für die personalisierte Medizin und ihrer künftigen Auswirkungen
- ♦ Fördern von Innovationen durch die Entwicklung von Strategien zur Verbesserung der medizinischen Versorgung

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

- ♦ Erwerben solider Kenntnisse in der Beschaffung, Filterung und Vorverarbeitung von medizinischen Daten
- ♦ Entwickeln eines klinischen Ansatzes auf der Grundlage von Datenqualität und -integrität im Kontext der Datenschutzbestimmungen
- ♦ Nutzen des erworbenen Wissens in Anwendungsfällen und praktischen Anwendungen, die es ermöglichen, branchenspezifische Herausforderungen zu verstehen und zu lösen, von der Textanalyse über die Datenvisualisierung bis hin zur medizinischen Informationssicherheit
- ♦ Definieren von *Big-Data*-Techniken speziell für den Gesundheitssektor, einschließlich der Anwendung von Algorithmen des maschinellen Lernens für die Analyse
- ♦ Einsetzen von *Big-Data*-Verfahren zur Verfolgung und Überwachung der Ausbreitung von Infektionskrankheiten in Echtzeit für eine wirksame Reaktion auf Epidemien

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
- ♦ Entwickeln von Fähigkeiten zur Entwicklung von KI-Systemen, die den Menschen in den Mittelpunkt stellen und Gleichheit und Transparenz beim maschinellen Lernen fördern



Genießen Sie die aktuellsten akademischen Inhalte der Bildungsszene, die in innovativen Multimedia-Formaten verfügbar sind, um Ihr Studium zu optimieren"

03

Kompetenzen

Dieser Universitätsabschluss vermittelt den Studenten ein aktuelles Wissen über die Anwendung von KI im Bereich der klinischen Forschung. So werden die Experten mit fortgeschrittenen und praktischen Fähigkeiten ausgestattet, um komplexe biomedizinische Herausforderungen zu bewältigen, von der Datenanalyse bis zur Simulation biologischer Prozesse. Darüber hinaus werden sie ein umfassendes Verständnis von Spitzentechnologien wie der genomischen Sequenzierung und der biomedizinischen Bildanalyse erlangen. Außerdem werden sie über umfassende Kenntnisse in ethischen, rechtlichen und regulatorischen Fragen verfügen.






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



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
- Verwenden von KI-Tools, -Plattformen und -Techniken, von der Datenanalyse bis zur Anwendung neuronaler Netze und prädiktiver Modellierung
- Anwenden von Computermodellen zur Simulation von biologischen Prozessen und Reaktionen auf Behandlungen unter Einsatz von KI, um das Verständnis komplexer biomedizinischer Phänomene zu verbessern
- Bewältigen aktueller Herausforderungen im biomedizinischen Bereich, einschließlich der effizienten Verwaltung klinischer Studien und der Anwendung von KI in der Immunologie





Spezifische Kompetenzen

- Anwenden von KI-Techniken und -Strategien zur Verbesserung der Effizienz im *Retail*
- Vertiefen des Verständnisses und der Anwendung von genetischen Algorithmen
- Anwenden von Entrauschungstechniken unter Verwendung von automatischen Kodierern
- Effektives Erstellen von Trainingsdatensätzen für Aufgaben der natürlichen Sprachverarbeitung (NLP)
- Ausführen von Clustering-Schichten und deren Verwendung in *Deep Computer Vision*-Modellen mit Keras
- Verwenden von *TensorFlow*-Funktionen und Graphen, um die Leistung von benutzerdefinierten Modellen zu optimieren
- Optimieren der Entwicklung und Anwendung von *Chatbots* und virtuellen Assistenten, indem man versteht, wie sie funktionieren und welche Anwendungsmöglichkeiten sie bieten
- Beherrschen der Wiederverwendung von vortrainierten Schichten, um den Trainingsprozess zu optimieren und zu beschleunigen
- Erstellen eines ersten neuronalen Netzes, indem die erlernten Konzepte in der Praxis angewendet werden
- Aktivieren eines mehrschichtigen Perzeptrons (MLP) mit der Keras-Bibliothek
- Anwenden von Datenexplorations- und Vorverarbeitungstechniken zur Identifizierung und Vorbereitung von Daten für die effektive Verwendung in maschinellen Lernmodellen
- Implementieren effektiver Strategien für den Umgang mit fehlenden Werten in Datensätzen, indem je nach Kontext Imputations- oder Eliminierungsmethoden angewendet werden
- Untersuchen von Sprachen und Software für die Erstellung von Ontologien unter Verwendung spezifischer Tools für die Entwicklung semantischer Modelle
- Entwickeln von Techniken zur Datenbereinigung, um die Qualität und Genauigkeit der in der nachfolgenden Analyse verwendeten Informationen zu gewährleisten
- Beherrschen der in der klinischen Forschung eingesetzten KI-Tools, -Plattformen und -Techniken, von der Datenanalyse bis zur Anwendung neuronaler Netze und prädiktiver Modellierung
- Anwenden von Computermodellen bei der Simulation von biologischen Prozessen, Krankheiten und Reaktionen auf Behandlungen unter Verwendung von KI-Tools, um das Verständnis und die Darstellung komplexer biomedizinischer Phänomene zu verbessern
- Anwenden genomischer Sequenzierungstechnologien und Datenanalyse mit KI
- Verwenden von KI in der biomedizinischen Bildanalyse
- Erwerben von Fähigkeiten zur fortgeschrittenen Visualisierung und effektiven Kommunikation komplexer Daten, mit Schwerpunkt auf der Entwicklung von KI-basierten Tools

04

Kursleitung

Um eine qualitativ hochwertige Fortbildung auf hohem Niveau anbieten zu können, bringt TECH renommierte Fachleute mit umfassender Erfahrung in der KI in der klinischen Praxis zusammen. In diesem Sinne zeichnet sich das Programm durch einen Lehrkörper aus, der den exklusivsten und vollständigsten Lehrplan auf dem akademischen Markt anbietet. So wurde jedes Modul mit einem Höchstmaß an Spezifität konzipiert, um den Studenten die Möglichkeit zu geben, ihre Fähigkeiten maximal zu festigen und zu entwickeln. So haben sie die Garantie, dass sie sich spezialisieren und auf dem Weg zu ihrem beruflichen Erfolg weiterentwickeln können.



“

Ein erfahrenes Dozententeam wird Sie während des gesamten Lernprozesses begleiten und alle aufkommenden Zweifel beseitigen"

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



Hr. Martín-Palomino Sahagún, Fernando

- ♦ *Chief Technology Officer* und *FuEul-Direktor* bei AURA Diagnostics (medTech)
- ♦ Geschäftsentwicklung bei SARLIN
- ♦ Direktor der Abteilung Betrieb bei Alliance Diagnósticos
- ♦ Direktor für Innovation bei Alliance Medical
- ♦ *Chief Information Officer* bei Alliance Medical
- ♦ *Field Engineer & Project Management* für digitale Radiologie bei Kodak
- ♦ MBA von der Polytechnischen Universität von Madrid
- ♦ *Executive Master* in Marketing und Vertrieb von ESADE
- ♦ Leitender Ingenieur für Telekommunikation von der Universität Alfonso X El Sabio

Professoren

Dr. Carrasco González, Ramón Alberto

- ♦ Spezialist für Informatik und Künstliche Intelligenz
- ♦ Forscher
- ♦ Leiter des Bereichs *Business Intelligence* (Marketing) bei Caja General de Ahorros de Granada und Banco Mare Nostrum
- ♦ Leiter der Abteilung Informationssysteme (*Data Warehousing und Business Intelligence*) bei Caja General de Ahorros de Granada und Banco Mare Nostrum
- ♦ Promotion in Künstliche Intelligenz an der Universität von Granada
- ♦ Hochschulabschluss in Informatik an der Universität von Granada

Hr. Popescu Radu, Daniel Vasile

- ♦ Spezialist für Pharmakologie, Ernährung und Diät
- ♦ Freiberuflicher Produzent von didaktischen und wissenschaftlichen Inhalten
- ♦ Kommunalen Ernährungsberater und Diätassistent
- ♦ Gemeinschaftsapotheker
- ♦ Forscher
- ♦ Masterstudiengang in Ernährung und Gesundheit an der Offenen Universität von Katalonien
- ♦ Masterstudiengang in Psychopharmakologie an der Universität von Valencia
- ♦ Hochschulabschluss in Pharmazie an der Universität Complutense von Madrid

05

Struktur und Inhalt

Diese akademische Qualifikation verbindet die wissenschaftliche Präzision der klinischen Forschung mit den bahnbrechenden Innovationen des maschinellen Lernens. Das Programm besteht aus 20 Modulen und deckt alles ab, von der Interpretation medizinischer Daten über die Entwicklung prädiktiver Algorithmen bis hin zur Implementierung technologischer Lösungen im klinischen Umfeld. Der Lehrplan bietet Inhalte, die Theorie und Praxis verbinden und die Grundlagen der KI und ihrer spezifischen Anwendung im medizinischen Bereich vermitteln. Auf diese Weise werden die Studenten darauf vorbereitet, Fortschritte bei der Personalisierung von Behandlungen und der Optimierung der Gesundheitsversorgung zu erzielen.



“

Sie werden in die Wissenschaft der Gesundheitsdaten eintauchen und Biostatistik und Big-Data-Analyse in 2.250 Stunden innovativer Inhalte erforschen"

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. KI-Implementierungsstrategie
- 1.10. Die Zukunft der künstlichen Intelligenz
 - 1.10.1. Wir wissen, wie man mit Algorithmen Emotionen erkennt
 - 1.10.2. Schaffung einer Persönlichkeit: Sprache, Ausdrücke und Inhalt
 - 1.10.3. Tendenzen der künstlichen Intelligenz
 - 1.10.4. Reflexionen

Modul 2. Datentypen und Datenlebenszyklus

- 2.1. Statistik
 - 2.1.1. Die Statistik: Deskriptive Statistik, statistische Schlussfolgerungen
 - 2.1.2. Population, Stichprobe, Individuum
 - 2.1.3. Variablen: Definition, Messskalen
- 2.2. Arten von statistischen Daten
 - 2.2.1. Je nach Typ
 - 2.2.1.1. Quantitative: kontinuierliche Daten und diskrete Daten
 - 2.2.1.2. Qualitative: 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 nichtrekursiven Algorithmen
 - 5.2.7. Mathematische Analyse von rekursiven Algorithmen
 - 5.2.8. Empirische Analyse von Algorithmen
- 5.3. Sortieralgorithmen
 - 5.3.1. Konzept der Sortierung
 - 5.3.2. Blase sortieren
 - 5.3.3. Sortieren nach Auswahl
 - 5.3.4. Reihenfolge der Insertion
 - 5.3.5. Sortierung zusammenführen (*Merge_Sort*)
 - 5.3.6. Schnelle Sortierung (*Quick_Sort*)

- 5.4. Algorithmen mit Bäumen
 - 5.4.1. Konzept des Baumes
 - 5.4.2. Binäre Bäume
 - 5.4.3. Baumpfade
 - 5.4.4. Ausdrücke darstellen
 - 5.4.5. Geordnete binäre Bäume
 - 5.4.6. Ausgeglichene binäre Bäume
- 5.5. Algorithmen mit *Heaps*
 - 5.5.1. *Heaps*
 - 5.5.2. Der *Heapsort*-Algorithmus
 - 5.5.3. Prioritätswarteschlangen
- 5.6. Graph-Algorithmen
 - 5.6.1. Vertretung
 - 5.6.2. Lauf in Breite
 - 5.6.3. Lauf in Tiefe
 - 5.6.4. Topologische Anordnung
- 5.7. *Greedy*-Algorithmen
 - 5.7.1. Die *Greedy*-Strategie
 - 5.7.2. Elemente der *Greedy*-Strategie
 - 5.7.3. Währungsumtausch
 - 5.7.4. Das Problem des Reisenden
 - 5.7.5. Problem mit dem Rucksack
- 5.8. Minimale Pfadsuche
 - 5.8.1. Das Problem des minimalen Pfades
 - 5.8.2. Negative Bögen und Zyklen
 - 5.8.3. Dijkstra-Algorithmus
- 5.9. *Greedy*-Algorithmen auf Graphen
 - 5.9.1. Der minimal aufspannende Baum
 - 5.9.2. Algorithmus von Prim
 - 5.9.3. Algorithmus von Kruskal
 - 5.9.4. Komplexitätsanalyse
- 5.10. *Backtracking*
 - 5.10.1. Das *Backtracking*
 - 5.10.2. Alternative Techniken

Modul 6. Intelligente Systeme

- 6.1. Agententheorie
 - 6.1.1. Geschichte des Konzepts
 - 6.1.2. Definition von Agent
 - 6.1.3. Agenten in der künstlichen Intelligenz
 - 6.1.4. Agenten in der Softwareentwicklung
- 6.2. Agent-Architekturen
 - 6.2.1. Der Denkprozess eines Agenten
 - 6.2.2. Reaktive Agenten
 - 6.2.3. Deduktive Agenten
 - 6.2.4. Hybride Agenten
 - 6.2.5. Vergleich
- 6.3. Informationen und Wissen
 - 6.3.1. Unterscheidung zwischen Daten, Informationen und Wissen
 - 6.3.2. Bewertung der Datenqualität
 - 6.3.3. Methoden der Datenerfassung
 - 6.3.4. Methoden der Informationsbeschaffung
 - 6.3.5. Methoden zum Wissenserwerb
- 6.4. Wissensrepräsentation
 - 6.4.1. Die Bedeutung der Wissensrepräsentation
 - 6.4.2. Definition der Wissensrepräsentation durch ihre Rollen
 - 6.4.3. Merkmale einer Wissensrepräsentation
- 6.5. Ontologien
 - 6.5.1. Einführung in Metadaten
 - 6.5.2. Philosophisches Konzept der Ontologie
 - 6.5.3. Computergestütztes Konzept der Ontologie
 - 6.5.4. Bereichsontologien und Ontologien auf höherer Ebene
 - 6.5.5. Wie erstellt man eine Ontologie?
- 6.6. Ontologiesprachen und Software für die Erstellung von Ontologien
 - 6.6.1. RDF-Tripel, *Turtle* und N
 - 6.6.2. RDF-Schema
 - 6.6.3. OWL

- 6.6.4. SPARQL
- 6.6.5. Einführung in die verschiedenen Tools für die Erstellung von Ontologien
- 6.6.6. Installation und Verwendung von *Protégé*
- 6.7. Das semantische Web
 - 6.7.1. Der aktuelle Stand und die Zukunft des semantischen Webs
 - 6.7.2. Anwendungen des Semantischen Webs
- 6.8. Andere Modelle der Wissensdarstellung
 - 6.8.1. Wortschatz
 - 6.8.2. Globale Sicht
 - 6.8.3. Taxonomie
 - 6.8.4. Thesauri
 - 6.8.5. Folksonomien
 - 6.8.6. Vergleich
 - 6.8.7. Mind Map
- 6.9. Bewertung und Integration von Wissensrepräsentationen
 - 6.9.1. Logik nullter Ordnung
 - 6.9.2. Logik erster Ordnung
 - 6.9.3. Beschreibende Logik
 - 6.9.4. Beziehung zwischen verschiedenen Arten von Logik
 - 6.9.5. *Prolog*: Programmierung auf Basis der Logik erster Ordnung
- 6.10. Semantische Reasoner, wissensbasierte Systeme und Expertensysteme
 - 6.10.1. Konzept des Reasoners
 - 6.10.2. Anwendungen eines Reasoners
 - 6.10.3. Wissensbasierte Systeme
 - 6.10.4. MYCIN, Geschichte der Expertensysteme
 - 6.10.5. Elemente und Architektur von Expertensystemen
 - 6.10.6. Erstellung von Expertensystemen

Modul 7. Maschinelles Lernen und *Data Mining*

- 7.1. Einführung in die Prozesse der Wissensentdeckung und in die grundlegenden Konzepte des maschinellen Lernens
 - 7.1.1. Schlüsselkonzepte von Prozessen der Wissensentdeckung
 - 7.1.2. Historische Perspektive der Wissensentdeckungsprozesse
 - 7.1.3. Phasen des Wissensentdeckungsprozesses
 - 7.1.4. Techniken, die bei der Wissensentdeckung eingesetzt werden

- 7.1.5. Merkmale guter Modelle für maschinelles Lernen
- 7.1.6. Arten von Informationen zum maschinellen Lernen
- 7.1.7. Grundlegende Lernkonzepte
- 7.1.8. Grundlegende Konzepte des unüberwachten Lernens
- 7.2. Datenexploration und Vorverarbeitung
 - 7.2.1. Datenverarbeitung
 - 7.2.2. Datenverarbeitung im Datenanalysefluss
 - 7.2.3. Datentypen
 - 7.2.4. Datenumwandlung
 - 7.2.5. Anzeige und Untersuchung von kontinuierlichen Variablen
 - 7.2.6. Anzeige und Erkundung kategorialer Variablen
 - 7.2.7. Korrelationsmaßnahmen
 - 7.2.8. Die häufigsten grafischen Darstellungen
 - 7.2.9. Einführung in die multivariate Analyse und Dimensionsreduktion
- 7.3. Entscheidungsbaum
 - 7.3.1. ID-Algorithmus
 - 7.3.2. Algorithmus C
 - 7.3.3. Übertraining und Beschneidung
 - 7.3.4. Analyse der Ergebnisse
- 7.4. Bewertung von Klassifikatoren
 - 7.4.1. Konfusionsmatrizen
 - 7.4.2. Numerische Bewertungsmatrizen
 - 7.4.3. Kappa-Statistik
 - 7.4.4. Die ROC-Kurve
- 7.5. Klassifizierungsregeln
 - 7.5.1. Maßnahmen zur Bewertung von Regeln
 - 7.5.2. Einführung in die grafische Darstellung
 - 7.5.3. Sequentieller Überlagerungsalgorithmus
- 7.6. Neuronale Netze
 - 7.6.1. Grundlegende Konzepte
 - 7.6.2. Einfache neuronale Netze
 - 7.6.3. *Backpropagation*-Algorithmus
 - 7.6.4. Einführung in rekurrente neuronale Netze

- 7.7. Bayessche Methoden
 - 7.7.1. Grundlegende Konzepte der Wahrscheinlichkeit
 - 7.7.2. Bayes-Theorem
 - 7.7.3. Naive Bayes
 - 7.7.4. Einführung in Bayessche Netzwerke
- 7.8. Regressions- und kontinuierliche Antwortmodelle
 - 7.8.1. Einfache lineare Regression
 - 7.8.2. Multiple lineare Regression
 - 7.8.3. Logistische Regression
 - 7.8.4. Regressionsbäume
 - 7.8.5. Einführung in Support Vector Machines (SVM)
 - 7.8.6. Maße für die Anpassungsgüte
- 7.9. *Clustering*
 - 7.9.1. Grundlegende Konzepte
 - 7.9.2. Hierarchisches *Clustering*
 - 7.9.3. Probabilistische Methoden
 - 7.9.4. EM-Algorithmus
 - 7.9.5. *B-Cubed*-Methode
 - 7.9.6. Implizite Methoden
- 7.10. *Text Mining* und natürliche Sprachverarbeitung (NLP)
 - 7.10.1. Grundlegende Konzepte
 - 7.10.2. Erstellung eines Korpus
 - 7.10.3. Deskriptive Analyse
 - 7.10.4. Einführung in die Stimmungsanalyse

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

- 8.1. Tiefes Lernen
 - 8.1.1. Arten von tiefem Lernen
 - 8.1.2. Anwendungen von tiefem Lernen
 - 8.1.3. Vor- und Nachteile von tiefem Lernen
- 8.2. Operationen
 - 8.2.1. Addition
 - 8.2.2. Produkt
 - 8.2.3. Transfer
- 8.3. Ebenen
 - 8.3.1. Eingangsebene
 - 8.3.2. Ausgeblendete Ebene
 - 8.3.3. Ausgangsebene
- 8.4. Schichtenverbund und Operationen
 - 8.4.1. Design-Architekturen
 - 8.4.2. Verbindung zwischen Ebenen
 - 8.4.3. Vorwärtsausbreitung
- 8.5. Aufbau des ersten neuronalen Netzes
 - 8.5.1. Entwurf des Netzes
 - 8.5.2. Festlegen der Gewichte
 - 8.5.3. Training des Netzes
- 8.6. Trainer und Optimierer
 - 8.6.1. Auswahl des Optimierers
 - 8.6.2. Festlegen einer Verlustfunktion
 - 8.6.3. Festlegung einer Metrik
- 8.7. Anwendung der Prinzipien des neuronalen Netzes
 - 8.7.1. Aktivierungsfunktionen
 - 8.7.2. Rückwärtsausbreitung
 - 8.7.3. Einstellung der Parameter
- 8.8. Von biologischen zu künstlichen Neuronen
 - 8.8.1. Funktionsweise eines biologischen Neurons
 - 8.8.2. Wissensübertragung auf künstliche Neuronen
 - 8.8.3. Herstellung von Beziehungen zwischen den beiden
- 8.9. Implementierung von MLP (Multilayer Perceptron) mit Keras
 - 8.9.1. Definition der Netzstruktur
 - 8.9.2. Modell-Kompilierung
 - 8.9.3. Modell-Training
- 8.10. Feinabstimmung der Hyperparameter von neuronalen Netzen
 - 8.10.1. Auswahl der Aktivierungsfunktion
 - 8.10.2. Einstellung der *Learning Rate*
 - 8.10.3. Einstellung der Gewichte

Modul 9. Training Tiefer Neuronaler Netze

- 9.1. Gradienten-Probleme
 - 9.1.1. Techniken der Gradientenoptimierung
 - 9.1.2. Stochastische Gradienten
 - 9.1.3. Techniken zur Initialisierung der Gewichte
- 9.2. Wiederverwendung von vortrainierten Schichten
 - 9.2.1. *Transfer Learning Training*
 - 9.2.2. Merkmalsextraktion
 - 9.2.3. Tiefes Lernen
- 9.3. Optimierer
 - 9.3.1. Stochastische Gradientenabstiegs-Optimierer
 - 9.3.2. Adam- und *RMSprop*-Optimierer
 - 9.3.3. Moment-Optimierer
- 9.4. Planen der Lernrate
 - 9.4.1. Automatische Steuerung der Lernrate
 - 9.4.2. Lernzyklen
 - 9.4.3. Bedingungen für die Glättung
- 9.5. Überanpassung
 - 9.5.1. Kreuzvalidierung
 - 9.5.2. Regulierung
 - 9.5.3. Bewertungsmetriken
- 9.6. Praktische Leitlinien
 - 9.6.1. Entwurf des Modells
 - 9.6.2. Auswahl der Metriken und Bewertungsparameter
 - 9.6.3. Testen von Hypothesen
- 9.7. *Transfer Learning*
 - 9.7.1. *Transfer Learning Training*
 - 9.7.2. Merkmalsextraktion
 - 9.7.3. Tiefes Lernen
- 9.8. *Data Augmentation*
 - 9.8.1. Bildtransformationen
 - 9.8.2. Generierung synthetischer Daten
 - 9.8.3. Textumwandlung

- 9.9. Praktische Anwendung von *Transfer Learning*
 - 9.9.1. *Transfer Learning Training*
 - 9.9.2. Merkmalsextraktion
 - 9.9.3. Tiefes Lernen
- 9.10. Regulierung
 - 9.10.1. L und L
 - 9.10.2. Maximale Entropie-Regularisierung
 - 9.10.3. *Dropout*

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

- 10.1. *TensorFlow*
 - 10.1.1. Verwendung der *TensorFlow*-Bibliothek
 - 10.1.2. Training von Modellen mit *TensorFlow*
 - 10.1.3. Operationen mit Graphen in *TensorFlow*
- 10.2. *TensorFlow* und NumPy
 - 10.2.1. NumPy-Berechnungsumgebung für *TensorFlow*
 - 10.2.2. Verwendung von NumPy-Arrays mit *TensorFlow*
 - 10.2.3. NumPy-Operationen für *TensorFlow*-Graphen
- 10.3. Anpassung von Modellen und Trainingsalgorithmen
 - 10.3.1. Erstellen von benutzerdefinierten Modellen mit *TensorFlow*
 - 10.3.2. Verwaltung von Trainingsparametern
 - 10.3.3. Verwendung von Optimierungstechniken für das Training
- 10.4. *TensorFlow*-Funktionen und -Graphen
 - 10.4.1. Funktionen mit *TensorFlow*
 - 10.4.2. Verwendung von Graphen für das Modelltraining
 - 10.4.3. Optimieren von Graphen mit *TensorFlow*-Operationen
- 10.5. Laden und Vorverarbeiten von Daten mit *TensorFlow*
 - 10.5.1. Laden von Datensätzen mit *TensorFlow*
 - 10.5.2. Vorverarbeiten von Daten mit *TensorFlow*
 - 10.5.3. Verwendung von *TensorFlow*-Tools zur Datenmanipulation

- 10.6. Die *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. 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 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 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 *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. 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. Diagnose in der klinischen Praxis mit KI

- 16.1. Technologien und Werkzeuge für die KI-gestützte Diagnose
 - 16.1.1. Softwareentwicklung für KI-gestützte Diagnose in verschiedenen medizinischen Fachbereichen
 - 16.1.2. Einsatz fortschrittlicher Algorithmen zur schnellen und genauen Analyse klinischer Symptome und Anzeichen
 - 16.1.3. Integration von KI in Diagnosegeräte zur Verbesserung der Effizienz
 - 16.1.4. KI-Tools zur Unterstützung bei der Interpretation von Labortestergebnissen
- 16.2. Integration von multimodalen klinischen Daten für die Diagnose
 - 16.2.1. KI-Systeme zur Kombination von Daten aus Bildgebung, Labor und Krankenakten
 - 16.2.2. Werkzeuge zur Korrelation multimodaler Daten für eine genauere Diagnose
 - 16.2.3. Einsatz von KI zur Analyse komplexer Muster aus verschiedenen Arten von klinischen Daten
 - 16.2.4. Integration von genomischen und molekularen Daten in die KI-gestützte Diagnose
- 16.3. Erstellung und Analyse von *Datasets* im Gesundheitswesen mit KI
 - 16.3.1. Entwicklung von klinischen Datenbanken für das Training von KI-Modellen
 - 16.3.2. Einsatz von KI für die Analyse und Gewinnung von *Insights* aus großen Gesundheitsdatensätzen
 - 16.3.3. KI-Tools für die Bereinigung und Aufbereitung klinischer Daten
 - 16.3.4. KI-Systeme zur Erkennung von Trends und Mustern in Gesundheitsdaten
- 16.4. Visualisierung und Verwaltung von Gesundheitsdaten mit KI
 - 16.4.1. KI-Tools für die interaktive und verständliche Visualisierung von Gesundheitsdaten
 - 16.4.2. KI-Systeme für den effizienten Umgang mit großen Mengen klinischer Daten
 - 16.4.3. Einsatz von KI-basierten *Dashboards* zur Überwachung von Gesundheitsindikatoren
 - 16.4.4. KI-Technologien für die Verwaltung und Sicherheit von Gesundheitsdaten

- 16.5. Mustererkennung und *Machine Learning* in der klinischen Diagnostik
 - 16.5.1. Anwendung von Techniken des *Machine Learning* zur Mustererkennung in klinischen Daten
 - 16.5.2. Einsatz von KI bei der Früherkennung von Krankheiten durch Musteranalyse
 - 16.5.3. Entwicklung von Vorhersagemodellen für genauere Diagnosen
 - 16.5.4. Einsatz von Algorithmen des maschinellen Lernens bei der Interpretation von Gesundheitsdaten
 - 16.6. Interpretation medizinischer Bilder mit Hilfe von KI
 - 16.6.1. KI-Systeme für die Erkennung und Klassifizierung von Anomalien in medizinischen Bildern
 - 16.6.2. Einsatz von *Deep Learning* bei der Interpretation von Röntgen-, MRT- und CT-Scans
 - 16.6.3. KI-Tools zur Verbesserung der Genauigkeit und Schnelligkeit bei der bildgebenden Diagnose
 - 16.6.4. Implementierung von KI für bildbasierte klinische Entscheidungshilfen
 - 16.7. Verarbeitung natürlicher Sprache in Krankenakten für die klinische Diagnose
 - 16.7.1. Einsatz von NLP für die Extraktion relevanter Informationen aus Krankenakten
 - 16.7.2. KI-Systeme zur Analyse von Arztbriefen und Patientenberichten
 - 16.7.3. KI-Tools zur Zusammenfassung und Klassifizierung von Informationen aus Krankenakten
 - 16.7.4. Anwendung von NLP bei der Identifizierung von Symptomen und Diagnosen aus klinischen Texten
 - 16.8. Validierung und Bewertung von KI-gestützten Diagnosemodellen
 - 16.8.1. Methoden für die Validierung und das Testen von KI-Modellen in realen klinischen Umgebungen
 - 16.8.2. Bewertung der Leistung und Genauigkeit von KI-gestützten Diagnoseinstrumenten
 - 16.8.3. Einsatz von KI zur Gewährleistung der Zuverlässigkeit und Ethik der klinischen Diagnostik
 - 16.8.4. Einführung von Protokollen zur kontinuierlichen Bewertung von KI-Systemen in der Gesundheitsversorgung
 - 16.9. KI bei der Diagnose seltener Krankheiten
 - 16.9.1. Entwicklung von spezialisierten KI-Systemen zur Erkennung seltener Krankheiten
 - 16.9.2. Einsatz von KI zur Analyse von atypischen Mustern und komplexer Symptomatik
 - 16.9.3. KI-Tools für die frühe und genaue Diagnose seltener Krankheiten
 - 16.9.4. Implementierung von globalen KI-gestützten Datenbanken zur Verbesserung der Diagnose seltener Krankheiten
 - 16.10. Erfolgsgeschichten und Herausforderungen bei der Implementierung von KI-Diagnostik
 - 16.10.1. Analyse von Fallstudien, in denen KI die klinische Diagnose erheblich verbessert hat
 - 16.10.2. Bewertung der Herausforderungen bei der Einführung von KI im klinischen Umfeld
 - 16.10.3. Diskussion der ethischen und praktischen Hindernisse für die Einführung von KI in der Diagnostik
 - 16.10.4. Untersuchung von Strategien zur Überwindung von Hindernissen bei der Integration von KI in die medizinische Diagnostik
- Modul 17. Behandlung und Management von Patienten mit KI**
- 17.1. KI-unterstützte Behandlungssysteme
 - 17.1.1. Entwicklung von KI-Systemen zur Unterstützung bei der therapeutischen Entscheidungsfindung
 - 17.1.2. Einsatz von KI zur Personalisierung von Behandlungen auf der Grundlage individueller Profile
 - 17.1.3. Einsatz von KI-Tools bei der Verabreichung von Dosierungen und Medikamentenplänen
 - 17.1.4. Integration von KI in die Echtzeitüberwachung und Behandlungsanpassung
 - 17.2. Definition von Indikatoren für die Kontrolle des Gesundheitszustands der Patienten
 - 17.2.1. Festlegung von Schlüsselparametern für die Überwachung des Gesundheitszustands von Patienten durch KI
 - 17.2.2. Einsatz von KI zur Ermittlung prädiktiver Indikatoren für Gesundheit und Krankheit
 - 17.2.3. Entwicklung von Frühwarnsystemen auf der Grundlage von Gesundheitsindikatoren
 - 17.2.4. Einsatz von KI für die kontinuierliche Bewertung des Gesundheitszustands von Patienten

- 17.3. Instrumente zur Überwachung und Kontrolle von Gesundheitsindikatoren
 - 17.3.1. Entwicklung von mobilen Anwendungen und Wearables mit KI für die Gesundheitsüberwachung
 - 17.3.2. Implementierung von KI-Systemen für die Echtzeitanalyse von Gesundheitsdaten
 - 17.3.3. Einsatz von KI-basierten *Dashboards* zur Visualisierung und Überwachung von Gesundheitsindikatoren
 - 17.3.4. Integration von IoT-Geräten in die kontinuierliche Überwachung von Gesundheitsindikatoren mittels KI
 - 17.4. KI bei der Planung und Durchführung medizinischer Eingriffe
 - 17.4.1. Einsatz von KI-Systemen zur Optimierung der Planung von Operationen und medizinischen Eingriffen
 - 17.4.2. Einsatz von KI in der Simulation und Praxis chirurgischer Eingriffe
 - 17.4.3. Einsatz von KI zur Verbesserung der Genauigkeit und Effizienz bei der Durchführung medizinischer Verfahren
 - 17.4.4. Anwendung von KI bei der Koordinierung und Verwaltung von chirurgischen Ressourcen
 - 17.5. Algorithmen des maschinellen Lernens für die Festlegung von therapeutischen Behandlungen
 - 17.5.1. Einsatz des *Machine Learning* zur Entwicklung personalisierter Behandlungsprotokolle
 - 17.5.2. Implementierung von prädiktiven Algorithmen für die Auswahl wirksamer Therapien
 - 17.5.3. Entwicklung von KI-Systemen für die Anpassung der Behandlung in Echtzeit
 - 17.5.4. Anwendung von KI bei der Analyse der Wirksamkeit verschiedener therapeutischer Optionen
 - 17.6. Anpassungsfähigkeit und kontinuierliche Aktualisierung von Therapieprotokollen durch KI
 - 17.6.1. Implementierung von KI-Systemen zur dynamischen Überprüfung und Aktualisierung von Behandlungen
 - 17.6.2. Einsatz von KI bei der Anpassung von Therapieprotokollen an neue Erkenntnisse und Daten
 - 17.6.3. Entwicklung von KI-Tools zur kontinuierlichen Personalisierung der Behandlung
 - 17.6.4. Integration von KI in die adaptive Reaktion auf sich entwickelnde Patientenbedingungen
 - 17.7. Optimierung von Gesundheitsdiensten mit KI-Technologie
 - 17.7.1. Einsatz von KI zur Verbesserung der Effizienz und Qualität von Gesundheitsdiensten
 - 17.7.2. Implementierung von KI-Systemen für das Ressourcenmanagement im Gesundheitswesen
 - 17.7.3. Entwicklung von KI-Tools für die Optimierung von Krankenhausabläufen
 - 17.7.4. Anwendung von KI zur Verkürzung von Wartezeiten und Verbesserung der Patientenversorgung
 - 17.8. Anwendung von KI in der medizinischen Notfallhilfe
 - 17.8.1. Implementierung von KI-Systemen für das schnelle und effiziente Management von Gesundheitskrisen
 - 17.8.2. Einsatz von KI bei der Optimierung der Ressourcenzuweisung in Notfällen
 - 17.8.3. Entwicklung von KI-Tools für die Vorhersage von Krankheitsausbrüchen und die Reaktion darauf
 - 17.8.4. Integration von KI in Warn- und Kommunikationssysteme bei gesundheitlichen Notfällen
 - 17.9. Interdisziplinäre Zusammenarbeit bei KI-gestützten Behandlungen
 - 17.9.1. Förderung der Zusammenarbeit zwischen verschiedenen medizinischen Fachrichtungen unter Verwendung von KI-Systemen
 - 17.9.2. Einsatz von KI zur Integration von Wissen und Techniken aus verschiedenen Disziplinen in die Behandlung
 - 17.9.3. Entwicklung von KI-Plattformen zur Erleichterung der interdisziplinären Kommunikation und Koordination
 - 17.9.4. Einsatz von KI bei der Bildung von multidisziplinären Behandlungsteams
 - 17.10. Erfolgreiche Erfahrungen mit KI im Krankheitsmanagement
 - 17.10.1. Analyse von Erfolgsgeschichten beim Einsatz von KI für wirksame Krankheitsbehandlungen
 - 17.10.2. Bewertung der Auswirkungen von KI auf die Verbesserung von Behandlungsergebnissen
 - 17.10.3. Dokumentation innovativer Erfahrungen mit dem Einsatz von KI in verschiedenen medizinischen Bereichen
 - 17.10.4. Debatte über Fortschritte und Herausforderungen bei der Implementierung von KI in medizinischen Behandlungen
- Modul 18. Personalisierung der Gesundheit durch KI**
- 18.1. KI-Anwendungen in der Genomik für die personalisierte Medizin
 - 18.1.1. Entwicklung von KI-Algorithmen für die Analyse genetischer Sequenzen und deren Zusammenhang mit Krankheiten
 - 18.1.2. Einsatz von KI bei der Identifizierung von genetischen Markern für personalisierte Behandlungen

- 18.1.3. Einsatz von KI für die schnelle und genaue Interpretation von Genomdaten
- 18.1.4. KI-Tools für die Korrelation von Genotypen mit dem Ansprechen auf Medikamente
- 18.2. KI in der Pharmakogenomik und Arzneimittelentwicklung
 - 18.2.1. Entwicklung von KI-Modellen zur Vorhersage der Wirksamkeit und Sicherheit von Arzneimitteln
 - 18.2.2. Einsatz von KI bei der Identifizierung von Targets und der Entwicklung von Medikamenten
 - 18.2.3. Anwendung von KI bei der Analyse von Gen-Wirkstoff-Interaktionen zur Personalisierung der Behandlung
 - 18.2.4. Implementierung von KI-Algorithmen zur Beschleunigung der Arzneimittelentdeckung
- 18.3. Personalisierte Überwachung mit intelligenten Geräten und KI
 - 18.3.1. Entwicklung von KI-fähigen Wearables zur kontinuierlichen Überwachung von Gesundheitsindikatoren
 - 18.3.2. Einsatz von KI bei der Interpretation der von intelligenten Geräten gesammelten Daten
 - 18.3.3. Einführung von KI-basierten Frühwarnsystemen für Gesundheitszustände
 - 18.3.4. KI-Tools zur Personalisierung von Lebensstil- und Gesundheitsempfehlungen
- 18.4. Klinische Entscheidungshilfesysteme mit KI
 - 18.4.1. Implementierung von KI zur Unterstützung von Ärzten bei der klinischen Entscheidungsfindung
 - 18.4.2. Entwicklung von KI-Systemen, die auf der Grundlage klinischer Daten Empfehlungen aussprechen
 - 18.4.3. Einsatz von KI bei der Risiko/Nutzen-Bewertung verschiedener therapeutischer Optionen
 - 18.4.4. KI-Tools für die Echtzeitintegration und -analyse von Gesundheitsdaten
- 18.5. Trends in der Gesundheitspersonalisierung mit KI
 - 18.5.1. Analyse der neuesten Trends in der KI für die Personalisierung der Gesundheitsversorgung
 - 18.5.2. Einsatz von KI bei der Entwicklung von präventiven und prädiktiven Ansätzen im Gesundheitswesen
 - 18.5.3. Einsatz von KI bei der Anpassung von Gesundheitsplänen an die individuellen Bedürfnisse
 - 18.5.4. Erforschung neuer KI-Technologien auf dem Gebiet der personalisierten Gesundheitsversorgung
- 18.6. Fortschritte in der KI-unterstützten chirurgischen Robotik
 - 18.6.1. Entwicklung von KI-gestützten chirurgischen Robotern für präzise und minimalinvasive Eingriffe
 - 18.6.2. Einsatz von KI zur Verbesserung der Präzision und Sicherheit bei robotergestützter Chirurgie
 - 18.6.3. Implementierung von KI-Systemen für die chirurgische Planung und Operationssimulation
 - 18.6.4. Fortschritte bei der Integration von taktilem und visuellem *Feedback* in der chirurgischen Robotik mit KI
- 18.7. Entwicklung von Vorhersagemodellen für die personalisierte klinische Praxis
 - 18.7.1. Einsatz von KI zur Erstellung von Vorhersagemodellen für Krankheiten auf der Grundlage individueller Daten
 - 18.7.2. Einsatz von KI bei der Vorhersage von Behandlungserfolgen
 - 18.7.3. Entwicklung von KI-Tools zur Vorhersage von Gesundheitsrisiken
 - 18.7.4. Anwendung von Vorhersagemodellen bei der Planung von Präventivmaßnahmen
- 18.8. KI in der personalisierten Schmerzbehandlung und -therapie
 - 18.8.1. Entwicklung von KI-Systemen für die personalisierte Bewertung und Behandlung von Schmerzen
 - 18.8.2. Einsatz von KI bei der Ermittlung von Schmerzmustern und Reaktionen auf die Behandlung
 - 18.8.3. Einsatz von KI-Tools für die Personalisierung der Schmerztherapie
 - 18.8.4. Anwendung von KI bei der Überwachung und Anpassung von Schmerzbehandlungsplänen
- 18.9. Patientenautonomie und aktive Beteiligung an der Personalisierung
 - 18.9.1. Förderung der Patientenautonomie durch KI-Tools für das Management ihrer Gesundheitsversorgung
 - 18.9.2. Entwicklung von KI-Systemen, die Patienten in die Lage versetzen, Entscheidungen zu treffen
 - 18.9.3. Einsatz von KI zur Bereitstellung personalisierter Patienteninformationen und -aufklärung
 - 18.9.4. KI-Tools, die die aktive Beteiligung der Patienten an ihrer Behandlung erleichtern

- 18.10. Integration von KI in elektronische Krankenakten
 - 18.10.1. Implementierung von KI zur effizienten Analyse und Verwaltung elektronischer Krankenakten
 - 18.10.2. Entwicklung von KI-Tools für die Gewinnung klinischer *Insights* aus elektronischen Aufzeichnungen
 - 18.10.3. Einsatz von KI zur Verbesserung der Datengenauigkeit und -zugänglichkeit in Krankenakten
 - 18.10.4. Anwendung von KI zur Korrelation von Daten aus Krankenakten mit Behandlungsplänen

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

- 19.1. Grundlagen von *Big Data* im Gesundheitswesen
 - 19.1.1. Die Datenexplosion im Gesundheitswesen
 - 19.1.2. Das Konzept von *Big Data* und die wichtigsten Tools
 - 19.1.3. Anwendungen von *Big Data* im Gesundheitswesen
- 19.2. Textverarbeitung und Analyse von Gesundheitsdaten
 - 19.2.1. Konzepte der natürlichen Sprachverarbeitung
 - 19.2.2. *Embedding*-Techniken
 - 19.2.3. Anwendung der natürlichen Sprachverarbeitung im Gesundheitswesen
- 19.3. Fortgeschrittene Methoden des Datenabrufs im Gesundheitswesen
 - 19.3.1. Erforschung innovativer Techniken für einen effizienten Datenabruf im Gesundheitswesen
 - 19.3.2. Entwicklung fortgeschrittener Strategien für die Extraktion und Organisation von Informationen im Gesundheitswesen
 - 19.3.3. Implementierung von adaptiven und maßgeschneiderten Datenabrufmethoden für verschiedene klinische Kontexte
- 19.4. Qualitätsbewertung bei der Analyse von Gesundheitsdaten
 - 19.4.1. Entwicklung von Indikatoren für eine präzise Bewertung der Datenqualität im Gesundheitswesen
 - 19.4.2. Einführung von Instrumenten und Protokollen zur Sicherstellung der Qualität der in klinischen Analysen verwendeten Daten
 - 19.4.3. Kontinuierliche Bewertung der Genauigkeit und Zuverlässigkeit der Ergebnisse von Projekten zur Analyse von Gesundheitsdaten
- 19.5. *Data Mining* und maschinelles Lernen im Gesundheitswesen
 - 19.5.1. Die wichtigsten Methoden für *Data Mining*
 - 19.5.2. Integration von Gesundheitsdaten
 - 19.5.3. Erkennung von Mustern und Anomalien in Gesundheitsdaten
- 19.6. Innovative Bereiche von *Big Data* und KI im Gesundheitswesen
 - 19.6.1. Erkundung neuer Grenzen bei der Anwendung von *Big Data* und KI zur Umgestaltung des Gesundheitssektors
 - 19.6.2. Identifizierung innovativer Möglichkeiten für die Integration von *Big Data*- und KI-Technologien in die medizinische Praxis
 - 19.6.3. Entwicklung bahnbrechender Ansätze zur Maximierung des Potenzials von *Big Data* und KI im Gesundheitswesen
- 19.7. Erfassung und Vorverarbeitung von medizinischen Daten
 - 19.7.1. Entwicklung effizienter Methoden für die Erfassung medizinischer Daten in klinischen und Forschungsumgebungen
 - 19.7.2. Anwendung fortgeschrittener Vorverarbeitungstechniken zur Optimierung der Qualität und Nützlichkeit medizinischer Daten
 - 19.7.3. Entwicklung von Erfassungs- und Vorverarbeitungsstrategien, die die Vertraulichkeit und den Schutz medizinischer Informationen gewährleisten
- 19.8. Datenvisualisierung und -kommunikation im Gesundheitswesen
 - 19.8.1. Entwicklung innovativer Visualisierungswerkzeuge im Gesundheitswesen
 - 19.8.2. Kreative Strategien der Gesundheitskommunikation
 - 19.8.3. Integration interaktiver Technologien im Gesundheitsbereich
- 19.9. Datensicherheit und -verwaltung im Gesundheitswesen
 - 19.9.1. Entwicklung umfassender Datensicherheitsstrategien zum Schutz der Vertraulichkeit und der Privatsphäre im Gesundheitswesen
 - 19.9.2. Einführung eines wirksamen *Governance*-Rahmens zur Gewährleistung eines ethischen und verantwortungsvollen Umgangs mit Daten im medizinischen Umfeld
 - 19.9.3. Entwicklung von Strategien und Verfahren zur Gewährleistung der Integrität und Verfügbarkeit medizinischer Daten unter Berücksichtigung der spezifischen Herausforderungen des Gesundheitswesens
- 19.10. Praktische Anwendungen von *Big Data* im Gesundheitswesen
 - 19.10.1. Entwicklung spezialisierter Lösungen zur Verwaltung und Analyse großer Datenmengen im Gesundheitswesen
 - 19.10.2. Einsatz praktischer Tools auf der Grundlage von *Big Data* zur Unterstützung der klinischen Entscheidungsfindung
 - 19.10.3. Anwendung innovativer *Big Data*-Ansätze zur Bewältigung spezifischer Herausforderungen im Gesundheitssektor

Modul 20. Ethik und Regulierung in der medizinischen KI


- 20.1. Ethische Grundsätze für den Einsatz von KI in der Medizin
 - 20.1.1. Analyse und Anwendung ethischer Grundsätze bei der Entwicklung und Nutzung von medizinischen KI-Systemen
 - 20.1.2. Integration ethischer Werte in die KI-gestützte Entscheidungsfindung in medizinischen Kontexten
 - 20.1.3. Erarbeitung ethischer Richtlinien zur Gewährleistung eines verantwortungsvollen Einsatzes von künstlicher Intelligenz in der Medizin
- 20.2. Datenschutz und Einwilligung in medizinischen Kontexten
 - 20.2.1. Entwicklung von Datenschutzrichtlinien zum Schutz sensibler Daten in medizinischen KI-Anwendungen
 - 20.2.2. Sicherstellung einer informierten Zustimmung bei der Erhebung und Nutzung von personenbezogenen Daten im medizinischen Kontext
 - 20.2.3. Implementierung von Sicherheitsmaßnahmen zum Schutz der Privatsphäre von Patienten in medizinischen KI-Umgebungen
- 20.3. Ethik in der Forschung und Entwicklung von medizinischen KI-Systemen
 - 20.3.1. Ethische Bewertung von Forschungsprotokollen bei der Entwicklung von medizinischen KI-Systemen
 - 20.3.2. Gewährleistung von Transparenz und ethischer Strenge in der Entwicklungs- und Validierungsphase von medizinischen KI-Systemen
 - 20.3.3. Ethische Erwägungen bei der Veröffentlichung und Weitergabe von Ergebnissen auf dem Gebiet der medizinischen KI
- 20.4. Soziale Auswirkungen und Verantwortlichkeit in der medizinischen KI
 - 20.4.1. Analyse der sozialen Auswirkungen der KI auf die Gesundheitsversorgung
 - 20.4.2. Entwicklung von Strategien zur Risikominimierung und ethischen Verantwortung bei KI-Anwendungen in der Medizin
 - 20.4.3. Laufende Bewertung der sozialen Auswirkungen und Anpassung von KI-Systemen, um einen positiven Beitrag zur öffentlichen Gesundheit zu leisten
- 20.5. Nachhaltige Entwicklung von KI im Gesundheitswesen
 - 20.5.1. Integration nachhaltiger Praktiken in die Entwicklung und Instandhaltung von KI-Systemen im Gesundheitswesen
 - 20.5.2. Bewertung der ökologischen und wirtschaftlichen Auswirkungen von KI-Technologien im Gesundheitssektor
 - 20.5.3. Entwicklung nachhaltiger Geschäftsmodelle zur Gewährleistung der Kontinuität und Verbesserung von KI-Lösungen im Gesundheitswesen
- 20.6. *Data Governance* und internationale regulatorische Rahmenbedingungen in der medizinischen KI
 - 20.6.1. Entwicklung eines *Governance*-Rahmens für eine ethische und effiziente Datenverwaltung bei medizinischen KI-Anwendungen
 - 20.6.2. Anpassung an internationale Standards und Vorschriften zur Gewährleistung der ethischen und rechtlichen Konformität
 - 20.6.3. Aktive Beteiligung an internationalen Initiativen zur Festlegung ethischer Standards bei der Entwicklung medizinischer KI-Systeme
- 20.7. Wirtschaftliche Aspekte der KI im Gesundheitswesen
 - 20.7.1. Analyse der wirtschaftlichen Auswirkungen und des Kosten-Nutzen-Verhältnisses bei der Einführung von KI-Systemen im Gesundheitswesen
 - 20.7.2. Entwicklung von Geschäftsmodellen und Finanzierung zur Erleichterung der Einführung von KI-Technologien im Gesundheitssektor
 - 20.7.3. Bewertung der wirtschaftlichen Effizienz und Gerechtigkeit beim Zugang zu KI-gesteuerten Gesundheitsdiensten
- 20.8. Menschenzentrierte Gestaltung von medizinischen KI-Systemen
 - 20.8.1. Integration von Prinzipien der menschenzentrierten Gestaltung zur Verbesserung der Benutzerfreundlichkeit und Akzeptanz von medizinischen KI-Systemen
 - 20.8.2. Einbeziehung von Fachkräften des Gesundheitswesens und Patienten in den Gestaltungsprozess, um die Relevanz und Wirksamkeit von Lösungen zu gewährleisten
 - 20.8.3. Kontinuierliche Bewertung der Nutzererfahrung und des Feedbacks zur Optimierung der Interaktion mit KI-Systemen im medizinischen Umfeld
- 20.9. Gleichheit und Transparenz beim maschinellen Lernen in der Medizin
 - 20.9.1. Entwicklung von Modellen für maschinelles Lernen in der Medizin, die Gleichheit und Transparenz fördern
 - 20.9.2. Umsetzung von Praktiken zur Abschwächung von Verzerrungen und zur Gewährleistung von Gleichheit bei der Anwendung von KI-Algorithmen im Gesundheitswesen
 - 20.9.3. Kontinuierliche Bewertung von Gleichheit und Transparenz bei der Entwicklung und dem Einsatz von Lösungen für maschinelles Lernen in der Medizin
- 20.10. Sicherheit und Politik bei der Implementierung von KI in der Medizin
 - 20.10.1. Entwicklung von Sicherheitsrichtlinien zum Schutz der Integrität und Vertraulichkeit von Daten in medizinischen KI-Anwendungen
 - 20.10.2. Umsetzung von Sicherheitsmaßnahmen beim Einsatz von KI-Systemen zur Vermeidung von Risiken und zur Gewährleistung der Patientensicherheit
 - 20.10.3. Kontinuierliche Evaluierung der Sicherheitsrichtlinien zur Anpassung an technologische Fortschritte und neue Herausforderungen beim Einsatz von medizinischer KI

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 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 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

