

Privater Masterstudiengang Künstliche Intelligenz in der Klinischen Forschung



Privater Masterstudiengang Künstliche Intelligenz in der Klinischen Forschung

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

Internetzugang: www.techtitute.com/de/kunstliche-intelligenz/masterstudiengang/masterstudiengang-kunstliche-intelligenz-klinischen-forschung

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

In der klinischen Forschung ist die künstliche Intelligenz (KI) zu einem unverzichtbaren Instrument geworden, um große Datenmengen effizient und genau zu analysieren. Auf diese Weise trägt dieses System zu bedeutenden Fortschritten sowohl beim Verständnis als auch bei der Behandlung von Krankheiten bei. Bei Krebs beispielsweise wird maschinelles Lernen eingesetzt, um Tumorerkrankungen in hochauflösenden medizinischen Bildern zu erkennen. Ebenso können Patienten durch die Untersuchung genomischer Informationen wirksamere Therapien erhalten, die das Auftreten von Nebenwirkungen verringern. Vor diesem Hintergrund hat TECH einen Universitätsabschluss entwickelt, mit dem Ärzte in die Innovation auf diesem Gebiet eintauchen können, um ihre medizinische Praxis zu verbessern. Und das alles in einem bequemen, vollständig digitalen Format!





“

Dank dieses 100%igen Online-Programms werden Sie die wesentlichen Grundsätze des maschinellen Lernens und seine Anwendung bei der Analyse biomedizinischer Daten umfassend analysieren"

Während der therapeutischen Behandlungen müssen die Nutzer ständig von medizinischem Fachpersonal überwacht werden, um die Wirksamkeit der Behandlungen zu überprüfen. In diesem Sinne ist die künstliche Intelligenz nützlich, um Echtzeitdaten über den klinischen Zustand der Menschen zu sammeln. Darüber hinaus erkennen ihre Werkzeuge selbst kleinste Veränderungen des Gesundheitszustands und alarmieren bei Bedarf Spezialisten. Auf diese Weise können die Ärzte auf der Grundlage der Reaktionen des Einzelnen Anpassungen vornehmen und künftige lebensbedrohliche Probleme verhindern.

TECH ist sich der Bedeutung dieses Themas bewusst und führt einen privaten Masterstudiengang ein, der sich eingehend mit den spezifischen Anwendungen der künstlichen Intelligenz im Bereich der klinischen Forschung befasst. Der von Experten auf diesem Gebiet konzipierte Lehrplan befasst sich mit der Computersimulation in der Biomedizin und der fortgeschrittenen Analyse von klinischen Daten.

Dadurch erhalten die Experten fortgeschrittene Fähigkeiten, um maschinelles Lernen in komplexen biomedizinischen Situationen zu implementieren. Darüber hinaus wird der Lehrplan die ethischen und rechtlichen Erwägungen beim Einsatz von Künstlicher Intelligenz hervorheben, so dass die Studenten ihre Verfahren unter einer stark deontologischen Perspektive durchführen werden.

Die Methodik dieses Programms unterstreicht seinen innovativen Charakter. TECH bietet eine 100%ige Online-Lernumgebung, die an die Bedürfnisse von Berufstätigen angepasst ist, die in ihrer beruflichen Laufbahn vorankommen wollen. Daher können sie ihre Zeit- und Prüfungspläne individuell planen. Die Fortbildung basiert auf dem innovativen *Relearning*-System, das auf der Wiederholung der wichtigsten Konzepte basiert, um das Wissen zu festigen und das Lernen zu erleichtern. Auf diese Weise macht die Kombination aus Flexibilität und einem robusten pädagogischen Ansatz das Programm sehr zugänglich. Die Fachleute haben auch Zugang zu einer Bibliothek voller audiovisueller Ressourcen, darunter Infografiken und interaktive Zusammenfassungen. Darüber hinaus wird der Universitätsabschluss echte klinische Fälle beinhalten, die die Entwicklung des Programms so nah wie möglich an die Realität der medizinischen Versorgung heranführen.

Dieser **Privater Masterstudiengang in Künstliche Intelligenz in der Klinischen Forschung** 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



Die Fähigkeit der künstlichen Intelligenz, sowohl Daten aus verschiedenen Quellen zu integrieren als auch Ergebnisse vorherzusagen, wird dazu beitragen, Ihre medizinische Praxis präziser und personalisierter zu gestalten"



Damit Sie Ihre akademischen Ziele auf flexible Weise erreichen können, bietet TECH eine 100%ige Online-Lernmethodik, die auf freiem Zugang zu Inhalten und personalisiertem Unterricht basiert"

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.

Möchten Sie tiefer in die Implementierung von Big Data eintauchen? Beherrschen Sie dank dieses privaten Masterstudiengangs die effektivsten Techniken des maschinellen Lernens.

Die Fortbildung umfasst die Analyse ethischer, rechtlicher und regulatorischer Aspekte, die Übernahme von Verantwortung und das Bewusstsein für aktuelle Herausforderungen.



02 Ziele

Diese Fortbildung vermittelt den Studenten ein umfassendes Wissen über künstliche Intelligenz in der klinischen Forschung. So werden die Fachleute hochqualifiziert sein, um den aktuellen und zukünftigen Herausforderungen im medizinischen Bereich zu begegnen. Darüber hinaus lernen die Spezialisten ethische und innovative Aspekte kennen, die ihnen helfen werden, die Gesundheitsversorgung zu verändern. Sie werden auch fortgeschrittene Techniken zur Analyse medizinischer Daten, zur Entwicklung von Vorhersagemodellen für klinische Studien und zur Umsetzung kreativer Lösungen für die Personalisierung von Behandlungen erlernen. Die Experten werden klinische Komplexitäten durch datengesteuerte Ansätze effektiv angehen.



“

Sie werden sich mit den neuesten Technologien und den revolutionärsten Anwendungen der künstlichen Intelligenz in der klinischen Forschung befassen und dabei die besten Multimedia-Ressourcen nutzen"



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, Tools und Erfassungskanäle
- ♦ Untersuchen des *Datawarehouse*-Konzepts mit Schwerpunkt auf den Elementen des *Datawarehouse* und seinem Design
- ♦ Analysieren der rechtlichen Aspekte im Zusammenhang mit der Datenverwaltung, der Einhaltung von Datenschutz- und Sicherheitsvorschriften sowie von Best Practices

Modul 3. Daten in der künstlichen Intelligenz

- ♦ Beherrschen der Grundlagen der Datenwissenschaft, einschließlich der Werkzeuge, Typen und Quellen für die Informationsanalyse
- ♦ Erforschen des Prozesses der Umwandlung von Daten in Informationen mithilfe von *Data Mining* und Datenvisualisierungstechniken
- ♦ Studieren der Struktur und der Eigenschaften von *Datasets* und verstehen 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 Modellleistung bei bestimmten Aufgaben
- ♦ Erforschen und Anwenden von Techniken der *Data Augmentation* zur Anreicherung von Datensätzen und Verbesserung der Modellgeneralisierung
- ♦ Entwickeln praktischer Anwendungen mit *Transfer Learning* zur Lösung realer Probleme
- ♦ Verstehen und Anwenden von Regularisierungstechniken zur Verbesserung der Generalisierung und zur Vermeidung von Overfitting in tiefen neuronalen Netzen

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

- ♦ Beherrschen der Grundlagen von *TensorFlow* und seiner Integration mit NumPy für effiziente Datenverwaltung und Berechnungen
- ♦ Anpassen von Modellen und Trainingsalgorithmen mit den fortgeschrittenen Fähigkeiten von *TensorFlow*
- ♦ Erforschen der tfdata-API zur effektiven Verwaltung und Manipulation von Datensätzen
- ♦ Implementieren des Formats TFRecord, um große Datensätze in *TensorFlow* zu speichern und darauf zuzugreifen

- ♦ Verwenden von Keras-Vorverarbeitungsschichten zur Erleichterung der Konstruktion eigener Modelle
- ♦ Erforschen des *TensorFlow Datasets*-Projekts, um auf vordefinierte Datensätze zuzugreifen und die Entwicklungseffizienz zu verbessern
- ♦ Entwickeln einer *Deep Learning*-Anwendung mit *TensorFlow* unter Einbeziehung der im Modul erworbenen Kenntnisse
- ♦ Anwenden aller Konzepte, die bei der Erstellung und dem Training von benutzerdefinierten Modellen mit *TensorFlow* erlernt wurden, auf praktische Art und Weise in realen Situationen

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

- ♦ Verstehen der Architektur des visuellen Kortex und ihrer Bedeutung für *Deep Computer Vision*
- ♦ Erforschen und Anwenden von Faltungsschichten, um wichtige Merkmale aus Bildern zu extrahieren
- ♦ Implementieren von Clustering-Schichten und ihre Verwendung in *Deep Computer Vision*-Modellen mit Keras
- ♦ Analysieren verschiedener Architekturen von *Convolutional Neural Networks* (CNN) und deren Anwendbarkeit in verschiedenen Kontexten
- ♦ Entwickeln und Implementieren eines CNN ResNet unter Verwendung der Keras-Bibliothek, um die Effizienz und Leistung des Modells zu verbessern
- ♦ Verwenden von vorab trainierten Keras-Modellen, um das Transfer-Lernen für bestimmte Aufgaben zu nutzen
- ♦ Anwenden von Klassifizierungs- und Lokalisierungstechniken in *Deep Computer Vision*-Umgebungen
- ♦ Erforschen von Strategien zur Objekterkennung und -verfolgung mit *Convolutional Neural Networks*
- ♦ Implementieren von semantischen Segmentierungstechniken, um Objekte in Bildern im Detail zu verstehen und zu klassifizieren

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

- ♦ Entwickeln von Fähigkeiten zur Texterstellung mit rekurrenten neuronalen Netzen (RNN)
- ♦ Anwenden von RNNs bei der Meinungsklassifizierung zur Stimmungsanalyse in Texten
- ♦ Verstehen und Anwenden von Aufmerksamkeitsmechanismen in Modellen zur Verarbeitung natürlicher Sprache
- ♦ Analysieren und Verwenden von *Transformers*-Modellen in spezifischen NLP-Aufgaben
- ♦ Erkunden der Anwendung von *Transformers*-Modellen im Kontext von Bildverarbeitung und Computer Vision
- ♦ 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. KI-Methoden und -Tools für die klinische Forschung

- ♦ Erlangen eines umfassenden Überblicks darüber, wie KI die klinische Forschung verändert, von ihren historischen Grundlagen bis hin zu aktuellen Anwendungen
- ♦ Implementieren fortschrittlicher statistischer Methoden und Algorithmen in klinischen Studien, um die Datenanalyse zu optimieren
- ♦ Entwerfen von Experimenten mit innovativen Ansätzen und Durchführung einer umfassenden Analyse der Ergebnisse in der klinischen Forschung
- ♦ Anwenden der Verarbeitung natürlicher Sprache zur Verbesserung der wissenschaftlichen und klinischen Dokumentation im Forschungskontext
- ♦ Effektives Integrieren heterogener Daten unter Verwendung modernster Techniken zur Verbesserung der interdisziplinären klinischen Forschung

Modul 17. Biomedizinische Forschung mit KI

- ♦ Erwerben solider Kenntnisse über die Validierung von Modellen und Simulationen im biomedizinischen Bereich, um deren Genauigkeit und klinische Relevanz sicherzustellen
- ♦ Integrieren heterogener Daten mit fortschrittlichen Methoden, um die multidisziplinäre Analyse in der klinischen Forschung zu bereichern
- ♦ Entwickeln von *Deep-Learning*-Algorithmen zur Verbesserung der Interpretation und Analyse von biomedizinischen Daten in klinischen Studien
- ♦ Erforschen der Verwendung von synthetischen *Datasets* in klinischen Studien und Verstehen der praktischen Anwendungen von KI in der Gesundheitsforschung
- ♦ Verstehen der entscheidenden Rolle der Computersimulation bei der Arzneimittelforschung, der Analyse molekularer Wechselwirkungen und der Modellierung komplexer Krankheiten

Modul 18. Praktische Anwendung der KI in der klinischen Forschung

- ♦ Erwerben von Fachwissen in Schlüsselbereichen wie der Personalisierung von Therapien, Präzisionsmedizin, KI-gestützte Diagnostik, Management klinischer Studie und Entwicklung von Impfstoffen
- ♦ Integrieren von Robotik und Automatisierung in klinischen Labors, um Prozesse zu optimieren und die Qualität der Ergebnisse zu verbessern
- ♦ Erforschen der Auswirkungen von KI auf Mikrobiom, Mikrobiologie, *Wearables* und Fernüberwachung in klinischen Studien
- ♦ Bewältigen aktueller Herausforderungen im biomedizinischen Bereich, z. B. die effiziente Verwaltung klinischer Studien, die Entwicklung von KI-gestützten Behandlungen und die Anwendung von KI in der Immunologie und bei Studien zur Immunantwort
- ♦ Innovieren in der KI-gestützten Diagnostik zur Verbesserung der Früherkennung und der diagnostischen Genauigkeit in der klinischen und biomedizinischen Forschung



Modul 19. Big Data-Analyse und maschinelles Lernen in der klinischen Forschung

- ♦ Erwerben eines soliden Verständnisses der grundlegenden Konzepte von *Big Data* im klinischen Umfeld und Kennenlernen der wichtigsten Tools für die Datenanalyse
- ♦ Erkunden fortgeschrittener *Data-Mining*-Techniken, Algorithmen für maschinelles Lernen, prädiktive Analysen und KI-Anwendungen in der Epidemiologie und im öffentlichen Gesundheitswesen
- ♦ Analysieren von biologischen Netzwerken und Krankheitsmustern zur Ermittlung von Zusammenhängen und möglichen Behandlungen
- ♦ Auseinandersetzen mit der Datensicherheit und Bewältigung der Herausforderungen im Zusammenhang mit großen Datenmengen in der biomedizinischen Forschung
- ♦ Untersuchen von Fallstudien, die das Potenzial von *Big Data* in der biomedizinischen Forschung aufzeigen

Modul 20. Ethische, rechtliche und zukünftige Aspekte der KI in der klinischen Forschung

- ♦ Verstehen der ethischen Dilemmata, die sich bei der Anwendung von KI in der klinischen Forschung ergeben, und Überprüfen der relevanten rechtlichen und regulatorischen Überlegungen im biomedizinischen Bereich
- ♦ Auseinandersetzen mit den spezifischen Herausforderungen beim Umgang mit der informierten Zustimmung in Studien mit KI
- ♦ Untersuchen, wie KI die Gleichheit und den Zugang zur Gesundheitsversorgung beeinflussen kann
- ♦ Analysieren der Zukunftsperspektiven, wie KI die klinische Forschung prägen wird, Untersuchen ihrer Rolle für die Nachhaltigkeit der biomedizinischen Forschungspraxis und Identifizieren von Möglichkeiten für Innovation und Unternehmertum
- ♦ Umfassendes Eingehen auf die ethischen, rechtlichen und sozioökonomischen Aspekte der KI-gestützten klinischen Forschung

03

Kompetenzen

Dieser Universitätsabschluss vermittelt den Studenten ein umfassendes und aktuelles Wissen über die Anwendung von künstlicher Intelligenz im Bereich der klinischen Forschung. Dank dieses Programms werden die Studenten über fortgeschrittene und praktische Fähigkeiten verfügen, um biomedizinische Herausforderungen wie die Datenanalyse oder die Simulation biologischer Prozesse effektiv zu bewältigen. Ebenso werden die Fachleute Spitzentechnologien (einschließlich der genomischen Sequenzierung) in ihre üblichen Verfahren einbeziehen. Darüber hinaus wird ihre Praxis durch die Berücksichtigung ethischer, rechtlicher und regulatorischer Aspekte bei der Anwendung von Künstlicher Intelligenz im medizinischen Bereich gekennzeichnet sein.



“

*Sie werden klinische Fallstudien durchführen,
die Ihre Fähigkeiten im Bereich des maschinellen
Lernens und des Data Mining verbessern werden”*



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



Eine Fortbildung, die Sie in die Lage versetzt, die Diagnosegenauigkeit und die Entwicklung personalisierter Behandlungen zu verbessern. Sie werden die medizinische Versorgung durch Innovation revolutionieren"

04

Kursleitung

In ihrem Bestreben, ihren Studenten eine exzellente Fortbildung zu bieten, hat TECH das Lehrpersonal für dieses Programm sorgfältig ausgewählt. Diese Fachleute verfügen dank ihrer langjährigen Berufserfahrung in der Forschung über ein hohes Maß an Wissen über die auf die klinische Forschung angewandte künstliche Intelligenz. Diese Fachleute sind somit maßgebliche Stimmen auf diesem Gebiet und werden dafür verantwortlich sein, ihr Wissen an die Studenten weiterzugeben. Aus diesem Grund wird sich das Lehrmaterial durch seine Qualität auszeichnen und die neuesten Technologien in diesem sich schnell entwickelnden Bereich des Gesundheitswesens zusammenbringen.



“

Ein spezialisiertes Dozententeam wird sein umfangreiches Wissen auf dem Gebiet der künstlichen Intelligenz in der klinischen Forschung in diesen Universitätsabschluss einbringen"

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. 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
- ♦ Ernährungsberater-Diätassistent von der Europäischen Universität Miguel de Cervantes

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

05

Struktur und Inhalt

Dieser private Masterstudiengang wird die wissenschaftliche Präzision der klinischen Forschung mit den bahnbrechenden Innovationen der künstlichen Intelligenz verbinden. Der aus 20 Modulen bestehende Lehrplan befasst sich sowohl mit der Interpretation medizinischer Daten als auch mit der Entwicklung von Vorhersagealgorithmen. Der Lehrplan wird auch die Relevanz der Implementierung technologischer Lösungen im klinischen Kontext hervorheben. Mit einem theoretisch-praktischen Ansatz werden die Studenten die Grundlagen des maschinellen Lernens und seine richtige Anwendung im medizinischen Bereich beherrschen. Die Studenten werden in der Lage sein, Fortschritte bei der Individualisierung von Behandlungen und der Optimierung der Gesundheitsversorgung zu erzielen.



“

Erhalten Sie vom ersten Tag an Zugriff auf die multimediale Ressourcenbibliothek und den gesamten Lehrplan. Ohne feste Stundenpläne oder Präsenzunterricht!"

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. Darstellung von Wissen: 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. *Fine Tuning* der Hyperparameter von neuronalen Netzen
 - 8.10.1. Auswahl der Aktivierungsfunktion
 - 8.10.2. Einstellung der *Learning Rate*
 - 8.10.3. Einstellung der Gewichte

Modul 9. Training Tiefer Neuronaler Netze

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

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

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

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

- 10.7. Das *TFRecord*-Format
 - 10.7.1. Verwendung der *TFRecord*-API für die Datenserialisierung
 - 10.7.2. Laden von *TFRecord*-Dateien mit *TensorFlow*
 - 10.7.3. Verwendung von *TFRecord*-Dateien für das Modelltraining
- 10.8. Keras Vorverarbeitungsschichten
 - 10.8.1. Verwendung der Keras-API für die Vorverarbeitung
 - 10.8.2. Aufbau von Keras-Vorverarbeitungs-*Pipelines*
 - 10.8.3. Verwendung der Keras Vorverarbeitungs-API für das Modelltraining
- 10.9. Das *TensorFlow Datasets*-Projekt
 - 10.9.1. Verwendung von *TensorFlow Datasets* zum Laden von Daten
 - 10.9.2. Vorverarbeitung von Daten mit *TensorFlow Datasets*
 - 10.9.3. Verwendung von *TensorFlow Datasets* für das Modelltraining
- 10.10. Erstellen einer *Deep Learning*-Anwendung mit *TensorFlow*
 - 10.10.1. Praktische Anwendung
 - 10.10.2. Erstellen einer *Deep Learning*-Anwendung mit *TensorFlow*
 - 10.10.3. Trainieren eines Modells mit *TensorFlow*
 - 10.10.4. Verwendung der Anwendung für die Vorhersage von Ergebnissen

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

- 11.1. Die *Visual Cortex*-Architektur
 - 11.1.1. Funktionen des visuellen Kortex
 - 11.1.2. Theorien des rechnergestützten Sehens
 - 11.1.3. Modelle der Bildverarbeitung
- 11.2. Faltungsschichten
 - 11.2.1. Wiederverwendung von Gewichten bei der Faltung
 - 11.2.2. Faltung D
 - 11.2.3. Aktivierungsfunktionen
- 11.3. Gruppierungsschichten und Implementierung von Gruppierungsschichten mit Keras
 - 11.3.1. *Pooling* und *Striding*
 - 11.3.2. *Flattening*
 - 11.3.3. Arten des *Pooling*
- 11.4. CNN-Architektur
 - 11.4.1. VGG-Architektur
 - 11.4.2. *AlexNet*-Architektur
 - 11.4.3. *ResNet*-Architektur

- 11.5. Implementierung eines *ResNet* CNN mit Keras
 - 11.5.1. Initialisierung der Gewichte
 - 11.5.2. Definition der Eingabeschicht
 - 11.5.3. Definition der Ausgabe
 - 11.6. Verwendung von vortrainierten Keras-Modellen
 - 11.6.1. Merkmale der vortrainierten Modelle
 - 11.6.2. Verwendung von vortrainierten Modellen
 - 11.6.3. Vorteile von vortrainierten Modellen
 - 11.7. Vortrainierte Modelle für das Transferlernen
 - 11.7.1. Transferlernen
 - 11.7.2. Prozess des Transferlernens
 - 11.7.3. Vorteile des Transferlernens
 - 11.8. Klassifizierung und Lokalisierung in *Deep Computer Vision*
 - 11.8.1. Klassifizierung von Bildern
 - 11.8.2. Objekte in Bildern lokalisieren
 - 11.8.3. 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
 - 11.10.1. Kantenerkennung
 - 11.10.1. Regelbasierte Segmentierungsmethoden
- Modul 12. Natürliche Sprachverarbeitung (NLP) mit rekurrenten neuronalen Netzen (RNN) und Aufmerksamkeit**
- 12.1. Textgenerierung mit RNN
 - 12.1.1. Training eines RNN für die Texterzeugung
 - 12.1.2. Generierung natürlicher Sprache mit RNN
 - 12.1.3. Anwendungen zur Texterzeugung mit RNN
 - 12.2. Erstellung von Trainingsdatensätzen
 - 12.2.1. Vorbereitung der Daten für das RNN-Training
 - 12.2.2. Speicherung des Trainingsdatensatzes
 - 12.2.3. Bereinigung und Transformation der Daten
 - 12.2.4. Sentiment-Analyse
 - 12.3. Ranking von Meinungen mit RNN
 - 12.3.1. Erkennung von Themen in Kommentaren
 - 12.3.2. Stimmungsanalyse mit *Deep Learning*-Algorithmen
 - 12.4. Encoder-Decoder-Netz für neuronale maschinelle Übersetzung
 - 12.4.1. Training eines RNN für maschinelle Übersetzung
 - 12.4.2. Verwendung eines *Encoder-Decoder*-Netzwerks für die maschinelle Übersetzung
 - 12.4.3. Verbesserung der Genauigkeit der maschinellen Übersetzung mit RNNs
 - 12.5. Aufmerksamkeitsmechanismen
 - 12.5.1. Implementierung von Aufmerksamkeitsmechanismen in RNN
 - 12.5.2. Verwendung von Betreuungsmechanismen zur Verbesserung der Modellgenauigkeit
 - 12.5.3. Vorteile von Betreuungsmechanismen in neuronalen Netzen
 - 12.6. *Transformer*-Modelle
 - 12.6.1. Verwendung von *Transformer*-Modellen für die Verarbeitung natürlicher Sprache
 - 12.6.2. Anwendung von *Transformer*-Modellen für 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. KI-Methoden und -Tools für die klinische Forschung

- 16.1. KI-Technologien und -Tools in der klinischen Forschung
 - 16.1.1. Einsatz von maschinellem Lernen zur Identifizierung von Mustern in klinischen Daten
 - 16.1.2. Entwicklung von Vorhersagealgorithmen für klinische Studien
 - 16.1.3. Implementierung von KI-Systemen zur Verbesserung der Patientenrekrutierung
 - 16.1.4. KI-Tools für die Echtzeitanalyse von Forschungsdaten
- 16.2. Statistische Methoden und Algorithmen in klinischen Studien
 - 16.2.1. Anwendung fortgeschrittener statistischer Verfahren für die Analyse klinischer Daten
 - 16.2.2. Anwendung von Algorithmen für die Validierung und Verifizierung von Testergebnissen
 - 16.2.3. Anwendung von Regressions- und Klassifikationsmodellen in klinischen Studien
 - 16.2.4. Analyse großer Datensätze mit Hilfe statistischer Berechnungsmethoden
- 16.3. Planung von Experimenten und Analyse der Ergebnisse
 - 16.3.1. Strategien für die effiziente Planung klinischer Versuche unter Verwendung von KI
 - 16.3.2. KI-Techniken für die Analyse und Interpretation von Versuchsdaten
 - 16.3.3. Optimierung von Forschungsprotokollen mit Hilfe von KI-Simulationen
 - 16.3.4. Bewertung der Wirksamkeit und Sicherheit von Behandlungen mit Hilfe von KI-Modellen
- 16.4. Interpretation medizinischer Bilder mit Hilfe von KI in der Forschung
 - 16.4.1. Entwicklung von KI-Systemen zur automatischen Erkennung von Pathologien in der Bildgebung
 - 16.4.2. Einsatz von *Deep Learning* zur Klassifizierung und Segmentierung in medizinischen Bildern
 - 16.4.3. KI-Tools zur Verbesserung der Genauigkeit in der bildgebenden Diagnostik
 - 16.4.4. Analyse von radiologischen Bildern und Magnetresonanzbildern mit Hilfe von KI
- 16.5. Analyse von klinischen und biomedizinischen Daten
 - 16.5.1. KI in der Verarbeitung und Analyse genomischer und proteomischer Daten
 - 16.5.2. Werkzeuge für die integrierte Analyse von klinischen und biomedizinischen Daten
 - 16.5.3. Einsatz von KI zur Identifizierung von Biomarkern in der klinischen Forschung
 - 16.5.4. Prädiktive Analyse klinischer Ergebnisse auf der Grundlage biomedizinischer Daten
- 16.6. Fortgeschrittene Datenvisualisierung in der klinischen Forschung
 - 16.6.1. Entwicklung von interaktiven Visualisierungstools für klinische Daten
 - 16.6.2. Einsatz von KI bei der Erstellung von grafischen Darstellungen komplexer Daten
 - 16.6.3. Visualisierungstechniken zur einfachen Interpretation von Forschungsergebnissen
 - 16.6.4. Werkzeuge der erweiterten und virtuellen Realität für die Visualisierung biomedizinischer Daten
- 16.7. Natürliche Sprachverarbeitung in der wissenschaftlichen und klinischen Dokumentation
 - 16.7.1. Anwendung von NLP für die Analyse von wissenschaftlicher Literatur und klinischen Aufzeichnungen
 - 16.7.2. KI-Tools für die Extraktion von relevanten Informationen aus medizinischen Texten
 - 16.7.3. KI-Systeme für die Zusammenfassung und Kategorisierung von wissenschaftlicher Literatur
 - 16.7.4. Einsatz von NLP zur Erkennung von Trends und Mustern in der klinischen Dokumentation
- 16.8. Verarbeitung heterogener Daten in der klinischen Forschung
 - 16.8.1. KI-Techniken zur Integration und Analyse von Daten aus verschiedenen klinischen Quellen
 - 16.8.2. Werkzeuge für die Verarbeitung unstrukturierter klinischer Daten
 - 16.8.3. KI-Systeme für die Korrelation klinischer und demografischer Daten
 - 16.8.4. Analyse multidimensionaler Daten für klinische *Insights*
- 16.9. Anwendungen von neuronalen Netzen in der biomedizinischen Forschung
 - 16.9.1. Verwendung neuronaler Netze zur Krankheitsmodellierung und Behandlungsvorhersage
 - 16.9.2. Einsatz neuronaler Netze bei der Klassifizierung genetischer Krankheiten
 - 16.9.3. Entwicklung von Diagnosesystemen auf der Grundlage neuronaler Netze
 - 16.9.4. Anwendung neuronaler Netze bei der Personalisierung der medizinischen Behandlung
- 16.10. Prädiktive Modellierung und ihre Auswirkungen auf die klinische Forschung
 - 16.10.1. Entwicklung von Vorhersagemodellen für die Vorhersage klinischer Ergebnisse
 - 16.10.2. Einsatz von KI bei der Vorhersage von Nebenwirkungen und unerwünschten Wirkungen
 - 16.10.3. Einsatz von Vorhersagemodellen bei der Optimierung klinischer Studien
 - 16.10.4. Risikoanalyse bei medizinischen Behandlungen mittels prädiktiver Modellierung

Modul 17. Biomedizinische Forschung mit KI

- 17.1. Design und Durchführung von Beobachtungsstudien mit KI
 - 17.1.1. Implementierung von KI für die Auswahl und Segmentierung von Studienpopulationen
 - 17.1.2. Einsatz von Algorithmen für das Echtzeit-Monitoring von Daten aus Beobachtungsstudien
 - 17.1.3. KI-Tools für die Identifizierung von Mustern und Korrelationen in Beobachtungsstudien
 - 17.1.4. Automatisierung des Prozesses der Datenerfassung und -analyse in Beobachtungsstudien
- 17.2. Validierung und Kalibrierung von Modellen in der klinischen Forschung
 - 17.2.1. KI-Techniken zur Gewährleistung der Genauigkeit und Zuverlässigkeit klinischer Modelle
 - 17.2.2. Einsatz von KI bei der Kalibrierung von Vorhersagemodellen in der klinischen Forschung
 - 17.2.3. Kreuzvalidierungsmethoden für klinische Modelle, die KI verwenden
 - 17.2.4. KI-Tools für die Bewertung der Verallgemeinerbarkeit von klinischen Modellen
- 17.3. Methoden zur Integration heterogener Daten in der klinischen Forschung
 - 17.3.1. KI-Techniken zur Kombination von klinischen, genomischen und umweltbezogenen Daten
 - 17.3.2. Einsatz von Algorithmen zur Verarbeitung und Analyse unstrukturierter klinischer Daten
 - 17.3.3. KI-Tools für die Normalisierung und Standardisierung klinischer Daten
 - 17.3.4. KI-Systeme für die Korrelation verschiedener Datentypen in der Forschung
- 17.4. Multidisziplinäre biomedizinische Datenintegration
 - 17.4.1. KI-Systeme für die Kombination von Daten aus verschiedenen biomedizinischen Disziplinen
 - 17.4.2. Algorithmen für die integrierte Analyse von klinischen und Labordaten
 - 17.4.3. KI-Tools für die Visualisierung komplexer biomedizinischer Daten
 - 17.4.4. Einsatz von KI bei der Erstellung von ganzheitlichen Gesundheitsmodellen aus multidisziplinären Daten
- 17.5. *Deep-Learning*-Algorithmen in der biomedizinischen Datenanalyse
 - 17.5.1. Implementierung neuronaler Netze in der Analyse genetischer und proteomischer Daten
 - 17.5.2. Verwendung von *Deep Learning* zur Mustererkennung in biomedizinischen Daten
 - 17.5.3. Entwicklung von Vorhersagemodellen in der Präzisionsmedizin durch *Deep Learning*
 - 17.5.4. Anwendung von KI in der fortgeschrittenen biomedizinischen Bildanalyse
- 17.6. Optimierung von Forschungsprozessen durch Automatisierung
 - 17.6.1. Automatisierung von Laborroutinen durch KI-Systeme
 - 17.6.2. Einsatz von KI zur effizienten Verwaltung von Forschungsressourcen und Zeit
 - 17.6.3. KI-Tools zur Optimierung von Arbeitsabläufen in der klinischen Forschung
 - 17.6.4. Automatisierte Systeme für die Verfolgung und Meldung von Forschungsfortschritten
- 17.7. Simulation und computergestützte Modellierung in der Medizin mit KI
 - 17.7.1. Entwicklung von Computermodellen zur Simulation von klinischen Szenarien
 - 17.7.2. Einsatz von KI zur Simulation von molekularen und zellulären Interaktionen
 - 17.7.3. KI-Tools für die Erstellung von prädiktiven Krankheitsmodellen
 - 17.7.4. Anwendung von KI bei der Simulation von Arzneimittel- und Behandlungseffekten
- 17.8. Einsatz von virtueller und erweiterter Realität in klinischen Studien
 - 17.8.1. Einsatz von virtueller Realität für Fortbildung und Simulation in der Medizin
 - 17.8.2. Einsatz von erweiterter Realität bei chirurgischen Eingriffen und in der Diagnostik
 - 17.8.3. Werkzeuge der virtuellen Realität für Verhaltens- und psychologische Studien
 - 17.8.4. Anwendung von immersiven Technologien in der Rehabilitation und Therapie
- 17.9. *Data-Mining*-Tools für die biomedizinische Forschung
 - 17.9.1. Einsatz von *Data-Mining*-Techniken zur Extraktion von Wissen aus biomedizinischen Datenbanken
 - 17.9.2. Implementierung von KI-Algorithmen zur Entdeckung von Mustern in klinischen Daten
 - 17.9.3. KI-Tools zur Erkennung von Trends in großen Datensätzen
 - 17.9.4. Anwendung von *Data Mining* bei der Erstellung von Forschungshypothesen
- 17.10. Entwicklung und Validierung von Biomarkern mit künstlicher Intelligenz
 - 17.10.1. Einsatz von KI für die Identifizierung und Charakterisierung neuer Biomarker
 - 17.10.2. Implementierung von KI-Modellen zur Validierung von Biomarkern in klinischen Studien
 - 17.10.3. KI-Tools für die Korrelation von Biomarkern mit klinischen Resultaten
 - 17.10.4. Anwendung von KI bei der Analyse von Biomarkern für die personalisierte Medizin

Modul 18. Praktische Anwendung der KI in der klinischen Forschung

- 18.1. Genomische Sequenzierungstechnologien und Datenanalyse mit KI
 - 18.1.1. Einsatz von KI für die schnelle und genaue Analyse von Gensequenzen
 - 18.1.2. Einsatz von Algorithmen des maschinellen Lernens bei der Interpretation genomischer Daten
 - 18.1.3. KI-Tools zur Identifizierung genetischer Varianten und Mutationen
 - 18.1.4. Anwendung von KI bei der Korrelation von Genomdaten mit Krankheiten und Merkmalen
- 18.2. KI in der biomedizinischen Bildanalyse
 - 18.2.1. Entwicklung von KI-Systemen für die Erkennung von Anomalien in medizinischen Bildern
 - 18.2.2. Einsatz von *Deep Learning* bei der Interpretation von Röntgen-, MRT- und CT-Scans
 - 18.2.3. KI-Tools zur Verbesserung der Genauigkeit bei der bildgebenden Diagnose
 - 18.2.4. Implementierung von KI bei der Klassifizierung und Segmentierung biomedizinischer Bilder
- 18.3. Robotik und Automatisierung in klinischen Labors
 - 18.3.1. Einsatz von Robotern zur Automatisierung von Labortests und -prozessen
 - 18.3.2. Einführung von automatisierten Systemen für die Verwaltung biologischer Proben
 - 18.3.3. Entwicklung von Robotertechnologien zur Verbesserung der Effizienz und Genauigkeit in der klinischen Analyse
 - 18.3.4. Anwendung von KI bei der Optimierung von Laborarbeitsabläufen
- 18.4. KI in der Personalisierung von Therapien und Präzisionsmedizin
 - 18.4.1. Entwicklung von KI-Modellen für die Personalisierung von medizinischen Behandlungen
 - 18.4.2. Einsatz von prädiktiven Algorithmen bei der Auswahl von Therapien auf der Grundlage genetischer Profile
 - 18.4.3. KI-Tools für die Anpassung von Medikamentendosen und -kombinationen
 - 18.4.4. Anwendung von KI bei der Ermittlung wirksamer Behandlungen für bestimmte Zielgruppen
- 18.5. Innovationen in der KI-gestützten Diagnose
 - 18.5.1. Implementierung von KI-Systemen für eine schnelle und genaue Diagnose
 - 18.5.2. Einsatz von KI zur Früherkennung von Krankheiten durch Datenanalyse
 - 18.5.3. Entwicklung von KI-Tools für die Interpretation klinischer Tests
 - 18.5.4. Anwendung von KI bei der Kombination von klinischen und biomedizinischen Daten für umfassende Diagnosen
- 18.6. KI-Anwendungen in der Mikrobiom- und Mikrobiologieforschung
 - 18.6.1. Einsatz von KI bei der Analyse und Kartierung des menschlichen Mikrobioms
 - 18.6.2. Implementierung von Algorithmen zur Untersuchung der Beziehung zwischen dem Mikrobiom und Krankheiten
 - 18.6.3. KI-Tools für die Identifizierung von Mustern in Mikrobiomstudien
 - 18.6.4. Anwendung von KI bei der Untersuchung von mikrobiombasierten Therapeutika
- 18.7. Wearables und Fernüberwachung in klinischen Studien
 - 18.7.1. Entwicklung von tragbaren Geräten mit KI zur kontinuierlichen Gesundheitsüberwachung
 - 18.7.2. Einsatz von KI bei der Interpretation der von Wearables gesammelten Daten
 - 18.7.3. Einsatz von Fernüberwachungssystemen in klinischen Studien
 - 18.7.4. Anwendung von KI bei der Vorhersage von klinischen Ereignissen anhand der Daten von Wearables
- 18.8. KI in der Verwaltung klinischer Studien
 - 18.8.1. Einsatz von KI-Systemen zur Optimierung des Managements klinischer Studien
 - 18.8.2. Einsatz von KI bei der Teilnehmerauswahl und Nachverfolgung
 - 18.8.3. KI-Tools für die Analyse von Daten und Ergebnissen klinischer Prüfungen
 - 18.8.4. Anwendung von KI zur Verbesserung der Studieneffizienz und zur Senkung der Studienkosten
- 18.9. KI-unterstützte Impfstoff- und Behandlungsentwicklung
 - 18.9.1. Einsatz von KI zur Beschleunigung der Impfstoffentwicklung
 - 18.9.2. Anwendung prädiktiver Modellierung bei der Identifizierung potenzieller Behandlungen
 - 18.9.3. KI-Tools für die Simulation von Impfstoff- und Arzneimittelreaktionen
 - 18.9.4. Anwendung von KI bei der Personalisierung von Impfstoffen und Therapien
- 18.10. KI-Anwendungen in der Immunologie und bei Studien zur Immunantwort
 - 18.10.1. Entwicklung von KI-Modellen zum Verständnis von Immunmechanismen
 - 18.10.2. Einsatz von KI bei der Identifizierung von Mustern in Immunreaktionen
 - 18.10.3. Einsatz von KI bei der Untersuchung von Autoimmunerkrankungen
 - 18.10.4. Anwendung der KI bei der Entwicklung von personalisierten Immuntherapien

Modul 19. *Big Data*-Analyse und maschinelles Lernen in der klinischen Forschung

- 19.1. *Big Data* in der klinischen Forschung: Konzepte und Werkzeuge
 - 19.1.1. Die Datenexplosion im Bereich der klinischen Forschung
 - 19.1.2. Das Konzept von *Big Data* und die wichtigsten Tools
 - 19.1.3. Anwendungen von *Big Data* in der klinischen Forschung
- 19.2. *Data Mining* in klinischen und biomedizinischen Registern
 - 19.2.1. Die wichtigsten Methoden für *Data Mining*
 - 19.2.2. Integration von Daten aus klinischen und biomedizinischen Registern
 - 19.2.3. Erkennung von Mustern und Anomalien in klinischen und biomedizinischen Aufzeichnungen
- 19.3. Algorithmen des maschinellen Lernens in der biomedizinischen Forschung
 - 19.3.1. Klassifizierungstechniken in der biomedizinischen Forschung
 - 19.3.2. Regressionstechniken in der biomedizinischen Forschung
 - 19.3.4. Unüberwachte Techniken in der biomedizinischen Forschung
- 19.4. Prädiktive Analysetechniken in der klinischen Forschung
 - 19.4.1. Klassifizierungstechniken in der klinischen Forschung
 - 19.4.2. Regressionstechniken in der klinischen Forschung
 - 19.4.3. *Deep Learning* in der klinischen Forschung
- 19.5. KI-Modelle in der Epidemiologie und im öffentlichen Gesundheitswesen
 - 19.5.1. Klassifizierungstechniken für Epidemiologie und öffentliche Gesundheit
 - 19.5.2. Regressionstechniken für die Epidemiologie und die öffentliche Gesundheit
 - 19.5.3. Unüberwachte Techniken für die Epidemiologie und die öffentliche Gesundheit
- 19.6. Analyse von biologischen Netzwerken und Krankheitsmustern
 - 19.6.1. Erforschung von Interaktionen in biologischen Netzen zur Identifizierung von Krankheitsmustern
 - 19.6.2. Integration von Omics-Daten in die Netzwerkanalyse zur Charakterisierung biologischer Komplexitäten
 - 19.6.3. Anwendung von Algorithmen des *Machine Learning* zur Entdeckung von Krankheitsmustern
- 19.7. Entwicklung von Instrumenten für die klinische Prognose
 - 19.7.1. Entwicklung innovativer Werkzeuge für die klinische Prognose auf der Grundlage multidimensionaler Daten
 - 19.7.2. Integration von klinischen und molekularen Variablen bei der Entwicklung von Prognoseinstrumenten
 - 19.7.3. Evaluierung der Wirksamkeit von Prognoseinstrumenten in verschiedenen klinischen Kontexten
- 19.8. Fortgeschrittene Visualisierung und Kommunikation von komplexen Daten
 - 19.8.1. Einsatz fortgeschrittener Visualisierungstechniken zur Darstellung komplexer biomedizinischer Daten
 - 19.8.2. Entwicklung effektiver Kommunikationsstrategien für die Präsentation komplexer Analyseergebnisse
 - 19.8.3. Implementierung von Interaktivitätswerkzeugen in Visualisierungen zur Verbesserung des Verständnisses
- 19.9. Datensicherheit und Herausforderungen bei der Verwaltung von *Big Data*
 - 19.9.1. Bewältigung von Datensicherheitsherausforderungen im biomedizinischen *Big-Data*-Kontext
 - 19.9.1. Strategien zum Schutz der Privatsphäre bei der Verwaltung großer biomedizinischer Datensätze
 - 19.9.3. Umsetzung von Sicherheitsmaßnahmen zur Risikominderung beim Umgang mit sensiblen Daten
- 19.10. Praktische Anwendungen und Fallstudien im Bereich biomedizinischer *Big Data*
 - 19.10.1. Untersuchung erfolgreicher Fälle bei der Implementierung von biomedizinischen *Big Data* in der klinischen Forschung
 - 19.10.2. Entwicklung von praktischen Strategien für die Anwendung von *Big Data* in der klinischen Entscheidungsfindung
 - 19.10.3. Bewertung der Auswirkungen und der gewonnenen Erkenntnisse durch Fallstudien in der biomedizinischen Forschung

Modul 20. Ethische, rechtliche und zukünftige Aspekte der KI in der klinischen Forschung


- 20.1. Ethische Aspekte der Anwendung von KI in der klinischen Forschung
 - 20.1.1. Ethische Analyse der KI-gestützten Entscheidungsfindung in der klinischen Forschung
 - 20.1.2. Ethik bei der Verwendung von KI-Algorithmen für die Teilnehmerauswahl in klinischen Studien
 - 20.1.3. Ethische Überlegungen bei der Interpretation von Ergebnissen, die von KI-Systemen in der klinischen Forschung generiert werden
- 20.2. Rechtliche und regulatorische Überlegungen zur biomedizinischen KI
 - 20.2.1. Analyse der rechtlichen Rahmenbedingungen für die Entwicklung und Anwendung von KI-Technologien im biomedizinischen Bereich
 - 20.2.2. Bewertung der Einhaltung spezifischer Vorschriften zur Gewährleistung der Sicherheit und Wirksamkeit von KI-basierten Lösungen
 - 20.2.3. Bewältigung neuer regulatorischer Herausforderungen im Zusammenhang mit dem Einsatz von KI in der biomedizinischen Forschung
- 20.3. Informierte Zustimmung und ethische Fragen bei der Nutzung klinischer Daten
 - 20.3.1. Entwicklung von Strategien zur Sicherstellung einer wirksamen informierten Zustimmung bei Projekten mit KI
 - 20.3.2. Ethische Fragen bei der Erhebung und Nutzung sensibler klinischer Daten im Rahmen der KI-gestützten Forschung
 - 20.3.3. Behandlung ethischer Fragen im Zusammenhang mit dem Eigentum an und dem Zugang zu klinischen Daten in Forschungsprojekten
- 20.4. KI und Haftung in der klinischen Forschung
 - 20.4.1. Bewertung der ethischen und rechtlichen Haftung bei der Implementierung von KI-Systemen in klinischen Forschungsprotokollen
 - 20.4.2. Entwicklung von Strategien zur Bewältigung potenzieller negativer Folgen des Einsatzes von KI in der biomedizinischen Forschung
 - 20.4.3. Ethische Überlegungen bei der aktiven Einbeziehung von KI in die Entscheidungsfindung in der klinischen Forschung
- 20.5. Auswirkungen der KI auf die Gleichheit und den Zugang zur Gesundheitsversorgung
 - 20.5.1. Bewertung der Auswirkungen von KI-Lösungen auf die Chancengleichheit bei der Teilnahme an klinischen Studien
 - 20.5.2. Entwicklung von Strategien zur Verbesserung des Zugangs zu KI-Technologien in verschiedenen klinischen Umfeldern
 - 20.5.3. Ethische Aspekte der Verteilung von Nutzen und Risiken im Zusammenhang mit der Anwendung von KI im Gesundheitswesen
- 20.6. Privatsphäre und Datenschutz in Forschungsprojekten
 - 20.6.1. Gewährleistung des Schutzes der Privatsphäre der Teilnehmer an Forschungsprojekten, die den Einsatz von KI beinhalten
 - 20.6.2. Entwicklung von Strategien und Praktiken für den Datenschutz in der biomedizinischen Forschung
 - 20.6.3. Bewältigung spezifischer Datenschutz- und Sicherheits Herausforderungen beim Umgang mit sensiblen Daten im klinischen Umfeld
- 20.7. KI und Nachhaltigkeit in der biomedizinischen Forschung
 - 20.7.1. Bewertung der Umweltauswirkungen und Ressourcen im Zusammenhang mit der Implementierung von KI in der biomedizinischen Forschung
 - 20.7.2. Entwicklung nachhaltiger Praktiken bei der Integration von KI-Technologien in klinische Forschungsprojekte
 - 20.7.3. Ethische Aspekte des Ressourcenmanagements und der Nachhaltigkeit bei der Einführung von KI in der biomedizinischen Forschung
- 20.8. Auditierung und Erklärbarkeit von KI-Modellen im klinischen Umfeld
 - 20.8.1. Entwicklung von Audit-Protokollen zur Bewertung der Zuverlässigkeit und Genauigkeit von KI-Modellen in der klinischen Forschung
 - 20.8.2. Ethik in der Erklärbarkeit von Algorithmen, um das Verständnis der von KI-Systemen im klinischen Kontext getroffenen Entscheidungen zu gewährleisten
 - 20.8.3. Bewältigung ethischer Herausforderungen bei der Interpretation von Ergebnissen von KI-Modellen in der biomedizinischen Forschung
- 20.9. Innovation und Unternehmertum in der klinischen KI
 - 20.9.1. Ethik in der verantwortungsvollen Innovation bei der Entwicklung von KI-Lösungen für klinische Anwendungen
 - 20.9.2. Entwicklung von ethischen Geschäftsstrategien im Bereich der klinischen KI
 - 20.9.3. Ethische Erwägungen bei der Vermarktung und Einführung von KI-Lösungen im klinischen Bereich
- 20.10. Ethische Überlegungen bei der internationalen Zusammenarbeit in der klinischen Forschung
 - 20.10.1. Entwicklung ethischer und rechtlicher Vereinbarungen für die internationale Zusammenarbeit bei KI-gestützten Forschungsprojekten
 - 20.10.2. Ethische Aspekte der Beteiligung mehrerer Institutionen und Länder an klinischer Forschung mit KI-Technologien
 - 20.10.3. Bewältigung neuer ethischer Herausforderungen im Zusammenhang mit der globalen Zusammenarbeit in der biomedizinischen Forschung

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 Forschung 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 Forschung** 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 Forschung**

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 Forschung

- » 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 Forschung