

Privater Masterstudiengang Künstliche Intelligenz in der Diagnostischen Bildgebung



Privater Masterstudiengang Künstliche Intelligenz in der Diagnostischen Bildgebung

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

Internetzugang: www.techtitude.com/de/kunstliche-intelligenz/masterstudiengang/masterstudiengang-kunstliche-intelligenz-diagnostischen-bildgebung

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 48

07

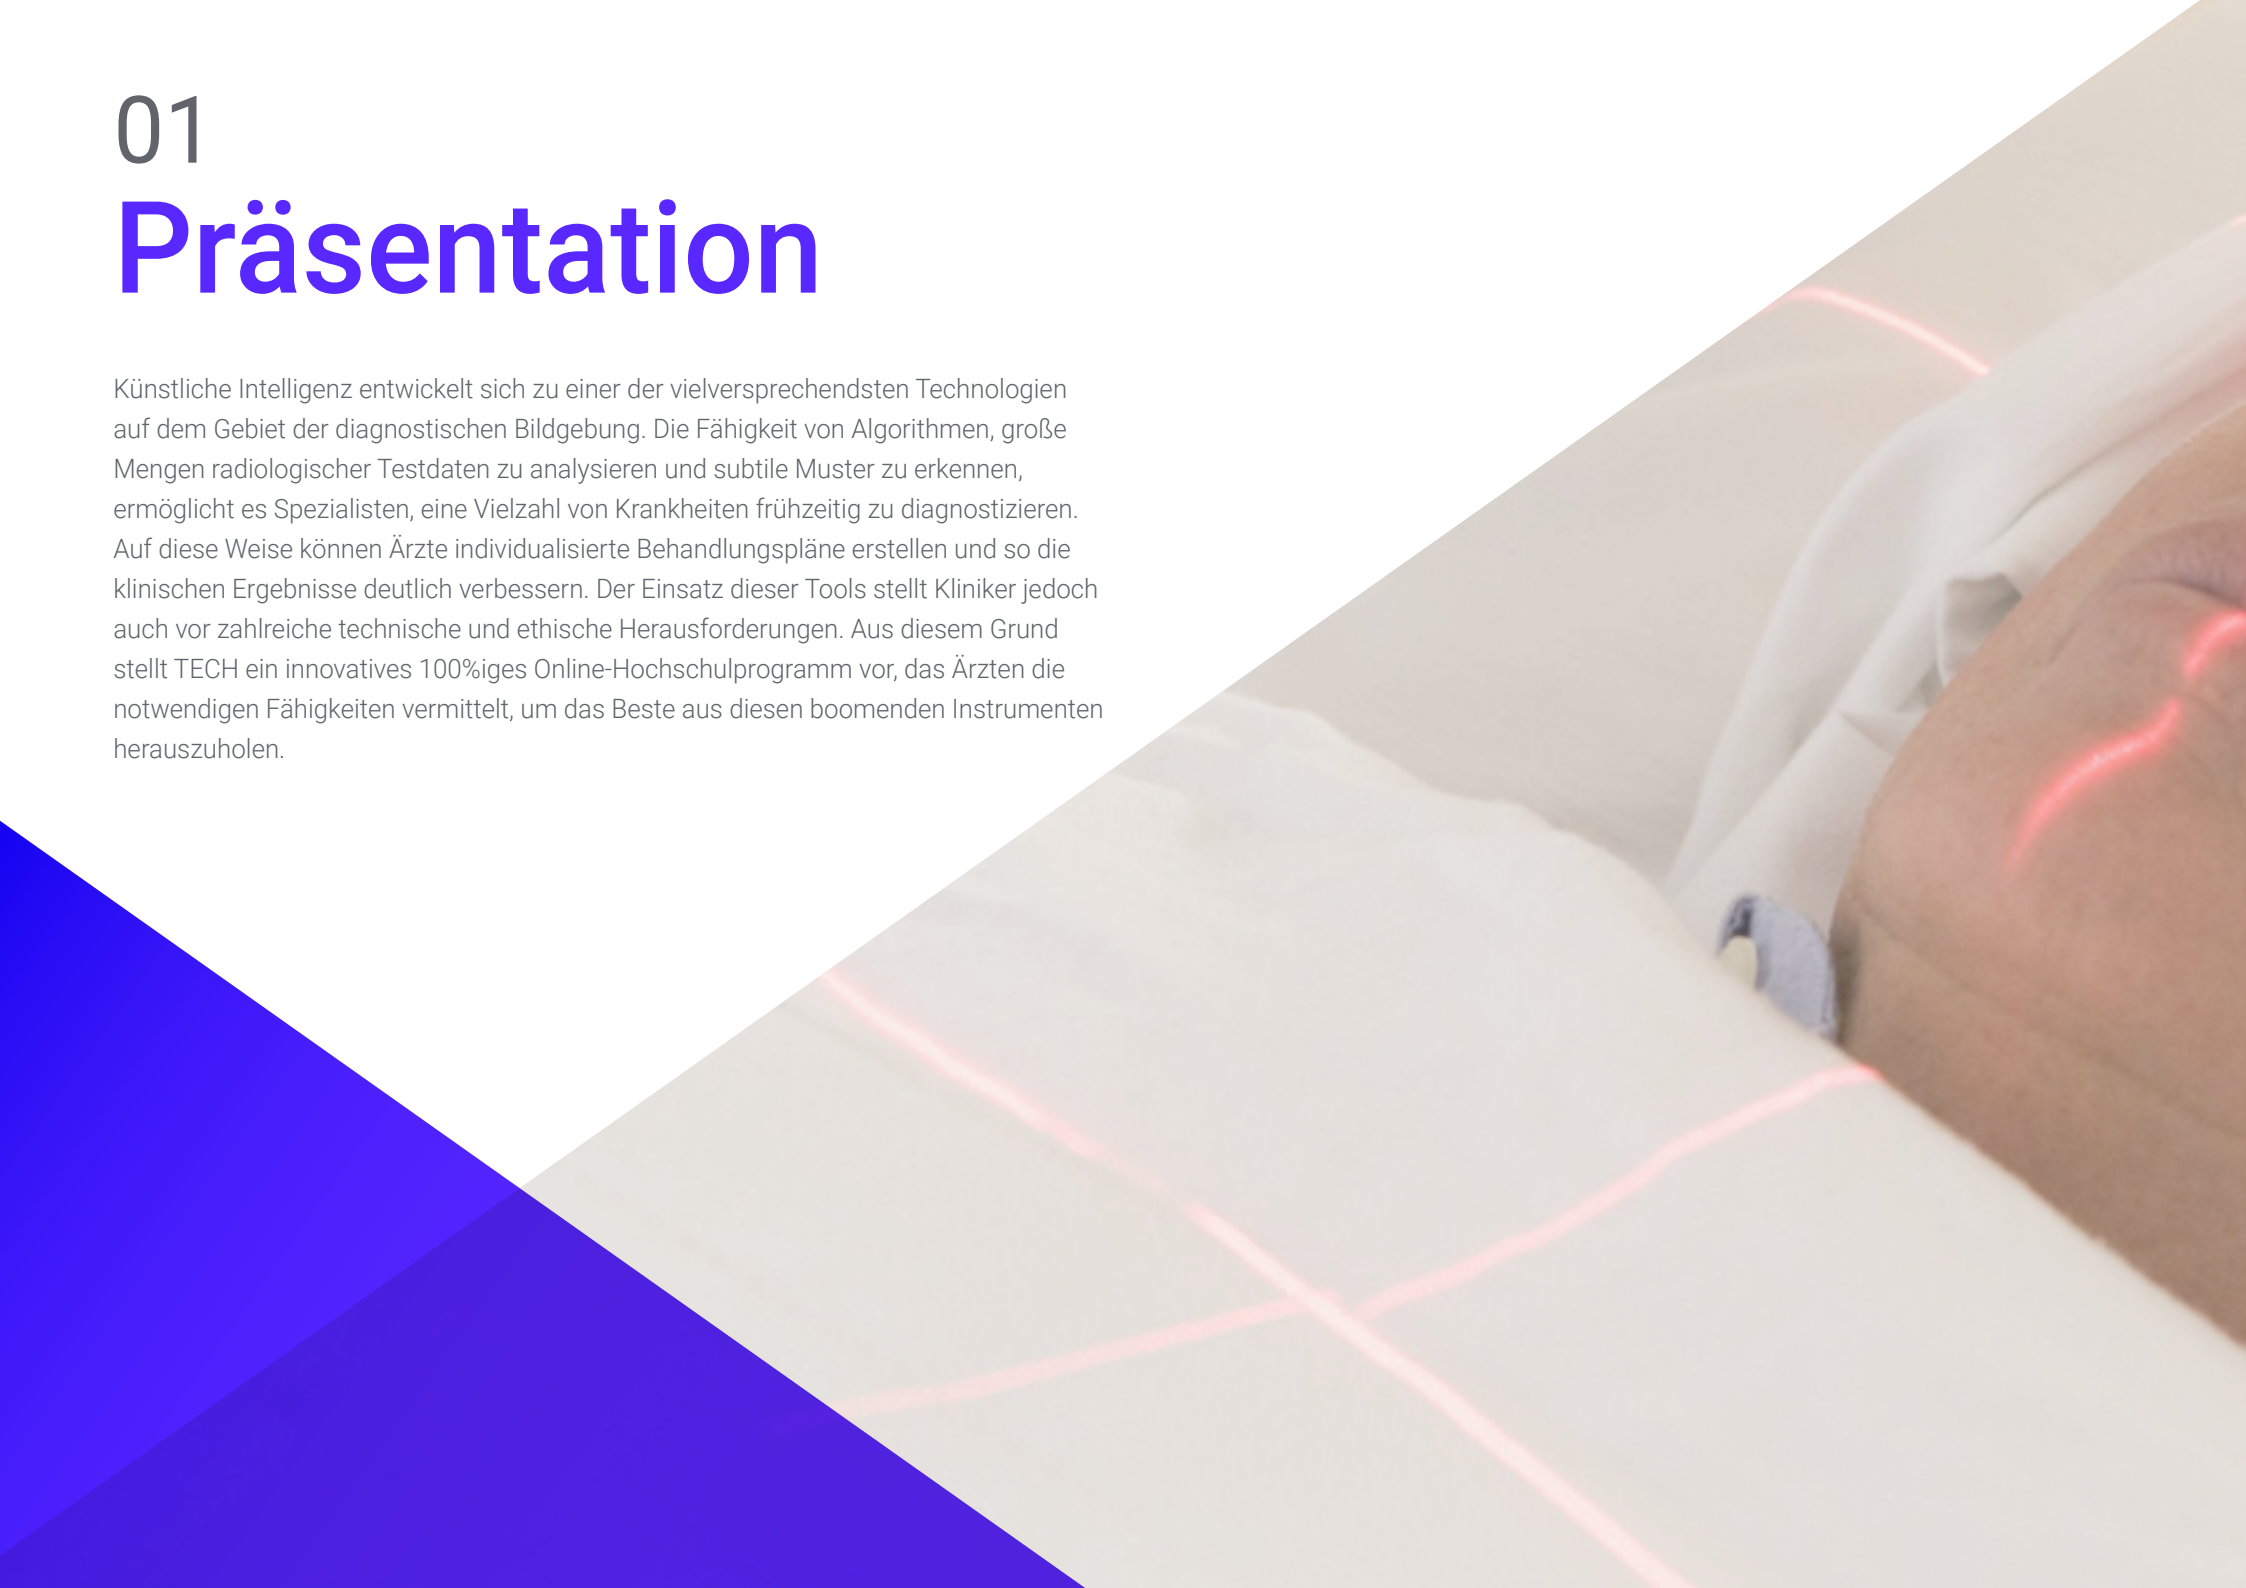
Qualifizierung

Seite 56

01

Präsentation

Künstliche Intelligenz entwickelt sich zu einer der vielversprechendsten Technologien auf dem Gebiet der diagnostischen Bildgebung. Die Fähigkeit von Algorithmen, große Mengen radiologischer Testdaten zu analysieren und subtile Muster zu erkennen, ermöglicht es Spezialisten, eine Vielzahl von Krankheiten frühzeitig zu diagnostizieren. Auf diese Weise können Ärzte individualisierte Behandlungspläne erstellen und so die klinischen Ergebnisse deutlich verbessern. Der Einsatz dieser Tools stellt Kliniker jedoch auch vor zahlreiche technische und ethische Herausforderungen. Aus diesem Grund stellt TECH ein innovatives 100%iges Online-Hochschulprogramm vor, das Ärzten die notwendigen Fähigkeiten vermittelt, um das Beste aus diesen boomenden Instrumenten herauszuholen.





“

Im Rahmen dieses 100%igen Online-Programms werden Sie die wichtigsten Werkzeuge der künstlichen Intelligenz beherrschen und sie nutzen, um die Qualität Ihrer klinischen Analysen zu optimieren“

Ein aktueller Bericht der Weltgesundheitsorganisation sagt voraus, dass die weltweite Belastung durch chronische Krankheiten in den kommenden Jahren zunehmen wird. Angesichts dieser Situation fordert die Organisation die Ärzte auf, die genauesten und effizientesten Instrumente zur Frühdiagnose einzusetzen. In diesem Zusammenhang ist die künstliche Intelligenz ein nützliches Instrument zur Früherkennung von Krankheiten wie Lungenkrebs, Herzversagen und sogar Alzheimer. Daher ist es wichtig, dass Fachleute fortschrittliche Techniken wie *Deep Learning* oder bioinspiriertes Computing in ihre tägliche klinische Praxis einbeziehen, um Diagnosefehler zu reduzieren und die Behandlung der Nutzer zu personalisieren.

In diesem Zusammenhang hat TECH ein innovatives Programm in Künstliche Intelligenz in der Diagnostischen Bildung entwickelt. Der Lehrplan, der von Experten auf diesem Gebiet entwickelt wurde, befasst sich mit den Grundlagen von neuronalen Netzen und genetischen Algorithmen. Im Einklang damit werden die didaktischen Materialien die Grundlagen für die Anwendung der anspruchsvollsten Techniken des *Data Mining* vermitteln. Auf diese Weise erwerben die Spezialisten fortgeschrittene Fähigkeiten, um die Genauigkeit bei der Erkennung von Krankheiten und medizinischen Zuständen zu verbessern und genauere Diagnosen zu stellen. Ebenso wird sich der Lehrplan mit der Verwaltung von bioinspirierten Computermodellen befassen, damit Ärzte diese zur Lösung komplexer klinischer Probleme und zur Optimierung klinischer Behandlungen einsetzen können.

TECH bietet eine 100%ige akademische Online-Umgebung, die auf die Bedürfnisse von Ärzten zugeschnitten ist, die ihre Karriere voranbringen wollen. Außerdem nutzt sie ihre revolutionäre *Relearning*-Methode, die auf der Wiederholung der wichtigsten Konzepte basiert, um das Wissen effizient und unmittelbar zu verinnerlichen. Darüber hinaus benötigen Experten nur ein Gerät mit Internetzugang (z. B. ein Mobiltelefon, einen Computer oder ein *Tablet*), um auf den virtuellen Campus zuzugreifen und eine Erfahrung zu machen, die ihren beruflichen Horizont erheblich erweitert.

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

- Die Entwicklung von Fallstudien, die von Experten in künstlicher Intelligenz präsentiert 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 durchgeführt werden kann
- Sein besonderer Schwerpunkt liegt auf innovativen Methoden
- Theoretische Lektionen, Fragen an den Experten, Diskussionsforen zu kontroversen Themen und individuelle Reflexionsarbeit
- Die Verfügbarkeit des Zugriffs auf die Inhalte von jedem festen oder tragbaren Gerät mit Internetanschluss



Ein intensiver Lehrplan, der Ihnen die Möglichkeit gibt, Ihr Wissen in einem realen Szenario zu aktualisieren, mit der maximalen wissenschaftlichen Genauigkeit einer Institution, die an der Spitze der Technologie steht“

“

Sie werden Convolutional Neural Networks verwenden, um Behandlungen an die spezifischen Bedürfnisse von Patienten anzupassen und deren Prognose deutlich zu verbessern“

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

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

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

Sie werden fortgeschrittene Fähigkeiten erwerben, um die Genauigkeit, Validität und klinische Anwendbarkeit von Modellen der künstlichen Intelligenz im medizinischen Bereich zu beurteilen.

Die interaktiven Zusammenfassungen der einzelnen Module ermöglichen es Ihnen, die Konzepte der natürlichen Sprachverarbeitung auf eine dynamischere Weise zu festigen.



02 Ziele

Dieses Programm vermittelt Ärzten umfassende Kenntnisse über die Anwendung von Technologien der künstlichen Intelligenz in der diagnostischen Bildgebung. Die Studenten werden auch fortgeschrittene Fähigkeiten entwickeln, um neue Techniken wie *Data Mining*, *Big Data* oder *Deep Learning* im klinischen Bereich einzusetzen. Außerdem werden Gesundheitsfachkräfte mit Tools wie *Convolutional Neural Networks* umgehen, um medizinische Bilder verschiedener Modalitäten zu interpretieren. Auf diese Weise werden Spezialisten Anomalien in den durchgeführten bildgebenden Untersuchungen erkennen und genauere Diagnosen stellen können, um die Genesung der Patienten zu verbessern.





“

Sie werden künstliche Intelligenz einsetzen, um Routineaufgaben wie die Erkennung von Anomalien in großen Mengen von Bildern zu automatisieren, damit Sie sich auf die komplexesten klinischen Fälle konzentrieren können“



Allgemeine Ziele

- Verstehen der theoretischen Grundlagen der künstlichen Intelligenz
- Studieren der verschiedenen Arten von Daten und Verstehen des Lebenszyklus von Daten
- Bewerten der entscheidenden Rolle von Daten bei der Entwicklung und Implementierung von KI-Lösungen
- Vertiefen des Verständnisses von Algorithmen und Komplexität zur Lösung spezifischer Probleme
- Erforschen der theoretischen Grundlagen von neuronalen Netzen für die Entwicklung von *Deep Learning*
- Erforschen des bio-inspirierten Computings und seiner Bedeutung für die Entwicklung intelligenter Systeme
- Entwickeln von Fähigkeiten zur Nutzung und Anwendung fortschrittlicher Tools der künstlichen Intelligenz bei der Auswertung und Analyse medizinischer Bilder zur Verbesserung der Diagnosegenauigkeit
- Implementieren von Lösungen der künstlichen Intelligenz, die die Automatisierung von Prozessen und die Personalisierung von Diagnosen ermöglichen
- Anwenden von Techniken des *Data Mining* und der prädiktiven Analyse, um evidenzbasierte klinische Entscheidungen zu treffen
- Erwerben von Forschungskompetenzen, die es Experten ermöglichen, zur Weiterentwicklung von künstlicher Intelligenz in der medizinischen Bildgebung beizutragen





Spezifische Ziele

Modul 1. Grundlagen der künstlichen Intelligenz

- ♦ Analysieren der historischen Entwicklung der künstlichen Intelligenz, von ihren Anfängen bis zu ihrem heutigen Stand, Identifizierung der wichtigsten Meilensteine und Entwicklungen
- ♦ Verstehen der Funktionsweise von neuronalen Netzen und ihrer Anwendung in Lernmodellen der künstlichen Intelligenz
- ♦ Untersuchen der Prinzipien und Anwendungen von genetischen Algorithmen und analysieren ihren Nutzen bei der Lösung komplexer Probleme
- ♦ Analysieren der Bedeutung von Thesauri, Vokabularen und Taxonomien bei der Strukturierung und Verarbeitung von Daten für KI-Systeme

Modul 2. Datentypen und Datenlebenszyklus

- ♦ Verstehen der grundlegenden Konzepte der Statistik und ihrer Anwendung in der Datenanalyse
- ♦ Identifizieren und Klassifizieren der verschiedenen Arten von statistischen Daten, von quantitativen bis zu qualitativen Daten
- ♦ Analysieren des Lebenszyklus von Daten, von der Erzeugung bis zur Entsorgung, und Identifizieren der wichtigsten Phasen
- ♦ Erkunden der ersten Phasen des Lebenszyklus von Daten, wobei die Bedeutung der Datenplanung und der Datenstruktur hervorgehoben wird
- ♦ Untersuchen der Prozesse der Datenerfassung, einschließlich Methodik, Tools und Erfassungskanäle
- ♦ Untersuchen des *Datawarehouse*-Konzepts mit Schwerpunkt auf den Elementen des Datawarehouse und seinem Design

Modul 3. Daten in der künstlichen Intelligenz

- ♦ Beherrschen der Grundlagen der Datenwissenschaft, einschließlich der Werkzeuge, Typen und Quellen für die Informationsanalyse
- ♦ Erforschen des Prozesses der Umwandlung von Daten in Informationen mithilfe von *Data Mining* und Datenvisualisierungstechniken
- ♦ Studieren der Struktur und der Eigenschaften von *Datasets* und verstehen ihrer Bedeutung für die Aufbereitung und Nutzung von Daten für KI-Modelle
- ♦ Verwenden spezifischer Tools und bewährter Verfahren für die Datenverarbeitung, um Effizienz und Qualität bei der Implementierung von künstlicher Intelligenz zu gewährleisten

Modul 4. *Data Mining*. Auswahl, Vorverarbeitung und Transformation

- ♦ Beherrschen statistischer Inferenztechniken, um statistische Methoden im *Data Mining* zu verstehen und anzuwenden
- ♦ Durchführen detaillierter explorativer Analysen von Datensätzen, um relevante Muster, Anomalien und Trends zu erkennen
- ♦ Entwickeln von Fähigkeiten zur Datenaufbereitung, einschließlich Datenbereinigung, -integration und -formatierung für die Verwendung im *Data Mining*
- ♦ Implementieren effektiver Strategien für den Umgang mit fehlenden Werten in Datensätzen, indem je nach Kontext Imputations- oder Eliminierungsmethoden angewendet werden
- ♦ Identifizieren und Entschärfen von Datenrauschen, indem Sie Filter- und Glättungsverfahren anwenden, um die Qualität des Datensatzes zu verbessern
- ♦ Eingehen auf die Datenvorverarbeitung in *Big-Data*-Umgebungen

Modul 5. Algorithmik und Komplexität in der künstlichen Intelligenz

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

Modul 6. Intelligente Systeme

- ♦ Erforschen der Agententheorie, Verstehen der grundlegenden Konzepte ihrer Funktionsweise und ihrer Anwendung in der künstlichen Intelligenz und im Software Engineering
- ♦ Studieren der Darstellung von Wissen, einschließlich der Analyse von Ontologien und deren Anwendung bei der Organisation von strukturierten Informationen
- ♦ Analysieren des Konzepts des semantischen Webs und seiner Auswirkungen auf die Organisation und den Abruf von Informationen in digitalen Umgebungen

- ♦ Evaluieren und Vergleichen verschiedener Wissensrepräsentationen und deren Integration zur Verbesserung der Effizienz und Genauigkeit von intelligenten Systemen

Modul 7. Maschinelles Lernen und *Data Mining*

- ♦ Einführen in die Prozesse der Wissensentdeckung und in die grundlegenden Konzepte des maschinellen Lernens
- ♦ Untersuchen von Entscheidungsbäumen als überwachte Lernmodelle, Verstehen ihrer Struktur und Anwendungen
- ♦ Bewerten von Klassifikatoren anhand spezifischer Techniken, um ihre Leistung und Genauigkeit bei der Datenklassifizierung zu messen
- ♦ Studieren neuronaler Netze und Verstehen ihrer Funktionsweise und Architektur, um komplexe Probleme des maschinellen Lernens zu lösen
- ♦ Erforschen von Bayes'schen Methoden und deren Anwendung im maschinellen Lernen, einschließlich Bayes'scher Netzwerke und Bayes'scher Klassifikatoren
- ♦ Analysieren von Regressions- und kontinuierlichen Antwortmodellen zur Vorhersage von numerischen Werten aus Daten
- ♦ Untersuchen von Techniken zum *Clustering*, um Muster und Strukturen in unmarkierten Datensätzen zu erkennen
- ♦ Erforschen von *Text Mining* und natürlicher Sprachverarbeitung (NLP), um zu verstehen, wie maschinelle Lerntechniken zur Analyse und zum Verständnis von Texten eingesetzt werden

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

- ♦ Beherrschen der Grundlagen des tiefen Lernens und Verstehen seiner wesentlichen Rolle beim *Deep Learning*
- ♦ Erkunden der grundlegenden Operationen in neuronalen Netzen und Verstehen ihrer Anwendung bei der Konstruktion von Modellen



- ◆ Analysieren der verschiedenen Schichten, die in neuronalen Netzen verwendet werden, und lernen, wie man sie richtig auswählt
- ◆ Verstehen der effektiven Verknüpfung von Schichten und Operationen, um komplexe und effiziente neuronale Netzarchitekturen zu entwerfen
- ◆ Verwenden von Trainern und Optimierern, um die Leistung von neuronalen Netzen abzustimmen und zu verbessern
- ◆ Erforschen der Verbindung zwischen biologischen und künstlichen Neuronen für ein tieferes Verständnis des Modelldesigns

Modul 9. Training Tiefer Neuronaler Netze

- ◆ Lösen von Problemen im Zusammenhang mit Gradienten beim Training von tiefen neuronalen Netzen
- ◆ Erforschen und Anwenden verschiedener Optimierer, um die Effizienz und Konvergenz von Modellen zu verbessern
- ◆ Programmieren der Lernrate zur dynamischen Anpassung der Konvergenzrate des Modells
- ◆ Verstehen und Bewältigen von *Overfitting* durch spezifische Strategien beim Training
- ◆ Anwenden praktischer Richtlinien, um ein effizientes und effektives Training von tiefen neuronalen Netzen zu gewährleisten
- ◆ Implementieren von *Transfer Learning* als fortgeschrittene Technik zur Verbesserung der Modellleistung bei bestimmten Aufgaben
- ◆ Erforschen und Anwenden von Techniken der *Data Augmentation* zur Anreicherung von Datensätzen und Verbesserung der Modellgeneralisierung
- ◆ Entwickeln praktischer Anwendungen mit *Transfer Learning* zur Lösung realer Probleme

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

- ♦ Beherrschen der Grundlagen von *TensorFlow* und seiner Integration mit NumPy für effiziente Datenverwaltung und Berechnungen
- ♦ Anpassen von Modellen und Trainingsalgorithmen mit den fortgeschrittenen Fähigkeiten von *TensorFlow*
- ♦ Erforschen der tfdata-API zur effektiven Verwaltung und Manipulation von Datensätzen
- ♦ Implementieren des Formats TFRecord, um große Datensätze in *TensorFlow* zu speichern und darauf zuzugreifen
- ♦ Verwenden von Keras-Vorverarbeitungsschichten zur Erleichterung der Konstruktion eigener Modelle
- ♦ Erforschen des *TensorFlow Datasets*-Projekts, um auf vordefinierte Datensätze zuzugreifen und die Entwicklungseffizienz zu verbessern
- ♦ Entwickeln einer *Deep Learning*-Anwendung mit *TensorFlow* unter Einbeziehung der im Modul erworbenen Kenntnisse
- ♦ Anwenden aller Konzepte, die bei der Erstellung und dem Training von benutzerdefinierten Modellen mit *TensorFlow* erlernt wurden, auf praktische Art und Weise in realen Situationen

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

- ♦ Verstehen der Architektur des visuellen Kortex und ihrer Bedeutung für *Deep Computer Vision*
- ♦ Erforschen und Anwenden von Faltungsschichten, um wichtige Merkmale aus Bildern zu extrahieren
- ♦ Implementieren von *Clustering*-Schichten und ihre Verwendung in *Deep Computer Vision*-Modellen mit Keras
- ♦ Analysieren verschiedener Architekturen von *Convolutional Neural Networks* (CNN) und deren Anwendbarkeit in verschiedenen Kontexten

- ♦ Entwickeln und Implementieren eines CNN ResNet unter Verwendung der Keras-Bibliothek, um die Effizienz und Leistung des Modells zu verbessern
- ♦ Verwenden von vorab trainierten Keras-Modellen, um das Transfer-Lernen für bestimmte Aufgaben zu nutzen
- ♦ Anwenden von Klassifizierungs- und Lokalisierungstechniken in *Deep Computer Vision*-Umgebungen
- ♦ Erforschen von Strategien zur Objekterkennung und -verfolgung mit *Convolutional Neural Networks*

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

- ♦ Entwickeln von Fähigkeiten zur Texterstellung mit rekurrenten neuronalen Netzen (RNN)
- ♦ Anwenden von RNNs bei der Meinungsklassifizierung zur Stimmungsanalyse in Texten
- ♦ Verstehen und Anwenden von Aufmerksamkeitsmechanismen in Modellen zur Verarbeitung natürlicher Sprache
- ♦ Analysieren und Verwenden von *Transformers*-Modellen in spezifischen NLP-Aufgaben
- ♦ Erkunden der Anwendung von *Transformers*-Modellen im Kontext von Bildverarbeitung und Computer Vision
- ♦ Vertraut sein mit der *Hugging Face Transformers*-Bibliothek für die effiziente Implementierung fortgeschrittener Modelle
- ♦ Vergleichen der verschiedenen *Transformers*-Bibliotheken, um ihre Eignung für bestimmte Aufgaben zu bewerten
- ♦ Entwickeln einer praktischen Anwendung von NLP, die RNN- und Aufmerksamkeitsmechanismen integriert, um reale Probleme zu lösen

Modul 13. Autoencoder, GANs und Diffusionsmodelle

- Entwickeln effizienter Datenrepräsentationen mit *Autoencodern*, *GANs* und Diffusionsmodellen
- Durchführen einer PCA unter Verwendung eines unvollständigen linearen *Autoencoders* zur Optimierung der Datendarstellung
- Implementieren und Verstehen der Funktionsweise von gestapelten *Autoencodern*
- Erforschen und Anwenden von *Convolutional Autoencoders* für effiziente visuelle Datendarstellungen
- Analysieren und Anwenden der Effektivität von *Sparse Autoencodern* bei der Datendarstellung
- Generieren von Modebildern aus dem MNIST-Datensatz mit Hilfe von *Autoencoders*
- Verstehen des Konzepts der *Generative Adversarial Networks (GANs)* und Diffusionsmodelle
- Implementieren und Vergleichen der Leistung von Diffusionsmodellen und *GANs* bei der Datengenerierung

Modul 14. Bio-inspiriertes Computing

- Einführen in die grundlegenden Konzepte des bio-inspirierten Computings
- Analysieren von Strategien zur Erforschung und Ausnutzung des Raums in genetischen Algorithmen
- Untersuchen von Modellen des evolutionären Rechnens im Kontext der Optimierung
- Fortsetzen der detaillierten Analyse von Modellen des evolutionären Rechnens
- Anwenden der evolutionären Programmierung auf spezifische Lernprobleme
- Bewältigen der Komplexität von Multi-Objektiv-Problemen im Rahmen des bio-inspirierten Computings
- Erforschen der Anwendung von neuronalen Netzen im Bereich des bio-inspirierten Computings

- Vertiefen der Implementierung und des Nutzens von neuronalen Netzen im Bereich des bio-inspirierten Computings

Modul 15. Künstliche Intelligenz: Strategien und Anwendungen

- Entwickeln von Strategien für die Implementierung von künstlicher Intelligenz in Finanzdienstleistungen
- Identifizieren und Bewerten der Risiken im Zusammenhang mit dem Einsatz von KI im Gesundheitssektor
- Bewerten der potenziellen Risiken im Zusammenhang mit dem Einsatz von KI in der Industrie
- Anwenden von Techniken der künstlichen Intelligenz in der Industrie zur Verbesserung der Produktivität
- Entwerfen von Lösungen der künstlichen Intelligenz zur Optimierung von Prozessen in der öffentlichen Verwaltung
- Bewerten des Einsatzes von KI-Technologien im Bildungssektor
- Anwenden von Techniken der künstlichen Intelligenz in der Forst- und Landwirtschaft zur Verbesserung der Produktivität
- Optimieren von Personalprozessen durch den strategischen Einsatz von künstlicher Intelligenz

Modul 16. Innovationen der künstlichen Intelligenz in der diagnostischen Bildgebung

- Beherrschen von Tools wie IBM Watson Imaging und NVIDIA Clara zur automatischen Interpretation klinischer Tests
- Erwerben von Kompetenzen zur Durchführung von klinischen Experimenten und zur Analyse der Ergebnisse mit Hilfe von künstlicher Intelligenz, wobei der Schwerpunkt auf der Verbesserung der diagnostischen Genauigkeit liegt

Modul 17. Fortgeschrittene Anwendungen der künstlichen Intelligenz in Studien und Analysen von medizinischen Bildern

- ♦ Durchführen von Beobachtungsstudien im Bereich der Bildgebung mit Hilfe von künstlicher Intelligenz und effizienter Validierung und Kalibrierung von Modellen
- ♦ Integrieren medizinischer Bildgebungsdaten mit anderen biomedizinischen Quellen und Verwenden von Tools wie Enlitic Curie, um multidisziplinäre Untersuchungen durchzuführen

Modul 18. Personalisierung und Automatisierung in der medizinischen Diagnostik durch künstliche Intelligenz

- ♦ Erwerben von Fähigkeiten zur Personalisierung von Diagnosen mithilfe von künstlicher Intelligenz, indem bildgebende Befunde mit genomischen Daten und anderen Biomarkern korreliert werden
- ♦ Beherrschen der Automatisierung der medizinischen Bilderfassung und -verarbeitung unter Anwendung fortschrittlicher Technologien der künstlichen Intelligenz

Modul 19. *Big Data* und prädiktive Analytik in der medizinischen Bildgebung

- ♦ Verwalten großer Datenmengen mithilfe von *Data-Mining*-Techniken und Algorithmen des maschinellen Lernens
- ♦ Erstellen von klinischen Prognosetools auf der Grundlage von *Big-Data*-Analysen mit dem Ziel, klinische Entscheidungen zu optimieren





Modul 20. Ethische und rechtliche Aspekte der künstlichen Intelligenz in der diagnostischen Bildgebung

- Erwerben eines ganzheitlichen Verständnisses der regulatorischen und deontologischen Prinzipien, die den Einsatz von Intelligenz im Bereich der Gesundheitsversorgung regeln, einschließlich Aspekten wie der informierten Zustimmung
- In der Lage sein, Modelle der künstlichen Intelligenz, die in der klinischen Praxis eingesetzt werden, zu überprüfen, um Transparenz und Verantwortlichkeit bei medizinischen Entscheidungen zu gewährleisten

“

Sie werden wertvolle Lektionen lernen, indem Sie echte klinische Fälle in simulierten Lernumgebungen lösen“

03

Kompetenzen

Nach Abschluss dieses Programms werden Ärzte in der Lage sein, fortschrittliche Technologien der künstlichen Intelligenz in ihrer täglichen klinischen Praxis einzusetzen. Dementsprechend werden die Absolventen technische Fähigkeiten entwickeln, um mit Tools wie *Deep Learning* oder bioinspiriertem Computing umzugehen. Auf diese Weise erhalten Fachleute wertvolle *Insights*, um verschiedene diagnostische Tests zu interpretieren und eine breite Palette von Krankheiten frühzeitig zu erkennen. So können Fachleute hochgradig personalisierte Interventionspläne entwerfen, die die Lebensqualität der Patienten erheblich verbessern.



“

Sie werden Data Mining beherrschen, um die Entwicklung einer Krankheit oder die Reaktion von Personen auf Behandlungen vorherzusehen und so fundierte klinische Entscheidungen treffen zu können“



Allgemeine Kompetenzen

- ♦ Effektives Anwenden der grundlegenden Techniken der künstlichen Intelligenz (*Big Data*, *Deep Learning*, neuronale Netze usw.) zur Optimierung der Analyse von Diagnosebildern
- ♦ Kritisches Interpretieren der von Systemen der künstlichen Intelligenz erzeugten Ergebnisse, um sowohl die Gültigkeit als auch die klinische Relevanz der Vorhersagen oder Klassifizierungen sicherzustellen
- ♦ Handhaben von KI-Programmiersprachen wie z. B. Python, um die Qualität der gewonnenen Daten sicherzustellen
- ♦ Entwickeln fortgeschrittener Fähigkeiten, um Verbesserungsmöglichkeiten in der diagnostischen Bildgebung zu erkennen und neue technologische Lösungen zu entwerfen
- ♦ Anpassen von Modellen der künstlichen Intelligenz für die Diagnose spezifischer Pathologien wie z. B. Tumoren unter Berücksichtigung individueller Variationen und Bevölkerungsmerkmale
- ♦ Verständliches und präzises Übermitteln der Ergebnisse von klinischen Analysen an verschiedene Zielgruppen





Spezifische Kompetenzen

- Trainieren von *Deep Neural Networks* zur Klassifizierung, Segmentierung und Mustererkennung in radiologischen Bildern
- Anwenden fortgeschrittener Bildverarbeitungsmethoden wie Filterung, Normalisierung und Kontrastverstärkung
- Handhaben von medizinischer Software, die Algorithmen der künstlichen Intelligenz für die automatisierte Analyse klinischer Tests enthält, und Sicherstellen ihrer Benutzerfreundlichkeit und der Einhaltung von Gesundheitsvorschriften
- Durchführen von klinischen Validierungsstudien, um sicherzustellen, dass die Tools der künstlichen Intelligenz effektiv sind und in der klinischen Praxis tatsächlich angewendet werden können



Sie werden Forschungsprojekte leiten, die neue Anwendungen der künstlichen Intelligenz in der diagnostischen Bildgebung erforschen und Innovationen im medizinischen Bereich vorantreiben“

04

Kursleitung

Die Philosophie von TECH basiert darauf, die umfassendsten und pragmatischsten Abschlüsse in der akademischen Szene anzubieten, weshalb sie einen sorgfältigen Prozess zur Auswahl ihres Lehrkörpers durchführt. Für dieses Programm arbeitet sie mit den besten Experten auf dem Gebiet der künstlichen Intelligenz in der diagnostischen Bildgebung zusammen. Diese Experten können auf eine lange berufliche Laufbahn zurückblicken, in der sie dazu beigetragen haben, die Lebensqualität vieler Patienten zu verbessern. So haben die Absolventen die Garantien, die sie verlangen, um eine Erfahrung zu machen, die ihnen einen Qualitätssprung in ihrer klinischen Praxis ermöglichen wird.



“

Sie werden von einem Dozententeam unterstützt, das sich aus authentischen Experten für künstliche Intelligenz in der diagnostischen Bildgebung zusammensetzt“

Leitung



Dr. Peralta Martín-Palomino, Arturo

- ♦ CEO und CTO bei Prometheus Global Solutions
- ♦ CTO bei Korporate Technologies
- ♦ CTO bei AI Shepherds GmbH
- ♦ Berater und strategischer Unternehmensberater bei Alliance Medical
- ♦ Direktor für Design und Entwicklung bei DocPath
- ♦ Promotion in Computertechnik an der Universität von Castilla La Mancha
- ♦ Promotion in Wirtschaftswissenschaften, Unternehmen und Finanzen an der Universität Camilo José Cela
- ♦ Promotion in Psychologie an der Universität von Castilla La Mancha
- ♦ Masterstudiengang Executive MBA von der Universität Isabel I
- ♦ Masterstudiengang in Business und Marketing Management von der Universität Isabel I
- ♦ Masterstudiengang in Big Data bei Formación Hadoop
- ♦ Masterstudiengang in Fortgeschrittene Informationstechnologie von der Universität von Castilla La Mancha
- ♦ Mitglied von: Forschungsgruppe SMILE



Professoren

Hr. Popescu Radu, Daniel Vasile

- Unabhängiger Spezialist für Pharmakologie, Ernährung und Diätetik
- Freiberuflicher Produzent von didaktischen und wissenschaftlichen Inhalten
- Kommunaler 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

“

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

05

Struktur und Inhalt

Die Lehrmaterialien, aus denen dieses Universitätsprogramm besteht, wurden von Spezialisten für den Einsatz von künstlicher Intelligenz in klinischen Kontexten entwickelt. Dank dessen vertieft der Studiengang den Umgang mit verschiedenen aufkommenden Tools wie *Deep Learning*, *Deep Neural Networks* oder natürlicher Sprachverarbeitung. Auf diese Weise werden die Studenten fortgeschrittene Fähigkeiten entwickeln, um diese Instrumente in ihre tägliche Praxis zu integrieren und die Ergebnisse von bildgebenden Tests umfassend zu analysieren. Darüber hinaus werden Ärzte dadurch in die Lage versetzt, die Genauigkeit ihrer Diagnosen zu optimieren und Behandlungen zu personalisieren, um zum allgemeinen Wohlbefinden der Patienten beizutragen.



“

Sie werden die ausgefeiltesten Big-Data-Techniken nutzen, um schwere Pathologien wie Krebs frühzeitig zu erkennen und individualisierte Therapiepläne zu entwerfen, um die Genesung der Nutzer zu optimieren“

Modul 1. Grundlagen der künstlichen Intelligenz

- 1.1. Geschichte der künstlichen Intelligenz
 - 1.1.1. Ab wann spricht man von künstlicher Intelligenz?
 - 1.1.2. Referenzen im Kino
 - 1.1.3. Bedeutung der künstlichen Intelligenz
 - 1.1.4. Technologien, die künstliche Intelligenz ermöglichen und unterstützen
- 1.2. Künstliche Intelligenz in Spielen
 - 1.2.1. Spieltheorie
 - 1.2.2. *Minimax* und Alpha-Beta-Beschneidung
 - 1.2.3. Simulation: Monte Carlo
- 1.3. Neuronale Netzwerke
 - 1.3.1. Biologische Grundlagen
 - 1.3.2. Berechnungsmodell
 - 1.3.3. Überwachte und nicht überwachte neuronale Netzwerke
 - 1.3.4. Einfaches Perzeptron
 - 1.3.5. Mehrschichtiges Perzeptron
- 1.4. Genetische Algorithmen
 - 1.4.1. Geschichte
 - 1.4.2. Biologische Grundlage
 - 1.4.3. Problem-Kodierung
 - 1.4.4. Erzeugung der Ausgangspopulation
 - 1.4.5. Hauptalgorithmus und genetische Operatoren
 - 1.4.6. Bewertung von Personen: Fitness
- 1.5. Thesauri, Vokabularien, Taxonomien
 - 1.5.1. Wortschatz
 - 1.5.2. Taxonomie
 - 1.5.3. Thesauri
 - 1.5.4. Ontologien
 - 1.5.5. Wissensrepräsentation: Semantisches Web
- 1.6. Semantisches Web
 - 1.6.1. Spezifizierungen: RDF, RDFS und OWL
 - 1.6.2. Schlussfolgerung/Begründung
 - 1.6.3. *Linked Data*



- 1.7. Expertensysteme und DSS
 - 1.7.1. Expertensysteme
 - 1.7.2. Systeme zur Entscheidungshilfe
- 1.8. *Chatbots* und virtuelle Assistenten
 - 1.8.1. Arten von Assistenten: sprach- und textbasierte Assistenten
 - 1.8.2. Grundlegende Bestandteile für die Entwicklung eines Assistenten: *Intents*, Entitäten und Dialogablauf
 - 1.8.3. Integrationen: Web, *Slack*, Whatsapp, Facebook
 - 1.8.4. Tools für die Entwicklung von Assistenten: *Dialog Flow*, *Watson Assistant*
- 1.9. KI-Implementierungsstrategie
- 1.10. Die Zukunft der künstlichen Intelligenz
 - 1.10.1. Wir wissen, wie man mit Algorithmen Emotionen erkennt
 - 1.10.2. Eine Persönlichkeit schaffen: Sprache, Ausdrücke und Inhalt
 - 1.10.3. Tendenzen der künstlichen Intelligenz
 - 1.10.4. Reflexionen

Modul 2. Datentypen und Datenlebenszyklus

- 2.1. Die Statistik
 - 2.1.1. Statistik: Deskriptive Statistik, statistische Schlussfolgerungen
 - 2.1.2. Population, Stichprobe, Individuum
 - 2.1.3. Variablen: Definition und Mess-Skalen
- 2.2. Arten von statistischen Daten
 - 2.2.1. Je nach Typ
 - 2.2.1.1. Quantitativ: kontinuierliche Daten und diskrete Daten
 - 2.2.1.2. Qualitativ: Binomialdaten, nominale Daten und ordinale Daten
 - 2.2.2. Je nach Form
 - 2.2.2.1. Numerisch
 - 2.2.2.2. Text
 - 2.2.2.3. Logisch
 - 2.2.3. Je nach Quelle
 - 2.2.3.1. Primär
 - 2.2.3.2. Sekundär

- 2.3. Lebenszyklus der Daten
 - 2.3.1. Etappen des Zyklus
 - 2.3.2. Meilensteine des Zyklus
 - 2.3.3. FAIR-Prinzipien
- 2.4. Die ersten Phasen des Zyklus
 - 2.4.1. Definition von Zielen
 - 2.4.2. Ermittlung des Ressourcenbedarfs
 - 2.4.3. Gantt-Diagramm
 - 2.4.4. Struktur der Daten
- 2.5. Datenerhebung
 - 2.5.1. Methodik der Erhebung
 - 2.5.2. Erhebungsinstrumente
 - 2.5.3. Kanäle für die Erhebung
- 2.6. Datenbereinigung
 - 2.6.1. Phasen der Datenbereinigung
 - 2.6.2. Qualität der Daten
 - 2.6.3. Datenmanipulation (mit R)
- 2.7. Datenanalyse, Interpretation und Bewertung der Ergebnisse
 - 2.7.1. Statistische Maßnahmen
 - 2.7.2. Beziehungsindizes
 - 2.7.3. *Data Mining*
- 2.8. Datenlager (*Datawarehouse*)
 - 2.8.1. Elemente, aus denen sie bestehen
 - 2.8.2. Design
 - 2.8.3. Zu berücksichtigende Aspekte
- 2.9. Verfügbarkeit von Daten
 - 2.9.1. Zugang
 - 2.9.2. Nützlichkeit
 - 2.9.3. Sicherheit
- 2.10. Regulatorische Aspekte
 - 2.10.1. Datenschutzgesetz
 - 2.10.2. Bewährte Verfahren
 - 2.10.3. Andere regulatorische Aspekte

Modul 3. Daten in der künstlichen Intelligenz

- 3.1. Datenwissenschaft
 - 3.1.1. Datenwissenschaft
 - 3.1.2. Fortgeschrittene Tools für den Datenwissenschaftler
- 3.2. Daten, Informationen und Wissen
 - 3.2.1. Daten, Informationen und Wissen
 - 3.2.2. Datentypen
 - 3.2.3. Datenquellen
- 3.3. Von Daten zu Informationen
 - 3.3.1. Datenanalyse
 - 3.3.2. Arten der Analyse
 - 3.3.3. Extraktion von Informationen aus einem *Dataset*
- 3.4. Extraktion von Informationen durch Visualisierung
 - 3.4.1. Visualisierung als Analyseinstrument
 - 3.4.2. Visualisierungsmethoden
 - 3.4.3. Visualisierung eines Datensatzes
- 3.5. Qualität der Daten
 - 3.5.1. Datenqualität
 - 3.5.2. Datenbereinigung
 - 3.5.3. Grundlegende Datenvorverarbeitung
- 3.6. *Dataset*
 - 3.6.1. *Dataset*-Anreicherung
 - 3.6.2. Der Fluch der Dimensionalität
 - 3.6.3. Ändern unseres Datensatzes
- 3.7. Ungleichgewicht
 - 3.7.1. Ungleichgewicht der Klassen
 - 3.7.2. Techniken zur Begrenzung von Ungleichgewichten
 - 3.7.3. *Dataset*-Abgleich
- 3.8. Unüberwachte Modelle
 - 3.8.1. Unüberwachtes Modell
 - 3.8.2. Methoden
 - 3.8.3. Klassifizierung mit unüberwachten Modellen

- 3.9. Überwachte Modelle
 - 3.9.1. Überwachtes Modell
 - 3.9.2. Methoden
 - 3.9.3. Klassifizierung mit überwachten Modellen
- 3.10. Tools und bewährte Verfahren
 - 3.10.1. Bewährte Praktiken für einen Datenwissenschaftler
 - 3.10.2. Das beste Modell
 - 3.10.3. Nützliche Tools

Modul 4. *Data Mining*. Auswahl, Vorverarbeitung und Transformation

- 4.1. Statistische Inferenz
 - 4.1.1. Deskriptive Statistik vs. statistische Inferenz
 - 4.1.2. Parametrische Verfahren
 - 4.1.3. Nichtparametrische Verfahren
- 4.2. Explorative Analyse
 - 4.2.1. Deskriptive Analyse
 - 4.2.2. Visualisierung
 - 4.2.3. Vorbereitung der Daten
- 4.3. Vorbereitung der Daten
 - 4.3.1. Datenintegration und -bereinigung
 - 4.3.2. Normalisierung der Daten
 - 4.3.3. Attribute umwandeln
- 4.4. Verlorene Werte
 - 4.4.1. Umgang mit verlorenen Werten
 - 4.4.2. Maximum-Likelihood-Imputationsmethoden
 - 4.4.3. Imputation verlorener Werte durch maschinelles Lernen
- 4.5. Datenrauschen
 - 4.5.1. Lärmklassen und Attribute
 - 4.5.2. Rauschfilterung
 - 4.5.3. Rauscheffekt
- 4.6. Der Fluch der Dimensionalität
 - 4.6.1. *Oversampling*
 - 4.6.2. *Undersampling*
 - 4.6.3. Multidimensionale Datenreduktion

- 4.7. Kontinuierliche zu diskreten Attributen
 - 4.7.1. Kontinuierliche versus diskrete Daten
 - 4.7.2. Prozess der Diskretisierung
- 4.8. Daten
 - 4.8.1. Datenauswahl
 - 4.8.2. Perspektiven und Auswahlkriterien
 - 4.8.3. Methoden der Auswahl
- 4.9. Auswahl der Instanzen
 - 4.9.1. Methoden für die Instanzauswahl
 - 4.9.2. Auswahl der Prototypen
 - 4.9.3. Erweiterte Methoden für die Instanzauswahl
- 4.10. Vorverarbeitung von Daten in *Big Data*-Umgebungen

Modul 5. Algorithmik und Komplexität in der künstlichen Intelligenz

- 5.1. Einführung in Algorithmus-Design-Strategien
 - 5.1.1. Rekursion
 - 5.1.2. Aufteilen und erobern
 - 5.1.3. Andere Strategien
- 5.2. Effizienz und Analyse von Algorithmen
 - 5.2.1. Maßnahmen zur Steigerung der Effizienz
 - 5.2.2. Messung der Eingabegröße
 - 5.2.3. Messung der Ausführungszeit
 - 5.2.4. Schlimmster, bester und durchschnittlicher Fall
 - 5.2.5. Asymptotische Notation
 - 5.2.6. Kriterien für die mathematische Analyse von nicht-rekursiven Algorithmen
 - 5.2.7. Mathematische Analyse von rekursiven Algorithmen
 - 5.2.8. Empirische Analyse von Algorithmen
- 5.3. Sortieralgorithmen
 - 5.3.1. Konzept der Sortierung
 - 5.3.2. Blase sortieren
 - 5.3.3. Sortieren nach Auswahl
 - 5.3.4. Reihenfolge der Insertion
 - 5.3.5. Sortierung zusammenführen (*Merge_Sort*)
 - 5.3.6. Schnelle Sortierung (*Quick_Sort*)
- 5.4. Algorithmen mit Bäumen
 - 5.4.1. Konzept des Baumes
 - 5.4.2. Binäre Bäume
 - 5.4.3. Baumpfade
 - 5.4.4. Ausdrücke darstellen
 - 5.4.5. Geordnete binäre Bäume
 - 5.4.6. Ausgeglichene binäre Bäume
- 5.5. Algorithmen mit *Heaps*
 - 5.5.1. *Heaps*
 - 5.5.2. Der *Heapsort*-Algorithmus
 - 5.5.3. Prioritätswarteschlangen
- 5.6. Graph-Algorithmen
 - 5.6.1. Vertretung
 - 5.6.2. Lauf in Breite
 - 5.6.3. Lauf in Tiefe
 - 5.6.4. Topologische Anordnung
- 5.7. *Greedy*-Algorithmen
 - 5.7.1. Die *Greedy*-Strategie
 - 5.7.2. Elemente der *Greedy*-Strategie
 - 5.7.3. Währungsumtausch
 - 5.7.4. Das Problem des Reisenden
 - 5.7.5. Problem mit dem Rucksack
- 5.8. Minimale Pfadsuche
 - 5.8.1. Das Problem des minimalen Pfades
 - 5.8.2. Negative Bögen und Zyklen
 - 5.8.3. Dijkstra-Algorithmus
- 5.9. *Greedy*-Algorithmen auf Graphen
 - 5.9.1. Der minimal aufspannende Baum
 - 5.9.2. Algorithmus von Prim
 - 5.9.3. Algorithmus von Kruskal
 - 5.9.4. Komplexitätsanalyse
- 5.10. *Backtracking*
 - 5.10.1. Das *Backtracking*
 - 5.10.2. Alternative Techniken

Modul 6. Intelligente Systeme

- 6.1. Agententheorie
 - 6.1.1. Geschichte des Konzepts
 - 6.1.2. Definition von Agent
 - 6.1.3. Agenten in der künstlichen Intelligenz
 - 6.1.4. Agenten in der Softwareentwicklung
- 6.2. Agent-Architekturen
 - 6.2.1. Der Denkprozess eines Agenten
 - 6.2.2. Reaktive Agenten
 - 6.2.3. Deduktive Agenten
 - 6.2.4. Hybride Agenten
 - 6.2.5. Vergleich
- 6.3. Informationen und Wissen
 - 6.3.1. Unterscheidung zwischen Daten, Informationen und Wissen
 - 6.3.2. Bewertung der Datenqualität
 - 6.3.3. Methoden der Datenerfassung
 - 6.3.4. Methoden der Informationsbeschaffung
 - 6.3.5. Methoden zum Wissenserwerb
- 6.4. Wissensrepräsentation
 - 6.4.1. Die Bedeutung der Wissensrepräsentation
 - 6.4.2. Definition der Wissensrepräsentation durch ihre Rollen
 - 6.4.3. Merkmale einer Wissensrepräsentation
- 6.5. Ontologien
 - 6.5.1. Einführung in Metadaten
 - 6.5.2. Philosophisches Konzept der Ontologie
 - 6.5.3. Computergestütztes Konzept der Ontologie
 - 6.5.4. Bereichsontologien und Ontologien auf höherer Ebene
 - 6.5.5. Wie erstellt man eine Ontologie?
- 6.6. Ontologiesprachen und Software für die Erstellung von Ontologien
 - 6.6.1. RDF-Tripel, *Turtle* und N
 - 6.6.2. RDF-Schema
 - 6.6.3. OWL
 - 6.6.4. SPARQL
 - 6.6.5. Einführung in die verschiedenen Tools für die Erstellung von Ontologien
 - 6.6.6. Installation und Verwendung von *Protégé*
- 6.7. Das semantische Web
 - 6.7.1. Der aktuelle Stand und die Zukunft des semantischen Webs
 - 6.7.2. Anwendungen des semantischen Webs
- 6.8. Andere Modelle der Wissensdarstellung
 - 6.8.1. Wortschatz
 - 6.8.2. Globale Sicht
 - 6.8.3. Taxonomie
 - 6.8.4. Thesauri
 - 6.8.5. Folksonomien
 - 6.8.6. Vergleich
 - 6.8.7. Mind Map
- 6.9. Bewertung und Integration von Wissensrepräsentationen
 - 6.9.1. Logik nullter Ordnung
 - 6.9.2. Logik erster Ordnung
 - 6.9.3. Beschreibende Logik
 - 6.9.4. Beziehung zwischen verschiedenen Arten von Logik
 - 6.9.5. *Prolog*: Programmierung auf Basis der Logik erster Ordnung
- 6.10. Semantische *Reasoner*, wissensbasierte Systeme und Expertensysteme
 - 6.10.1. Konzept des *Reasoners*
 - 6.10.2. Anwendungen eines *Reasoners*
 - 6.10.3. Wissensbasierte Systeme
 - 6.10.4. MYCIN, Geschichte der Expertensysteme
 - 6.10.5. Elemente und Architektur von Expertensystemen
 - 6.10.6. Erstellung von Expertensystemen

Modul 7. Maschinelles Lernen und Data Mining

- 7.1. Einführung in die Prozesse der Wissensentdeckung und in die grundlegenden Konzepte des maschinellen Lernens
 - 7.1.1. Schlüsselkonzepte von Prozessen der Wissensentdeckung
 - 7.1.2. Historische Perspektive der Wissensentdeckungsprozesse
 - 7.1.3. Phasen des Wissensentdeckungsprozesses
 - 7.1.4. Techniken, die bei der Wissensentdeckung eingesetzt werden
 - 7.1.5. Merkmale guter Modelle für maschinelles Lernen
 - 7.1.6. Arten von Informationen zum maschinellen Lernen
 - 7.1.7. Grundlegende Lernkonzepte
 - 7.1.8. Grundlegende Konzepte des unüberwachten Lernens
- 7.2. Datenexploration und Vorverarbeitung
 - 7.2.1. Datenverarbeitung
 - 7.2.2. Datenverarbeitung im Datenanalysefluss
 - 7.2.3. Datentypen
 - 7.2.4. Datenumwandlung
 - 7.2.5. Anzeige und Untersuchung von kontinuierlichen Variablen
 - 7.2.6. Anzeige und Erkundung kategorialer Variablen
 - 7.2.7. Korrelationsmaßnahmen
 - 7.2.8. Die häufigsten grafischen Darstellungen
 - 7.2.9. Einführung in die multivariate Analyse und Dimensionsreduktion
- 7.3. Entscheidungsbaum
 - 7.3.1. ID-Algorithmus
 - 7.3.2. Algorithmus C
 - 7.3.3. Übertraining und Beschneidung
 - 7.3.4. Analyse der Ergebnisse
- 7.4. Bewertung von Klassifikatoren
 - 7.4.1. Konfusionsmatrizen
 - 7.4.2. Numerische Bewertungsmatrizen
 - 7.4.3. Kappa-Statistik
 - 7.4.4. Die ROC-Kurve



- 7.5. Klassifizierungsregeln
 - 7.5.1. Maßnahmen zur Bewertung von Regeln
 - 7.5.2. Einführung in die grafische Darstellung
 - 7.5.3. Sequentieller Überlagerungsalgorithmus
- 7.6. Neuronale Netze
 - 7.6.1. Grundlegende Konzepte
 - 7.6.2. Einfache neuronale Netze
 - 7.6.3. *Backpropagation*-Algorithmus
 - 7.6.4. Einführung in rekurrente neuronale Netze
- 7.7. Bayessche Methoden
 - 7.7.1. Grundlegende Konzepte der Wahrscheinlichkeit
 - 7.7.2. Bayes-Theorem
 - 7.7.3. Naive Bayes
 - 7.7.4. Einführung in Bayessche Netzwerke
- 7.8. Regressions- und kontinuierliche Antwortmodelle
 - 7.8.1. Einfache lineare Regression
 - 7.8.2. Multiple lineare Regression
 - 7.8.3. Logistische Regression
 - 7.8.4. Regressionsbäume
 - 7.8.5. Einführung in *Support Vector Machines* (SVM)
 - 7.8.6. Maße für die Anpassungsgüte
- 7.9. *Clustering*
 - 7.9.1. Grundlegende Konzepte
 - 7.9.2. Hierarchisches *Clustering*
 - 7.9.3. Probabilistische Methoden
 - 7.9.4. EM-Algorithmus
 - 7.9.5. *B-Cubed*-Methode
 - 7.9.6. Implizite Methoden
- 7.10. *Text Mining* und natürliche Sprachverarbeitung (NLP)
 - 7.10.1. Grundlegende Konzepte
 - 7.10.2. Erstellung eines Korpus
 - 7.10.3. Deskriptive Analyse
 - 7.10.4. Einführung in die Stimmungsanalyse

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

- 8.1. Tiefes Lernen
 - 8.1.1. Arten von tiefem Lernen
 - 8.1.2. Anwendungen von tiefem Lernen
 - 8.1.3. Vor- und Nachteile von tiefem Lernen
- 8.2. Operationen
 - 8.2.1. Addition
 - 8.2.2. Produkt
 - 8.2.3. Transfer
- 8.3. Ebenen
 - 8.3.1. Eingangsebene
 - 8.3.2. Ausgeblendete Ebene
 - 8.3.3. Ausgangsebene
- 8.4. Schichtenverbund und Operationen
 - 8.4.1. Design-Architekturen
 - 8.4.2. Verbindung zwischen Ebenen
 - 8.4.3. Vorwärtsausbreitung
- 8.5. Aufbau des ersten neuronalen Netzes
 - 8.5.1. Entwurf des Netzes
 - 8.5.2. Festlegen der Gewichte
 - 8.5.3. Training des Netzes
- 8.6. Trainer und Optimierer
 - 8.6.1. Auswahl des Optimierers
 - 8.6.2. Festlegen einer Verlustfunktion
 - 8.6.3. Festlegung einer Metrik
- 8.7. Anwendung der Prinzipien des neuronalen Netzes
 - 8.7.1. Aktivierungsfunktionen
 - 8.7.2. Rückwärtsausbreitung
 - 8.7.3. Einstellung der Parameter
- 8.8. Von biologischen zu künstlichen Neuronen
 - 8.8.1. Funktionsweise eines biologischen Neurons
 - 8.8.2. Wissensübertragung auf künstliche Neuronen
 - 8.8.3. Herstellung von Beziehungen zwischen den beiden

- 8.9. Implementierung von MLP (Multilayer Perceptron) mit Keras
 - 8.9.1. Definition der Netzstruktur
 - 8.9.2. Modell-Kompilierung
 - 8.9.3. Modell-Training
- 8.10. *Fine Tuning* der Hyperparameter von neuronalen Netzen
 - 8.10.1. Auswahl der Aktivierungsfunktion
 - 8.10.2. Einstellung der *Learning Rate*
 - 8.10.3. Einstellung der Gewichte

Modul 9. Training Tiefer Neuronaler Netze

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

- 9.7. *Transfer Learning*
 - 9.7.1. *Transfer Learning Training*
 - 9.7.2. Merkmalsextraktion
 - 9.7.3. Tiefes Lernen
- 9.8. *Data Augmentation*
 - 9.8.1. Bildtransformationen
 - 9.8.2. Generierung synthetischer Daten
 - 9.8.3. Textumwandlung
- 9.9. Praktische Anwendung von *Transfer Learning*
 - 9.9.1. *Transfer Learning Training*
 - 9.9.2. Merkmalsextraktion
 - 9.9.3. Tiefes Lernen
- 9.10. Regulierung
 - 9.10.1. L und L
 - 9.10.2. Maximale Entropie-Regularisierung
 - 9.10.3. *Dropout*

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

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

- 10.5. Laden und Vorverarbeiten von Daten mit *TensorFlow*
 - 10.5.1. Laden von Datensätzen mit *TensorFlow*
 - 10.5.2. Vorverarbeiten von Daten mit *TensorFlow*
 - 10.5.3. Verwendung von *TensorFlow*-Tools zur Datenmanipulation
- 10.6. Die *tfdata*-API
 - 10.6.1. Verwendung der *tfdata*-API für die Datenverarbeitung
 - 10.6.2. Konstruktion von Datenströmen mit *tfdata*
 - 10.6.3. Verwendung der *tfdata*-API für das Modelltraining
- 10.7. Das *TFRecord*-Format
 - 10.7.1. Verwendung der *TFRecord*-API für die Datenserialisierung
 - 10.7.2. Laden von *TFRecord*-Dateien mit *TensorFlow*
 - 10.7.3. Verwendung von *TFRecord*-Dateien für das Modelltraining
- 10.8. Keras Vorverarbeitungsschichten
 - 10.8.1. Verwendung der Keras-API für die Vorverarbeitung
 - 10.8.2. Aufbau von Keras-Vorverarbeitungs-Pipelines
 - 10.8.3. Verwendung der Keras Vorverarbeitungs-API für das Modelltraining
- 10.9. Das Projekt *TensorFlow Datasets*
 - 10.9.1. Verwendung von *TensorFlow Datasets* zum Laden von Daten
 - 10.9.2. Vorverarbeitung von Daten mit *TensorFlow Datasets*
 - 10.9.3. Verwendung von *TensorFlow Datasets* für das Modelltraining
- 10.10. Erstellen einer *Deep-Learning*-Anwendung mit *TensorFlow*
 - 10.10.1. Praktische Anwendung
 - 10.10.2. Erstellen einer *Deep-Learning*-Anwendung mit *TensorFlow*
 - 10.10.3. Trainieren eines Modells mit *TensorFlow*
 - 10.10.4. Verwendung der Anwendung für die Vorhersage von Ergebnissen

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

- 11.1. Die *Visual-Cortex*-Architektur
 - 11.1.1. Funktionen des visuellen Kortex
 - 11.1.2. Theorien des rechnergestützten Sehens
 - 11.1.3. Modelle der Bildverarbeitung
- 11.2. Faltungsschichten
 - 11.2.1. Wiederverwendung von Gewichten bei der Faltung
 - 11.2.2. Faltung D
 - 11.2.3. Aktivierungsfunktionen



- 11.3. Gruppierungsschichten und Implementierung von Gruppierungsschichten mit Keras
 - 11.3.1. *Pooling* und *Striding*
 - 11.3.2. *Flattening*
 - 11.3.3. Arten des *Pooling*
- 11.4. CNN-Architektur
 - 11.4.1. VGG-Architektur
 - 11.4.2. *AlexNet*-Architektur
 - 11.4.3. *ResNet*-Architektur
- 11.5. Implementierung eines *ResNet*- CNN mit Keras
 - 11.5.1. Initialisierung der Gewichte
 - 11.5.2. Definition der Eingabeschicht
 - 11.5.3. Definition der Ausgabe
- 11.6. Verwendung von vortrainierten Keras-Modellen
 - 11.6.1. Merkmale der vortrainierten Modelle
 - 11.6.2. Verwendung von vortrainierten Modellen
 - 11.6.3. Vorteile von vortrainierten Modellen
- 11.7. Vortrainierte Modelle für das Transferlernen
 - 11.7.1. Transferlernen
 - 11.7.2. Prozess des Transferlernens
 - 11.7.3. Vorteile des Transferlernens
- 11.8. Klassifizierung und Lokalisierung in *Deep Computer Vision*
 - 11.8.1. Klassifizierung von Bildern
 - 11.8.2. Objekte in Bildern lokalisieren
 - 11.8.3. Objekterkennung
- 11.9. Objekterkennung und Objektverfolgung
 - 11.9.1. Methoden zur Objekterkennung
 - 11.9.2. Algorithmen zur Objektverfolgung
 - 11.9.3. Verfolgungs- und Lokalisierungstechniken
- 11.10. Semantische Segmentierung
 - 11.10.1. *Deep Learning* für semantische Segmentierung
 - 11.10.2. Kantenerkennung
 - 11.10.3. Regelbasierte Segmentierungsmethoden

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

- 12.1. Textgenerierung mit RNN
 - 12.1.1. Training eines RNN für die Texterzeugung
 - 12.1.2. Generierung natürlicher Sprache mit RNN
 - 12.1.3. Anwendungen zur Texterzeugung mit RNN
- 12.2. Erstellung von Trainingsdatensätzen
 - 12.2.1. Vorbereitung der Daten für das RNN-Training
 - 12.2.2. Speicherung des Trainingsdatensatzes
 - 12.2.3. Bereinigung und Transformation der Daten
 - 12.2.4. Sentiment-Analyse
- 12.3. Ranking von Meinungen mit RNN
 - 12.3.1. Erkennung von Themen in Kommentaren
 - 12.3.2. Stimmungsanalyse mit *Deep-Learning*-Algorithmen
- 12.4. *Encoder-Decoder*-Netz für neuronale maschinelle Übersetzung
 - 12.4.1. Training eines RNN für maschinelle Übersetzung
 - 12.4.2. Verwendung eines *Encoder-Decoder*-Netzwerks für die maschinelle Übersetzung
 - 12.4.3. Verbesserung der Genauigkeit der maschinellen Übersetzung mit RNNs
- 12.5. Aufmerksamkeitsmechanismen
 - 12.5.1. Implementierung von Aufmerksamkeitsmechanismen in RNN
 - 12.5.2. Verwendung von Betreuungsmechanismen zur Verbesserung der Modellgenauigkeit
 - 12.5.3. Vorteile von Betreuungsmechanismen in neuronalen Netzen
- 12.6. *Transformer*-Modelle
 - 12.6.1. Verwendung von *Transformer*-Modellen für die Verarbeitung natürlicher Sprache
 - 12.6.2. Anwendung von *Transformer*-Modellen für die Sicht
 - 12.6.3. Vorteile von *Transformer*-Modellen
- 12.7. *Transformers* für die Sicht
 - 12.7.1. Verwendung von *Transformer* für die Sicht
 - 12.7.2. Vorverarbeitung von Bilddaten
 - 12.7.3. Training eines *Transformer*-Modells für die Sicht
- 12.8. *Hugging Face Transformers*-Bibliothek
 - 12.8.1. Verwendung der *Hugging Face Transformers*-Bibliothek
 - 12.8.2. Anwendung der *Hugging Face Transformers*-Bibliothek
 - 12.8.3. Vorteile der *Hugging Face Transformers*-Bibliothek

- 12.9. Andere *Transformer*-Bibliotheken. Vergleich
 - 12.9.1. Vergleich zwischen den verschiedenen *Transformer*-Bibliotheken
 - 12.9.2. Verwendung der anderen *Transformer*-Bibliotheken
 - 12.9.3. Vorteile der anderen *Transformer*-Bibliotheken
- 12.10. Entwicklung einer NLP-Anwendung mit RNN und Aufmerksamkeit. Praktische Anwendung
 - 12.10.1. Entwicklung einer Anwendung zur Verarbeitung natürlicher Sprache mit RNN und Aufmerksamkeit
 - 12.10.2. Verwendung von RNN, Aufmerksamkeitsmechanismen und *Transformers*-Modellen in der Anwendung
 - 12.10.3. Bewertung der praktischen Umsetzung

Modul 13. Autoencoder, GANs und Diffusionsmodelle

- 13.1. Effiziente Datendarstellungen
 - 13.1.1. Reduzierung der Dimensionalität
 - 13.1.2. Tiefes Lernen
 - 13.1.3. Kompakte Repräsentationen
- 13.2. Realisierung von PCA mit einem unvollständigen linearen automatischen Kodierer
 - 13.2.1. Trainingsprozess
 - 13.2.2. Python-Implementierung
 - 13.2.3. Verwendung von Testdaten
- 13.3. Gestapelte automatische Kodierer
 - 13.3.1. Tiefe neuronale Netze
 - 13.3.2. Konstruktion von Kodierungsarchitekturen
 - 13.3.3. Verwendung der Regularisierung
- 13.4. Faltungs-Autokodierer
 - 13.4.1. Entwurf eines Faltungsmodells
 - 13.4.2. Training von Faltungsmodellen
 - 13.4.3. Auswertung der Ergebnisse
- 13.5. Automatische Entrauschung des Encoders
 - 13.5.1. Anwendung von Filtern
 - 13.5.2. Entwurf von Kodierungsmodellen
 - 13.5.3. Anwendung von Regularisierungstechniken
- 13.6. Automatische Verteilkodierer
 - 13.6.1. Steigerung der Kodierungseffizienz
 - 13.6.2. Minimierung der Anzahl von Parametern
 - 13.6.3. Verwendung von Regularisierungstechniken

- 13.7. Automatische Variationskodierer
 - 13.7.1. Verwendung der Variationsoptimierung
 - 13.7.2. Unüberwachtes tiefes Lernen
 - 13.7.3. Tiefe latente Repräsentationen
- 13.8. Modische MNIST-Bilderzeugung
 - 13.8.1. Mustererkennung
 - 13.8.2. Bilderzeugung
 - 13.8.3. Training Tiefer Neuronaler Netze
- 13.9. *Generative Adversarial Networks* und Diffusionsmodelle
 - 13.9.1. Bildbasierte Inhaltsgenerierung
 - 13.9.2. Modellierung von Datenverteilungen
 - 13.9.3. Verwendung von *Adversarial Networks*
- 13.10. Implementierung der Modelle
 - 13.10.1. Praktische Anwendung
 - 13.10.2. Implementierung der Modelle
 - 13.10.3. Verwendung von realen Daten
 - 13.10.4. Auswertung der Ergebnisse

Modul 14. Bio-inspiriertes Computing

- 14.1. Einführung in das bio-inspirierte Computing
 - 14.1.1. Einführung in das bio-inspirierte Computing
- 14.2. Algorithmen zur sozialen Anpassung
 - 14.2.1. Bioinspiriertes Computing auf der Grundlage von Ameisenkolonien
 - 14.2.2. Varianten von Ameisenkolonie-Algorithmen
 - 14.2.3. Cloud-basiertes Computing auf Partikelebene
- 14.3. Genetische Algorithmen
 - 14.3.1. Allgemeine Struktur
 - 14.3.2. Implementierungen der wichtigsten Operatoren
- 14.4. Explorations-Ausbeutungsraum-Strategien für genetische Algorithmen
 - 14.4.1. CHC-Algorithmus
 - 14.4.2. Multimodale Probleme
- 14.5. Evolutionäre Berechnungsmodelle (I)
 - 14.5.1. Evolutionäre Strategien
 - 14.5.2. Evolutionäre Programmierung
 - 14.5.3. Algorithmen auf der Grundlage der differentiellen Evolution

- 14.6. Evolutionäre Berechnungsmodelle (II)
 - 14.6.1. Evolutionäre Modelle auf der Grundlage der Schätzung von Verteilungen (EDA)
 - 14.6.2. Genetische Programmierung
- 14.7. Evolutionäre Programmierung angewandt auf Lernprobleme
 - 14.7.1. Regelbasiertes Lernen
 - 14.7.2. Evolutionäre Methoden bei Instanzauswahlproblemen
- 14.8. Multi-Objektive Probleme
 - 14.8.1. Konzept der Dominanz
 - 14.8.2. Anwendung evolutionärer Algorithmen auf multikriterielle Probleme
- 14.9. Neuronale Netze (I)
 - 14.9.1. Einführung in neuronale Netzwerke
 - 14.9.2. Praktisches Beispiel mit neuronalen Netzwerken
- 14.10. Neuronale Netze
 - 14.10.1. Anwendungsbeispiele für neuronale Netze in der medizinischen Forschung
 - 14.10.2. Anwendungsbeispiele für neuronale Netze in der Wirtschaft
 - 14.10.3. Anwendungsfälle für neuronale Netze in der industriellen Bildverarbeitung

Modul 15. Künstliche Intelligenz: Strategien und Anwendungen

- 15.1. Finanzdienstleistungen
 - 15.1.1. Die Auswirkungen von künstlicher Intelligenz (KI) auf Finanzdienstleistungen. Chancen und Herausforderungen
 - 15.1.2. Anwendungsbeispiele
 - 15.1.3. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.1.4. Mögliche zukünftige Entwicklungen/Nutzungen von KI
- 15.2. Auswirkungen von künstlicher Intelligenz im Gesundheitswesen
 - 15.2.1. Auswirkungen von KI im Gesundheitswesen. Chancen und Herausforderungen
 - 15.2.2. Anwendungsbeispiele
- 15.3. Risiken im Zusammenhang mit dem Einsatz von KI im Gesundheitswesen
 - 15.3.1. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.3.2. Mögliche zukünftige Entwicklungen/Nutzungen von KI

- 15.4. *Retail*
 - 15.4.1. Auswirkungen von KI im *Retail*. Chancen und Herausforderungen
 - 15.4.2. Anwendungsbeispiele
 - 15.4.3. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.4.4. Mögliche zukünftige Entwicklungen/Nutzungen von KI
- 15.5. Industrie
 - 15.5.1. Auswirkungen von KI in der Industrie. Chancen und Herausforderungen
 - 15.5.2. Anwendungsbeispiele
- 15.6. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI in der Industrie
 - 15.6.1. Anwendungsbeispiele
 - 15.6.2. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.6.3. Mögliche zukünftige Entwicklungen/Nutzungen von KI
- 15.7. Öffentliche Verwaltung
 - 15.7.1. Auswirkungen von KI in der Öffentlichen Verwaltung. Chancen und Herausforderungen
 - 15.7.2. Anwendungsbeispiele
 - 15.7.3. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.7.4. Mögliche zukünftige Entwicklungen/Nutzungen von KI
- 15.8. Bildung
 - 15.8.1. Auswirkungen von KI in der Bildung. Chancen und Herausforderungen
 - 15.8.2. Anwendungsbeispiele
 - 15.8.3. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.8.4. Mögliche zukünftige Entwicklungen/Nutzungen von KI
- 15.9. Forst- und Landwirtschaft
 - 15.9.1. Auswirkungen von KI in der Forst- und Landwirtschaft. Chancen und Herausforderungen
 - 15.9.2. Anwendungsbeispiele
 - 15.9.3. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.9.4. Mögliche zukünftige Entwicklungen/Nutzungen von KI
- 15.10. Personalwesen
 - 15.10.1. Auswirkungen von KI im Personalwesen. Chancen und Herausforderungen
 - 15.10.2. Anwendungsbeispiele
 - 15.10.3. Potenzielle Risiken im Zusammenhang mit dem Einsatz von KI
 - 15.10.4. Mögliche zukünftige Entwicklungen/Nutzungen von KI

Modul 16. Innovationen der künstlichen Intelligenz in der diagnostischen Bildgebung

- 16.1. Technologien und Werkzeuge der künstlichen Intelligenz in der diagnostischen Bildgebung mit IBM Watson Imaging Clinical Review
 - 16.1.1. Führende Software-Plattformen für die medizinische Bildanalyse
 - 16.1.2. Radiologie-spezifische Deep Learning Tools
 - 16.1.3. Innovationen bei der Hardware zur Beschleunigung der Bildverarbeitung
 - 16.1.4. Integration von System der künstlichen Intelligenz in bestehende Krankenhausinfrastrukturen
- 16.2. Statistische Methoden und Algorithmen zur medizinischen Bildinterpretation mit DeepMind AI for Breast Cancer Analysis
 - 16.2.1. Algorithmen zur Bildsegmentierung
 - 16.2.2. Klassifizierungs- und Erkennungstechniken in medizinischen Bildern
 - 16.2.3. Verwendung von *Convolutional Neural Networks* in der Radiologie
 - 16.2.4. Methoden zur Rauschunterdrückung und Verbesserung der Bildqualität
- 16.3. Planung von Experimenten und Analyse der Ergebnisse in der diagnostischen Bildgebung mit Google Cloud Healthcare API
 - 16.3.1. Entwurf von Validierungsprotokollen für Algorithmen der künstlichen Intelligenz
 - 16.3.2. Statistische Methoden zum Vergleich der Leistungen von künstlicher Intelligenz und Radiologen
 - 16.3.3. Einrichtung von multizentrischen Studien zum Testen von künstlicher Intelligenz
 - 16.3.4. Interpretation und Präsentation der Ergebnisse von Leistungstests
- 16.4. Erkennung subtiler Muster in niedrig aufgelösten Bildern
 - 16.4.1. Künstliche Intelligenz für die Frühdiagnose von neurodegenerativen Erkrankungen
 - 16.4.2. Anwendungen der künstlichen Intelligenz in der interventionellen Kardiologie
 - 16.4.3. Einsatz von künstlicher Intelligenz zur Optimierung von Bildgebungsprotokollen
- 16.5. Biomedizinische Bildanalyse und -verarbeitung
 - 16.5.1. Vorverarbeitende Techniken zur Verbesserung der automatischen Interpretation
 - 16.5.2. Textur- und Musteranalyse von histologischen Bildern
 - 16.5.3. Extraktion von klinischen Merkmalen aus Ultraschallbildern
 - 16.5.4. Methoden zur Längsschnittanalyse von Bildern in klinischen Studien
- 16.6. Erweiterte Datenvisualisierung in der diagnostischen Bildgebung mit OsiriX MD
 - 16.6.1. Entwicklung von grafischen Schnittstellen für die 3D-Bilderkundung
 - 16.6.2. Werkzeuge zur Visualisierung zeitlicher Veränderungen in medizinischen Bildern
 - 16.6.3. Techniken der erweiterten Realität für den Anatomieunterricht
 - 16.6.4. Echtzeit-Visualisierungssysteme für chirurgische Eingriffe
- 16.7. Natürliche Sprachverarbeitung in der medizinischen Bilddokumentation und Berichterstattung mit Nuance PowerScribe 360
 - 16.7.1. Automatische Erstellung von radiologischen Berichten
 - 16.7.2. Extraktion relevanter Informationen aus elektronischen Krankenakten
 - 16.7.3. Semantische Analyse zur Korrelation von bildgebenden und klinischen Befunden
 - 16.7.4. Tools für die Bildsuche und das Abrufen von Bildern auf der Grundlage textueller Beschreibungen
- 16.8. Integration und Verarbeitung von heterogenen Daten in der medizinischen Bildgebung
 - 16.8.1. Fusionen von Bildgebungsmodalitäten für eine vollständige Diagnose
 - 16.8.2. Integration von Labor- und genetischen Daten in die Bildanalyse
 - 16.8.3. Systeme für die Verarbeitung großer Mengen von Bilddaten
 - 16.8.4. Strategien zur Normalisierung von *Datasets* aus verschiedenen Quellen
- 16.9. Anwendungen von neuronalen Netzen in der medizinischen Bildinterpretation mit Zebra Medical Vision
 - 16.9.1. Verwendung von generativen Netzen für die Erstellung synthetischer medizinischer Bilder
 - 16.9.2. Neuronale Netze für die automatische Tumorklassifizierung
 - 16.9.3. *Deep Learning* für die Zeitreihenanalyse in der funktionellen Bildgebung
 - 16.9.4. Anpassung von vortrainierten Modellen an spezifische *Datasets* für medizinische Bilder
- 16.10. Prädiktive Modellierung und ihre Auswirkungen auf die diagnostische Bildgebung mit IBM Watson Oncology
 - 16.10.1. Prädiktive Modelle für die Risikobewertung bei onkologischen Patienten
 - 16.10.2. Prädiktive Tools für die Überwachung chronischer Krankheiten
 - 16.10.3. Überlebensanalyse anhand medizinischer Bildgebungsdaten
 - 16.10.4. Vorhersage des Krankheitsverlaufs mit Techniken des *Machine Learning*



Modul 17. Fortgeschrittene KI-Anwendungen in Studien und Analysen von medizinischen Bildern

- 17.1. Entwurf und Durchführung von Beobachtungsstudien mit künstlicher Intelligenz in der medizinischen Bildgebung mit Flatiron Health
 - 17.1.1. Kriterien für die Auswahl der Population in KI-Beobachtungsstudien
 - 17.1.2. Methoden für die Kontrolle von Störvariablen in bildgebenden Studien
 - 17.1.3. Strategien für die langfristige Nachverfolgung in Beobachtungsstudien
 - 17.1.4. Ergebnisanalyse und Validierung von Modellen der künstlichen Intelligenz in realen klinischen Kontexten
- 17.2. Validierung und Kalibrierung von KI-Modellen bei der Bildinterpretation mit Arterys Cardio AI
 - 17.2.1. Kreuzvalidierungstechniken angewandt auf Modelle der diagnostischen Bildgebung
 - 17.2.2. Methoden zur Kalibrierung von Wahrscheinlichkeiten in KI-Vorhersagen
 - 17.2.3. Leistungsstandards und Genauigkeitsmetriken für die KI-Bewertung
 - 17.2.4. Implementierung von Robustheitstests in verschiedenen Populationen und unter verschiedenen Bedingungen
- 17.3. Methoden zur Integration von Bildgebungsdaten mit anderen biomedizinischen Quellen
 - 17.3.1. Datenfusionstechniken zur Verbesserung der Bildinterpretation
 - 17.3.2. Gemeinsame Analyse von Bild- und genomischen Daten für eine genaue Diagnose
 - 17.3.3. Integration von klinischen und Laborinformationen in Systeme der künstlichen Intelligenz
 - 17.3.4. Entwicklung von Benutzeroberflächen zur integrierten Visualisierung multidisziplinärer Daten
- 17.4. Nutzung von medizinischen Bildgebungsdaten in der multidisziplinären Forschung mit Enlitic Curie
 - 17.4.1. Interdisziplinäre Zusammenarbeit für fortgeschrittene Bildanalyse
 - 17.4.2. Anwendung von Techniken der künstlichen Intelligenz aus anderen Bereichen in der diagnostischen Bildgebung
 - 17.4.3. Herausforderungen und Lösungen bei der Verwaltung von großen und heterogenen Daten
 - 17.4.4. Fallstudien über erfolgreiche multidisziplinäre Anwendungen
- 17.5. *Deep-Learning*-Algorithmen speziell für die medizinische Bildgebung mit Aidoc
 - 17.5.1. Entwicklung von bildspezifischen neuronalen Netzwerkarchitekturen
 - 17.5.2. Hyperparameter-Optimierung für medizinische Bildgebungsmodelle
 - 17.5.3. Transfer des Lernens und seine Anwendbarkeit in der Radiologie

- 17.6. Herausforderungen bei der Interpretation und Visualisierung von Merkmalen, die von tiefen Modellen gelernt wurden
 - 17.6.1. Optimierung der medizinischen Bildinterpretation durch Automatisierung mit Viz.ai
 - 17.6.2. Automatisierung von Diagnoseroutinen für operative Effizienz
 - 17.6.3. Frühwarnsysteme für die Erkennung von Anomalien
 - 17.6.4. Verringerung der Arbeitsbelastung von Radiologen durch Werkzeuge der künstlichen Intelligenz
 - 17.6.5. Auswirkungen der Automatisierung auf die Genauigkeit und Geschwindigkeit von Diagnosen
- 17.7. Simulation und computergestützte Modellierung in der diagnostischen Bildgebung
 - 17.7.1. Simulationen zum Training und zur Validierung von Algorithmen der künstlichen Intelligenz
 - 17.7.2. Modellierung von Krankheiten und deren Darstellung in synthetischen Bildern
 - 17.7.3. Verwendung von Simulationen für die Planung von Behandlungen und Operationen
 - 17.7.4. Fortschritte bei den Rechentechniken für die Echtzeit-Bildverarbeitung
- 17.8. Virtuelle und erweiterte Realität in der medizinischen Bildvisualisierung und -analyse
 - 17.8.1. Anwendungen der virtuellen Realität für die Ausbildung in der diagnostischen Bildgebung
 - 17.8.2. Einsatz von erweiterter Realität bei bildgesteuerten chirurgischen Eingriffen
 - 17.8.3. Fortgeschrittene Visualisierungstools für die Therapieplanung
 - 17.8.4. Entwicklung von immersiven Schnittstellen für die Überprüfung radiologischer Studien
- 17.9. *Data-Mining*-Tools für die diagnostische Bildgebung mit Radiomics
 - 17.9.1. *Data-Mining*-Techniken für große medizinische Bilddatenbanken
 - 17.9.2. Anwendungen der Musteranalyse in Bilddatensammlungen
 - 17.9.3. Biomarker-Identifizierung durch *Image Data Mining*
 - 17.9.4. Integration von Data Mining und maschinellem Lernen für klinische Entdeckungen
- 17.10. Entwicklung und Validierung von Biomarkern durch Bildanalyse mit Oncimmune
 - 17.10.1. Strategien zur Identifizierung von bildgebenden Biomarkern bei verschiedenen Krankheiten
 - 17.10.2. Klinische Validierung von Bildgebungs-Biomarkern für die Diagnose
 - 17.10.3. Auswirkungen von bildgebenden Biomarkern auf die Personalisierung der Behandlung
 - 17.10.4. Aufstrebende Technologien bei der Erkennung und Analyse von Biomarkern mit Hilfe von künstlicher Intelligenz

Modul 18. Personalisierung und Automatisierung in der medizinischen Diagnostik durch künstliche Intelligenz

- 18.1. Anwendung von künstlicher Intelligenz in der genomischen Sequenzierung und Korrelation mit bildgebenden Befunden mit Fabric Genomics
 - 18.1.1. Techniken der Künstlichen Intelligenz für die Integration von genomischen und bildgebenden Daten
 - 18.1.2. Vorhersagemodelle für die Korrelation von genetischen Varianten mit auf Bildern sichtbaren Pathologien
 - 18.1.3. Entwicklung von Algorithmen für die automatische Analyse von Sequenzen und deren Darstellung in Bildern
 - 18.1.4. Fallstudien zu den klinischen Auswirkungen der Verschmelzung von Genomik und Bildgebung
- 18.2. Fortschritte in der künstlichen Intelligenz für die detaillierte Analyse biomedizinischer Bilder mit PathAI
 - 18.2.1. Innovationen bei Bildverarbeitungs- und Analysetechniken auf zellulärer Ebene
 - 18.2.2. Anwendung von künstlicher Intelligenz zur Verbesserung der Auflösung von Mikroskopiebildern
 - 18.2.3. *Deep-Learning*-Algorithmen, die auf die Erkennung von submikroskopischen Mustern spezialisiert sind
 - 18.2.4. Auswirkungen von Fortschritten in der künstlichen Intelligenz auf die biomedizinische Forschung und klinische Diagnose
- 18.3. Automatisierung der medizinischen Bilderfassung und -verarbeitung mit Butterfly Network
 - 18.3.1. Automatisierte Systeme zur Optimierung der Bildaufnahmeparameter
 - 18.3.2. Künstliche Intelligenz bei der Verwaltung und Wartung von Bildgebungsgeräten
 - 18.3.3. Algorithmen für die Echtzeitverarbeitung von Bildern während medizinischer Verfahren
 - 18.3.4. Erfolgreiche Fälle bei der Implementierung von automatisierten Systemen in Krankenhäusern und Kliniken
- 18.4. Personalisierung von Diagnosen durch künstliche Intelligenz und Präzisionsmedizin mit Tempus AI
 - 18.4.1. Modelle der Künstlichen Intelligenz für personalisierte Diagnosen auf der Grundlage von genetischen und bildgebenden Profilen
 - 18.4.2. Strategien für die Integration von klinischen und bildgebenden Daten in die Therapieplanung
 - 18.4.3. Auswirkungen der Präzisionsmedizin auf die klinischen Ergebnisse durch KI
 - 18.4.4. Ethische und praktische Herausforderungen bei der Umsetzung der personalisierten Medizin

- 18.5. Innovationen in der KI-unterstützten Diagnostik mit Caption Health
 - 18.5.1. Entwicklung neuer Werkzeuge der künstlichen Intelligenz für die Früherkennung von Krankheiten
 - 18.5.2. Fortschritte bei Algorithmen der künstlichen Intelligenz für die Interpretation von komplexen Pathologien
 - 18.5.3. Integration von KI-gestützter Diagnostik in die klinische Routinepraxis
 - 18.5.4. Bewertung der Wirksamkeit und Akzeptanz der KI-Diagnostik durch Gesundheitsfachkräfte
- 18.6. Anwendungen der künstlichen Intelligenz in der Mikrobiom-Bildanalyse mit DayTwo AI
 - 18.6.1. Techniken der künstlichen Intelligenz für die Bildanalyse in Mikrobiomstudien
 - 18.6.2. Korrelation von Mikrobiom-Bilddaten mit Gesundheitsindikatoren
 - 18.6.3. Auswirkungen von Mikrobiom-Befunden auf therapeutische Entscheidungen
 - 18.6.4. Herausforderungen bei der Standardisierung und Validierung der Mikrobiom-Bildgebung
- 18.7. Verwendung von *Wearables* zur Verbesserung der Interpretation von diagnostischen Bildern mit AliveCor
 - 18.7.1. Integration von *Wearable*-Daten mit medizinischen Bildern für eine vollständige Diagnose
 - 18.7.2. KI-Algorithmen für die kontinuierliche Datenanalyse und Darstellung in Bildern
 - 18.7.3. Technologische Innovationen bei *Wearables* für die Gesundheitsüberwachung
 - 18.7.4. Fallstudien zur Verbesserung der Lebensqualität durch *Wearables* und bildgebende Diagnostik
- 18.8. Verwaltung von diagnostischen Bildgebungsdaten in klinischen Studien mit Hilfe von künstlicher Intelligenz
 - 18.8.1. KI-Tools für die effiziente Verwaltung großer Mengen von bildgebenden Daten
 - 18.8.2. Strategien zur Sicherstellung der Datenqualität und -integrität in multizentrischen Studien
 - 18.8.3. Anwendungen der künstlichen Intelligenz für prädiktive Analysen in klinischen Studien
 - 18.8.4. Herausforderungen und Möglichkeiten bei der Standardisierung von Bildgebungsprotokollen in globalen Studien
- 18.9. Entwicklung von Behandlungen und Impfstoffen mit Hilfe fortschrittlicher KI-Diagnostik
 - 18.9.1. Einsatz von künstlicher Intelligenz für die Entwicklung personalisierter Behandlungen auf der Grundlage von Bildgebungs- und klinischen Daten
 - 18.9.2. Modelle der künstlichen Intelligenz für die beschleunigte Entwicklung von Impfstoffen mit Hilfe der diagnostischen Bildgebung
 - 18.9.3. Bewertung der Wirksamkeit von Behandlungen durch Bildüberwachung
 - 18.9.4. Auswirkungen von künstlicher Intelligenz auf Zeit- und Kosteneinsparungen bei der Entwicklung neuer Therapien

- 18.10. KI-Anwendungen in der Immunologie und Studien zur Immunantwort mit ImmunoMind
 - 18.10.1. KI-Modelle für die Interpretation von Bildern im Zusammenhang mit der Immunantwort
 - 18.10.2. Integration von bildgebenden und immunologischen Analysedaten für eine genaue Diagnose
 - 18.10.3. Entwicklung von bildgebenden Biomarkern für Autoimmunkrankheiten
 - 18.10.4. Fortschritte bei der Personalisierung von immunologischen Behandlungen durch den Einsatz von künstlicher Intelligenz

Modul 19. *Big Data* und prädiktive Analytik in der medizinischen Bildgebung

- 19.1. *Big Data* in der diagnostischen Bildgebung: Konzepte und Tools mit GE Healthcare Edison
 - 19.1.1. Grundlagen von *Big Data* in der Bildgebung
 - 19.1.2. Technologische Tools und Plattformen für die Verarbeitung großer Mengen von Bilddaten
 - 19.1.3. Herausforderungen bei der Integration und Analyse von *Big Data* in der Bildgebung
 - 19.1.4. Anwendungsfälle von *Big Data* in der diagnostischen Bildgebung
- 19.2. *Data Mining* in biomedizinischen Bildgebungsdaten mit IBM Watson Imaging
 - 19.2.1. Fortgeschrittene *Data-Mining*-Techniken zur Identifizierung von Mustern in medizinischen Bildern
 - 19.2.2. Strategien für die Extraktion von relevanten Merkmalen in großen Bilddatenbanken
 - 19.2.3. Anwendungen von *Clustering* und Klassifizierungstechniken in Bilddatenbanken
 - 19.2.4. Auswirkungen von *Data Mining* auf die Verbesserung von Diagnose und Behandlung
- 19.3. Algorithmen des maschinellen Lernens in der Bildanalyse mit Google DeepMind Health
 - 19.3.1. Entwicklung von überwachten und unüberwachten Algorithmen für die medizinische Bildgebung
 - 19.3.2. Innovationen bei maschinellen Lerntechniken für die Erkennung von Krankheitsbildern
 - 19.3.3. *Deep Learning*-Anwendungen in der Bildsegmentierung und -klassifizierung
 - 19.3.4. Bewertung der Wirksamkeit und Genauigkeit von Algorithmen des maschinellen Lernens in klinischen Studien

- 19.4. Prädiktive Analysetechniken angewandt auf die diagnostische Bildgebung mit Predictive Oncology
 - 19.4.1. Vorhersagemodelle für die Früherkennung von Krankheiten anhand von Bildern
 - 19.4.2. Einsatz von prädiktiver Analytik für die Überwachung und Bewertung von Behandlungen
 - 19.4.3. Integration von klinischen und bildgebenden Daten zur Anreicherung prädiktiver Modelle
 - 19.4.4. Herausforderungen bei der Implementierung von prädiktiven Techniken in der klinischen Praxis
- 19.5. Bildbasierte Modelle der künstlichen Intelligenz für die Epidemiologie mit BlueDot
 - 19.5.1. Anwendung der künstlichen Intelligenz bei der Analyse von Epidemieausbrüchen anhand von Bildern
 - 19.5.2. Modelle der Krankheitsausbreitung, visualisiert durch bildgebende Verfahren
 - 19.5.3. Korrelation zwischen epidemiologischen Daten und bildgebenden Befunden
 - 19.5.4. Beitrag der künstlichen Intelligenz zur Untersuchung und Kontrolle von Pandemien
- 19.6. Analyse von biologischen Netzwerken und Krankheitsmustern anhand von Bildern
 - 19.6.1. Anwendung der Netzwerktheorie in der Bildanalyse zum Verständnis von Pathologien
 - 19.6.2. Computermodelle zur Simulation von in Bildern sichtbaren biologischen Netzwerken
 - 19.6.3. Integration von Bildanalyse und molekularen Daten zur Kartierung von Krankheiten
 - 19.6.4. Auswirkungen dieser Analysen auf die Entwicklung von personalisierten Therapien
- 19.7. Entwicklung von bildbasierten Tools für die klinische Prognostik
 - 19.7.1. Werkzeuge der künstlichen Intelligenz für die Vorhersage der klinischen Entwicklung auf der Grundlage von diagnostischen Bildern
 - 19.7.2. Fortschritte bei der automatischen Erstellung prognostischer Berichte
 - 19.7.3. Integration von Prognosemodellen in klinische Systeme
 - 19.7.4. Validierung und klinische Akzeptanz von KI-basierten Prognosetools
- 19.8. Fortgeschrittene Visualisierung und Kommunikation von komplexen Daten mit Tableau
 - 19.8.1. Visualisierungstechniken für die multidimensionale Darstellung von Bilddaten
 - 19.8.2. Interaktive Tools zur Erkundung großer Bilddatensätze
 - 19.8.3. Strategien zur effektiven Kommunikation komplexer Erkenntnisse durch Visualisierungen
 - 19.8.4. Auswirkungen fortschrittlicher Visualisierung auf die medizinische Ausbildung und Entscheidungsfindung

- 19.9. Datensicherheit und Herausforderungen bei der Verwaltung von *Big Data*
 - 19.9.1. Sicherheitsmaßnahmen zum Schutz großer Mengen an medizinischen Bilddaten
 - 19.9.2. Datenschutz und ethische Herausforderungen bei der Verwaltung umfangreicher Bilddaten
 - 19.9.3. Technologische Lösungen für die sichere Verwaltung von *Big Data* im Gesundheitswesen
 - 19.9.4. Fallstudien zu Sicherheitsverstößen und deren Behebung
- 19.10. Praktische Anwendungen und Fallstudien im Bereich biomedizinischer *Big Data*
 - 19.10.1. Beispiele für erfolgreiche Anwendungen von *Big Data* bei der Diagnose und Behandlung von Krankheiten
 - 19.10.2. Fallstudien über die Integration von *Big Data* in Gesundheitssystemen
 - 19.10.3. *Lessons Learned* aus *Big-Data*-Projekten im biomedizinischen Bereich
 - 19.10.4. Zukünftige Richtungen und Potenziale von *Big Data* in der Medizin

Modul 20. Ethische und rechtliche Aspekte der künstlichen Intelligenz in der diagnostischen Bildgebung

- 20.1. Ethik in der Anwendung von künstlicher Intelligenz in der diagnostischen Bildgebung mit *Ethics and Algorithms Toolkit*
 - 20.1.1. Grundlegende ethische Prinzipien bei der Anwendung von künstlicher Intelligenz für die Diagnose
 - 20.1.2. Umgang mit algorithmischen Verzerrungen und deren Auswirkungen auf die diagnostische Fairness
 - 20.1.3. Informierte Zustimmung im Zeitalter der diagnostischen künstlichen Intelligenz
 - 20.1.4. Ethische Herausforderungen bei der internationalen Implementierung von Technologien der künstlichen Intelligenz
- 20.2. Rechtliche und regulatorische Überlegungen bei der Anwendung von künstlicher Intelligenz in der medizinischen Bildgebung mit *Compliance.ai*
 - 20.2.1. Aktueller rechtlicher Rahmen für künstliche Intelligenz in der diagnostischen Bildgebung
 - 20.2.2. Einhaltung von Vorschriften zum Schutz der Privatsphäre und des Datenschutzes
 - 20.2.3. Validierungs- und Zertifizierungsanforderungen für Algorithmen der künstlichen Intelligenz im Gesundheitswesen
 - 20.2.4. Rechtliche Haftung im Falle von Fehlern bei der Diagnose durch künstliche Intelligenz



- 20.3. Informierte Zustimmung und ethische Fragen bei der Nutzung klinischer Daten
 - 20.3.1. Überprüfung von Verfahren zur informierten Zustimmung, die an künstliche Intelligenz angepasst sind
 - 20.3.2. Patientenaufklärung über den Einsatz von künstlicher Intelligenz in der Patientenversorgung
 - 20.3.3. Transparenz bei der Verwendung von klinischen Daten für das Training von KI
 - 20.3.4. Respekt vor der Patientenautonomie bei KI-basierten Entscheidungen
- 20.4. Künstliche Intelligenz und Haftung in der klinischen Forschung
 - 20.4.1. Zuweisung von Verantwortlichkeiten der Anwendung von künstlicher Intelligenz für die Diagnose
 - 20.4.2. Auswirkungen von Fehlern der künstlichen Intelligenz in der klinischen Praxis
 - 20.4.3. Versicherung und Deckung von Risiken im Zusammenhang mit dem Einsatz von künstlicher Intelligenz
 - 20.4.4. Strategien für das Management von KI-bezogenen Vorfällen
- 20.5. Auswirkungen von künstlicher Intelligenz auf die Gerechtigkeit und den Zugang zur Gesundheitsversorgung mit AI for Good
 - 20.5.1. Bewertung der Auswirkungen von künstlicher Intelligenz auf die Verteilung von medizinischen Leistungen
 - 20.5.2. Strategien zur Gewährleistung eines gerechten Zugangs zur Technologie der künstlichen Intelligenz
 - 20.5.3. Künstliche Intelligenz als Instrument zum Abbau gesundheitlicher Ungleichheiten
 - 20.5.4. Fallstudien über die Implementierung von künstlicher Intelligenz in ressourcenbeschränkten Umgebungen
- 20.6. Privatsphäre und Datenschutz in Forschungsprojekten mit Duality SecurePlus
 - 20.6.1. Strategien zur Gewährleistung der Vertraulichkeit von Daten in Projekten der künstlichen Intelligenz
 - 20.6.2. Fortgeschrittene Techniken zur Anonymisierung von Patientendaten
 - 20.6.3. Rechtliche und ethische Herausforderungen beim Schutz persönlicher Daten
 - 20.6.4. Auswirkungen von Sicherheitsverletzungen auf das öffentliche Vertrauen

- 20.7. Künstliche Intelligenz und Nachhaltigkeit in der biomedizinischen Forschung mit Green Algorithm
 - 20.7.1. Einsatz von künstlicher Intelligenz zur Verbesserung von Effizienz und Nachhaltigkeit in der Forschung
 - 20.7.2. Lebenszyklusbewertung von Technologien der künstlichen Intelligenz im Gesundheitswesen
 - 20.7.3. Umweltauswirkungen der Infrastruktur von Technologien der künstlichen Intelligenz
 - 20.7.4. Nachhaltige Praktiken bei der Entwicklung und dem Einsatz von künstlicher Intelligenz
- 20.8. Überprüfung und Erklärbarkeit von Modellen der künstlichen Intelligenz im klinischen Umfeld mit IBM AI Fairness 360
 - 20.8.1. Bedeutung einer regelmäßigen Überprüfung von KI-Algorithmen
 - 20.8.2. Techniken zur Verbesserung der Erklärbarkeit von KI-Modellen
 - 20.8.3. Herausforderungen bei der Kommunikation von KI-basierten Entscheidungen an Patienten und Kliniker
 - 20.8.4. Vorschriften zur Transparenz von Algorithmen der künstlichen Intelligenz im Gesundheitswesen
- 20.9. Innovation und Unternehmertum auf dem Gebiet der klinischen künstlichen Intelligenz mit Hindsight
 - 20.9.1. Chancen für Start-ups im Bereich der Technologien der künstlichen Intelligenz für das Gesundheitswesen
 - 20.9.2. Zusammenarbeit zwischen dem öffentlichen und dem privaten Sektor bei der Entwicklung von künstlicher Intelligenz
 - 20.9.3. Herausforderungen für Unternehmer im regulatorischen Umfeld des Gesundheitswesens
 - 20.9.4. Erfolgsgeschichten und Lehren aus dem Unternehmertum im Bereich der klinischen künstlichen Intelligenz
- 20.10. Ethische Überlegungen in der internationalen Zusammenarbeit in der klinischen Forschung mit Global Alliance for Genomics and Health mit GA4GH
 - 20.10.1. Ethische Koordination in internationalen KI-Projekten
 - 20.10.2. Umgang mit kulturellen und regulatorischen Unterschieden in internationalen Kooperationen
 - 20.10.3. Strategien für eine gerechte Einbeziehung in globale Studien
 - 20.10.4. Herausforderungen und Lösungen beim Datenaustausch



“


Möchten Sie Ihre Sicherheit bei der klinischen Entscheidungsfindung durch den Einsatz von künstlicher Intelligenz erhöhen? Erreichen Sie das mit diesem Universitätsabschluss in weniger als einem Jahr“

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 Diagnostischen Bildgebung 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 Diagnostischen Bildung** 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 Diagnostischen Bildung**

Modalität: **online**

Dauer: **12 Monate**



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

zukunft

gesundheit vertrauen menschen
erziehung information 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
Diagnostischen Bildgebung

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

Privater Masterstudiengang Künstliche Intelligenz in der Diagnostischen Bildgebung

