

Weiterbildender Masterstudiengang Künstliche Intelligenz in der Pharmazie



Weiterbildender Masterstudiengang Künstliche Intelligenz in der Pharmazie

- » Modalität: online
- » Dauer: 12 Monate
- » Qualifizierung: TECH Global University
- » Akkreditierung: 90 ECTS
- » Zeitplan: in Ihrem eigenen Tempo
- » Prüfungen: online

Internetzugang: www.techitute.com/de/pharmazie/weiterbildender-masterstudiengang/weiterbildender-masterstudiengang-kunstliche-intelligenz-pharmazie

Index

01

Präsentation des Programms

Seite 4

02

Warum an der TECH studieren?

Seite 8

03

Lehrplan

Seite 12

04

Lehrziele

Seite 32

05

Karrieremöglichkeiten

Seite 42

06

Studienmethodik

Seite 46

07

Lehrkörper

Seite 56

08

Qualifizierung

Seite 60

01

Präsentation des Programms

Künstliche Intelligenz verändert verschiedene Sektoren, und die Pharmazeutik ist da keine Ausnahme. Einem Bericht der Weltgesundheitsorganisation zufolge kann die Integration von KI in Gesundheitssysteme medizinische Fehler reduzieren und die Effizienz von Arzneimittelbehandlungen erhöhen, wodurch sich die Ergebnisse für die Patienten verbessern. Angesichts der tiefgreifenden Auswirkungen neuer Technologien auf die Gesundheitsversorgung und das Arzneimittelmanagement hat TECH diesen umfassenden Aufbaustudiengang entwickelt, der Fachleuten die Möglichkeit gibt, an der Spitze dieses Wandels zu stehen und sie mit dem Wissen und den Fähigkeiten auszustatten, die sie benötigen, um in einem sich ständig verändernden Sektor eine Führungsrolle zu übernehmen. All dies geschieht zu 100% online und mit einer innovativen Methodik.



“

Dank der hochwertigen Online-Fortbildung werden Sie in der Lage sein, die Art und Weise zu verändern, wie die Herausforderungen im Pharmasektor angegangen werden. Sie werden die Ergebnisse für die Patienten verbessern und das Ressourcenmanagement optimieren!“

Die Bedeutung der künstlichen Intelligenz in der Pharmazie liegt in der Fähigkeit, Prozesse zu optimieren, die Genauigkeit der Entscheidungsfindung zu verbessern und einen stärker personalisierten Ansatz in der Gesundheitsversorgung zu bieten, der sich direkt auf die Lebensqualität der Patienten auswirkt. In diesem Sinne hat sie zur Analyse großer Datenmengen, zur Automatisierung von Routine- und Verwaltungsaufgaben und zu Fortschritten in der Arzneimittelforschung beigetragen.

Dieser Weiterbildende Masterstudiengang in Künstliche Intelligenz in der Pharmazie von TECH bietet eine einzigartige Gelegenheit, sich mit den wichtigsten Aspekten dieses sich ständig weiterentwickelnden Sektors zu befassen. Durch einen umfassenden Ansatz werden Fachleute darauf vorbereitet, die Umsetzung innovativer Technologien im Pharmasektor zu leiten. Sie erhalten ein umfassendes Verständnis dafür, wie KI alles verändert, von der Personalisierung von Behandlungen über die Optimierung von Prozessen bis hin zur Verbesserung der Patientensicherheit. Sie werden auch lernen, wie sie fortschrittliche KI-Tools nutzen können, um große Datenmengen zu verwalten, Wechselwirkungen zwischen Medikamenten zu erkennen, Medikamente zu entwickeln und Verwaltungsprozesse zu automatisieren, um den Patienten einen effizienteren und präziseren Service bieten zu können.

Damit haben die Fachleute nicht nur eine Reihe von begehrten Fähigkeiten erworben, sondern auch einen entscheidenden Schritt in Richtung einer vielversprechenden Zukunft im pharmazeutischen Bereich getan. Gleichzeitig werden sie darauf vorbereitet sein, bei der Integration von künstlicher Intelligenz in der Pharmazie als Agenten des Wandels zu fungieren und die Gesundheitsergebnisse und die Erfahrungen der Patienten durch den Einsatz von Technologie zu verbessern.

TECH hat auch an die Exzellenz und Flexibilität der Studenten gedacht und bietet daher diesen Aufbaustudiengang zu 100% online an, so dass die Fortbildung zu der Zeit und an dem Ort stattfinden kann, der am besten zu ihren täglichen Verpflichtungen passt. Ergänzt wird dies durch die *Relearning*-Methode, die es ermöglicht, die Konzepte auf eine agilere und produktivere Art und Weise zu verinnerlichen, ohne viele Stunden in das Studium investieren zu müssen.

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

- ♦ Die Entwicklung von Fallstudien, die von Experten für künstliche Intelligenz in der Pharmazie vorgestellt werden
- ♦ Der anschauliche, schematische und äußerst praxisnahe Inhalt vermittelt alle für die berufliche Praxis unverzichtbaren Informationen
- ♦ Die praktischen 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 Zugangs zu Inhalten von jedem festen oder tragbaren Gerät mit Internetanschluss



Dank des Relearning-Systems werden Sie in der Lage sein, die akademischen Inhalte auf natürlichere und fortschrittlichere Weise zu meistern, was Sie effizient darauf vorbereitet, Teil der technologischen Revolution im Gesundheitswesen zu sein“

“

Jetzt ist es an der Zeit, den nächsten Schritt zu tun und sich eine herausragende Position in einem der innovativsten und vielversprechendsten Bereiche des Gesundheitswesens zu sichern. Schreiben Sie sich jetzt ein und bilden Sie sich dank des Online-Modus in Ihrem eigenen Tempo weiter!“

Zu den Dozenten des Programms gehören Fachleute aus der Branche, die ihre Erfahrungen in diese Fortbildung einbringen, sowie anerkannte Spezialisten von führenden Gesellschaften und renommierten 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.

Durch das Verständnis von KI in der Pharmazie werden Sie in der Lage sein, Behandlungen zu personalisieren, Prozesse zu optimieren und die pharmazeutische Versorgung zu verbessern. Sie werden Ihre Zukunft mit den besten akademischen Werkzeugen von TECH!

In diesem Weiterbildenden Masterstudiengang werden Sie von renommierten Experten fortgebildet und erhalten Zugang zu aktuellen Inhalten über den Einsatz von KI im Arzneimittelmanagement, in der Arzneimittelentwicklung und mehr.



02

Warum an der TECH studieren?

TECH ist die größte digitale Universität der Welt. Mit einem beeindruckenden Katalog von über 14.000 Hochschulprogrammen, die in 11 Sprachen angeboten werden, ist sie mit einer Vermittlungsquote von 99% führend im Bereich der Beschäftigungsfähigkeit. Darüber hinaus verfügt sie über einen beeindruckenden Lehrkörper mit mehr als 6.000 Professoren von höchstem internationalem Prestige.



“

Studieren Sie an der größten digitalen Universität der Welt und sichern Sie sich Ihren beruflichen Erfolg. Die Zukunft beginnt bei TECH“

Die beste Online-Universität der Welt laut FORBES

Das renommierte, auf Wirtschaft und Finanzen spezialisierte Magazin Forbes hat TECH als „beste Online-Universität der Welt“ ausgezeichnet. Dies wurde kürzlich in einem Artikel in der digitalen Ausgabe des Magazins festgestellt, in dem die Erfolgsgeschichte dieser Einrichtung „dank ihres akademischen Angebots, der Auswahl ihrer Lehrkräfte und einer innovativen Lernmethode, die auf die Ausbildung der Fachkräfte der Zukunft abzielt“, hervorgehoben wird.

Die besten internationalen Top-Lehrkräfte

Der Lehrkörper der TECH besteht aus mehr als 6.000 Professoren von höchstem internationalen Ansehen. Professoren, Forscher und Führungskräfte multinationaler Unternehmen, darunter Isaiah Covington, Leistungstrainer der Boston Celtics, Magda Romanska, leitende Forscherin am Harvard MetaLAB, Ignacio Wistumba, Vorsitzender der Abteilung für translationale Molekularpathologie am MD Anderson Cancer Center, und D.W. Pine, Kreativdirektor des TIME Magazine, um nur einige zu nennen.

Die größte digitale Universität der Welt

TECH ist die weltweit größte digitale Universität. Wir sind die größte Bildungseinrichtung mit dem besten und umfangreichsten digitalen Bildungskatalog, der zu 100% online ist und die meisten Wissensgebiete abdeckt. Wir bieten weltweit die größte Anzahl eigener Abschlüsse sowie offizieller Grund- und Aufbaustudiengänge an. Insgesamt sind wir mit mehr als 14.000 Hochschulabschlüssen in elf verschiedenen Sprachen die größte Bildungseinrichtung der Welt.



Die umfassendsten Lehrpläne in der Universitätslandschaft

TECH bietet die vollständigsten Lehrpläne in der Universitätslandschaft an, mit Lehrplänen, die grundlegende Konzepte und gleichzeitig die wichtigsten wissenschaftlichen Fortschritte in ihren spezifischen wissenschaftlichen Bereichen abdecken. Darüber hinaus werden diese Programme ständig aktualisiert, um den Studenten die akademische Avantgarde und die gefragtesten beruflichen Kompetenzen zu garantieren. Auf diese Weise verschaffen die Abschlüsse der Universität ihren Absolventen einen bedeutenden Vorteil, um ihre Karriere erfolgreich voranzutreiben.

Eine einzigartige Lernmethode

TECH ist die erste Universität, die *Relearning* in allen ihren Studiengängen einsetzt. Es handelt sich um die beste Online-Lernmethodik, die mit internationalen Qualitätszertifikaten renommierter Bildungseinrichtungen ausgezeichnet wurde. Darüber hinaus wird dieses disruptive akademische Modell durch die „Fallmethode“ ergänzt, wodurch eine einzigartige Online-Lehrstrategie entsteht. Es werden auch innovative Lehrmittel eingesetzt, darunter ausführliche Videos, Infografiken und interaktive Zusammenfassungen.

Die offizielle Online-Universität der NBA

TECH ist die offizielle Online-Universität der NBA. Durch eine Vereinbarung mit der größten Basketball-Liga bietet sie ihren Studenten exklusive Universitätsprogramme sowie eine breite Palette von Bildungsressourcen, die sich auf das Geschäft der Liga und andere Bereiche der Sportindustrie konzentrieren. Jedes Programm hat einen einzigartig gestalteten Lehrplan und bietet außergewöhnliche Gastredner: Fachleute mit herausragendem Sporthintergrund, die ihr Fachwissen zu den wichtigsten Themen zur Verfügung stellen.

Führend in Beschäftigungsfähigkeit

TECH ist es gelungen, die führende Universität im Bereich der Beschäftigungsfähigkeit zu werden. 99% der Studenten finden innerhalb eines Jahres nach Abschluss eines Studiengangs der Universität einen Arbeitsplatz in dem von ihnen studierten Fachgebiet. Ähnlich viele erreichen einen unmittelbaren Karriereaufstieg. All dies ist einer Studienmethodik zu verdanken, die ihre Wirksamkeit auf den Erwerb praktischer Fähigkeiten stützt, die für die berufliche Entwicklung absolut notwendig sind.



Google Partner Premier

Der amerikanische Technologieriese hat TECH mit dem Logo Google Partner Premier ausgezeichnet. Diese Auszeichnung, die nur 3% der Unternehmen weltweit erhalten, unterstreicht die effiziente, flexible und angepasste Erfahrung, die diese Universität den Studenten bietet. Die Anerkennung bestätigt nicht nur die maximale Präzision, Leistung und Investition in die digitalen Infrastrukturen der TECH, sondern positioniert diese Universität auch als eines der modernsten Technologieunternehmen der Welt.



Die von ihren Studenten am besten bewertete Universität

Die Studenten haben TECH auf den wichtigsten Bewertungsportalen als die am besten bewertete Universität der Welt eingestuft, mit einer Höchstbewertung von 4,9 von 5 Punkten, die aus mehr als 1.000 Bewertungen hervorgeht. Diese Ergebnisse festigen die Position der TECH als internationale Referenzuniversität und spiegeln die Exzellenz und die positiven Auswirkungen ihres Bildungsmodells wider.



03 Lehrplan

Dieser Studiengang bietet eine fortgeschrittene Fortbildung für Fachleute, die an der Spitze der technologischen Innovation stehen wollen. Während des Programms werden sie entdecken, wie KI-Tools die Pharmazie verändern, von der Personalisierung von Behandlungen bis zur Optimierung von pharmazeutischen Managementprozessen. Der Lehrplan deckt auch Schlüsselbereiche ab, wie den Einsatz von KI bei der Entwicklung von Arzneimitteln, die Automatisierung von Verwaltungsprozessen und die Verbesserung der Sicherheit bei der Abgabe von Arzneimitteln. Auf diese Weise werden sie mit den neuesten Technologien vertraut gemacht, die in der Forschung und Entwicklung des Sektors eingesetzt werden.



“

Sie werden den nächsten Schritt in Ihrer beruflichen Laufbahn machen und die notwendigen Kompetenzen erwerben, um eine Referenz in der Pharmazie der Zukunft zu werden. Machen Sie sich bereit, den Pharmasektor mit KI zu verändern!”

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 Film
 - 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. Mehrlagiges 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 von 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. Sortieren der Blase
 - 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 Maps*

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 (Mehrlagiges Perzeptron) 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 *TensorFlow Datasets*-Projekt
 - 10.9.1. Verwendung von *TensorFlow Datasets* zum Laden von Daten
 - 10.9.2. Vorverarbeitung von Daten mit *TensorFlow Datasets*
 - 10.9.3. Verwendung von *TensorFlow Datasets* für das Modelltraining
- 10.10. Erstellen einer *Deep-Learning*-Anwendung mit *TensorFlow*
 - 10.10.1. Praktische Anwendung
 - 10.10.2. Aufbau einer *Deep-Learning*-Anwendung mit *TensorFlow*
 - 10.10.3. Trainieren eines Modells mit *TensorFlow*
 - 10.10.4. Verwendung der Anwendung für die Vorhersage von Ergebnissen

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

- 11.1. Die *Visual-Cortex*-Architektur
 - 11.1.1. Funktionen des visuellen Kortex
 - 11.1.2. Theorien des rechnergestützten Sehens
 - 11.1.3. Modelle der Bildverarbeitung
- 11.2. Faltungsschichten
 - 11.2.1. Wiederverwendung von Gewichten bei der Faltung
 - 11.2.2. Faltung D
 - 11.2.3. Aktivierungsfunktionen
- 11.3. Gruppierungsschichten und Implementierung von Gruppierungsschichten mit Keras
 - 11.3.1. *Pooling* und *Striding*
 - 11.3.2. *Flattening*
 - 11.3.3. Arten des *Pooling*
- 11.4. CNN-Architektur
 - 11.4.1. VGG-Architektur
 - 11.4.2. AlexNet-Architektur
 - 11.4.3. ResNet-Architektur
- 11.5. Implementierung eines ResNet-CNN mit Keras
 - 11.5.1. Initialisierung der Gewichte
 - 11.5.2. Definition der Eingabeschicht
 - 11.5.3. Definition der Ausgabe
- 11.6. Verwendung von vortrainierten Keras-Modellen
 - 11.6.1. Merkmale der vortrainierten Modelle
 - 11.6.2. Verwendung von vortrainierten Modellen
 - 11.6.3. Vorteile von vortrainierten Modellen

- 11.7. Vortrainierte Modelle für das Transferlernen
 - 11.7.1. Transferlernen
 - 11.7.2. Prozess des Transferlernens
 - 11.7.3. Vorteile des Transferlernens
- 11.8. Klassifizierung und Lokalisierung in *Deep Computer Vision*
 - 11.8.1. Klassifizierung von Bildern
 - 11.8.2. Objekte in Bildern lokalisieren
 - 11.8.3. 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
 - 11.10.1. Kantenerkennung
 - 11.10.1. Regelbasierte Segmentierungsmethoden

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

- 12.1. Textgenerierung mit RNN
 - 12.1.1. Training eines RNN für die Texterzeugung
 - 12.1.2. Generierung natürlicher Sprache mit RNN
 - 12.1.3. Anwendungen zur Texterzeugung mit RNN
- 12.2. Erstellung von Trainingsdatensätzen
 - 12.2.1. Vorbereitung der Daten für das RNN-Training
 - 12.2.2. Speicherung des Trainingsdatensatzes
 - 12.2.3. Bereinigung und Transformation der Daten
 - 12.2.4. Sentiment-Analyse
- 12.3. Ranking von Meinungen mit RNN
 - 12.3.1. Erkennung von Themen in Kommentaren
 - 12.3.2. Stimmungsanalyse mit *Deep-Learning*-Algorithmen

- 12.4. *Encoder-Decoder*-Netz für neuronale maschinelle Übersetzung
 - 12.4.1. Training eines RNN für maschinelle Übersetzung
 - 12.4.2. Verwendung eines *Encoder-Decoder*-Netzes für die maschinelle Übersetzung
 - 12.4.3. Verbesserung der Genauigkeit der maschinellen Übersetzung mit RNNs
- 12.5. Aufmerksamkeitsmechanismen
 - 12.5.1. Implementierung von Aufmerksamkeitsmechanismen in RNN
 - 12.5.2. Verwendung von Betreuungsmechanismen zur Verbesserung der Modellgenauigkeit
 - 12.5.3. Vorteile von Betreuungsmechanismen in neuronalen Netzen
- 12.6. *Transformer*-Modelle
 - 12.6.1. Verwendung von *Transformer*-Modellen für die Verarbeitung natürlicher Sprache
 - 12.6.2. Anwendung von *Transformer*-Modellen für 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 *Transformer*-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 Netze
 - 14.9.2. Praktisches Beispiel mit neuronalen Netzen
- 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 künstlicher Intelligenz im Gesundheitswesen. Chancen und Herausforderungen
 - 15.2.2. Anwendungsbeispiele
- 15.3. Risiken im Zusammenhang mit dem Einsatz von künstlicher Intelligenz im Gesundheitswesen
 - 15.3.1. Potenzielle Risiken im Zusammenhang mit dem Einsatz von künstlicher Intelligenz
 - 15.3.2. Mögliche zukünftige Entwicklungen/Nutzungen von künstlicher Intelligenz
- 15.4. *Retail*
 - 15.4.1. Auswirkungen von künstlicher Intelligenz im *Retail*. Chancen und Herausforderungen
 - 15.4.2. Anwendungsbeispiele
 - 15.4.3. Potenzielle Risiken im Zusammenhang mit dem Einsatz von künstlicher Intelligenz
 - 15.4.4. Mögliche zukünftige Entwicklungen/Nutzungen von künstlicher Intelligenz

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

Modul 16. Verwaltung und Analyse von biomedizinischen Informationen und wissenschaftlicher Literatur mit künstlicher Intelligenz

- 16.1. Einführung in den Einsatz von KI in der biomedizinischen Information
 - 16.1.1. Bedeutung von biomedizinischen Informationen in der Pharmazie
 - 16.1.2. Herausforderungen bei der Verwaltung und Analyse von wissenschaftlicher Literatur
 - 16.1.3. Rolle der KI bei der Handhabung großer Mengen an wissenschaftlichen Daten
 - 16.1.4. Beispiele von KI-Tools wie Semantic Scholar in der biomedizinischen Forschung
- 16.2. Informationsbeschaffung in der Biomedizin mit KI
 - 16.2.1. Fortgeschrittene Suchtechniken in wissenschaftlichen Datenbanken
 - 16.2.2. KI-Algorithmen zur Verbesserung der Suchgenauigkeit und Relevanz
 - 16.2.3. Personalisierung von Ergebnissen durch maschinelles Lernen
 - 16.2.4. Anwendungen wie PubMed AI für eine effiziente Informationsbeschaffung
- 16.3. Verarbeitung natürlicher Sprache (NLP) in wissenschaftlichen Texten
 - 16.3.1. NLP-Anwendungen in der Analyse biomedizinischer Literatur
 - 16.3.2. Automatische Extraktion von Schlüsselinformationen aus wissenschaftlichen Artikeln
 - 16.3.3. Automatische Zusammenfassung und Generierung von strukturierten Zusammenfassungen
 - 16.3.4. Tools wie SciBERT für die wissenschaftliche Textverarbeitung
- 16.4. Biomedizinisches *Text Mining*
 - 16.4.1. Grundlegende Konzepte und Techniken im *Text Mining*
 - 16.4.2. Identifizierung von Trends und Mustern in wissenschaftlichen Publikationen
 - 16.4.3. Extraktion von Beziehungen zwischen biomedizinischen Entitäten
 - 16.4.4. Beispiele wie MEDLINE und Text Mining Library für *Text Mining*
- 16.5. Ontologien und semantische Annotationen in der Biomedizin
 - 16.5.1. Verwendung und Erstellung von Ontologien in den Gesundheitswissenschaften
 - 16.5.2. Semantische Annotation von wissenschaftlichen Dokumenten
 - 16.5.3. KI für semantische Anreicherung und kontextbezogene Suche
 - 16.5.4. Tools wie BioPortal und UMLS für die Ontologieverwaltung
- 16.6. Empfehlungssysteme für wissenschaftliche Literatur
 - 16.6.1. Empfehlungsalgorithmen in wissenschaftlichen Plattformen
 - 16.6.2. Personalisierung von Inhalten für Forscher und Fachkräfte
 - 16.6.3. KI bei der Vorhersage zukünftiger Relevanz und Zitationen
 - 16.6.4. Anwendungen wie Mendeley Suggest und ResearchGate
- 16.7. Visualisierung von biomedizinischen Daten und Kenntnissen

- 16.7.1. Visualisierungstechniken für komplexe Daten in der Biomedizin
- 16.7.2. Wissenskarten und Forschungsnetzwerke
- 16.7.3. KI-Tools zur Visualisierung von Beziehungen und Trends
- 16.7.4. Beispiele wie VOSviewer und Cytoscape in der wissenschaftlichen Visualisierung
- 16.8. KI-gestützte Wissensentdeckung
 - 16.8.1. Identifizierung neuer Hypothesen aus vorhandenen Daten
 - 16.8.2. Integration von multidisziplinären Daten mit KI
 - 16.8.3. Vorhersage unbekannter Wechselwirkungen zwischen Medikamenten und Wirkungen
 - 16.8.4. Beispiele wie IBM Watson Discovery und Entellect von Elsevier
- 16.9. Verwaltung von *Big Data* in der biomedizinischen Forschung
 - 16.9.1. Herausforderungen von *Big Data* in der biomedizinischen Forschung
 - 16.9.2. Effiziente Speicherung und Verarbeitung von Massendaten
 - 16.9.3. KI für die Analyse genomischer und proteomischer Daten
 - 16.9.4. Werkzeuge wie Apache Hadoop und Spark in der Biomedizin
- 16.10. Herausforderungen und Zukunftsperspektiven im NLP für wissenschaftliche Literatur
 - 16.10.1. Spezifische NLP-Herausforderungen bei wissenschaftlichen und biomedizinischen Daten
 - 16.10.2. Beschränkungen bei der Automatisierung von Suche und Analyse
 - 16.10.3. Jüngste Fortschritte im NLP für biomedizinische Wissenschaften (BioGPT, BioBERT)
 - 16.10.4. Künftige Anwendungen von KI in der wissenschaftlichen Forschung und Veröffentlichung

Modul 17. Entwicklung von neuen Medikamenten mit künstlicher Intelligenz

- 17.1. Identifizierung von therapeutischen *Targets* mit KI
 - 17.1.1. Konzept der therapeutischen *Targets* und ihre Bedeutung in der Pharmakologie
 - 17.1.2. KI-Algorithmen für die Identifizierung potenzieller *Targets*
 - 17.1.3. Neuronale Netzwerkmodelle für die Vorhersage therapeutischer *Targets*
 - 17.1.4. Beispiele wie Insilico Medicine für die Entdeckung von *Targets*
- 17.2. KI-gestütztes Design von Arzneimitteln
 - 17.2.1. KI-gestützte Techniken des molekularen Designs
 - 17.2.2. Computermodellierung im Arzneimitteldesign
 - 17.2.3. Generierung von Molekülen mit *Deep Learning*
 - 17.2.4. Anwendungen wie Atomwise in der Arzneimittelforschung
- 17.3. Optimierung von pharmazeutischen Wirkstoffen

- 17.3.1. Optimierungsprozesse bei der Arzneimittelentwicklung
- 17.3.2. KI-Techniken zur Verbesserung der Eigenschaften von Wirkstoffen
- 17.3.3. Werkzeuge für die molekulare Simulation bei der Optimierung von Arzneimitteln
- 17.3.4. Beispiele für Plattformen wie Schrodinger zur Optimierung
- 17.4. Simulation von Arzneimittel-Rezeptor-Wechselwirkungen
 - 17.4.1. Bedeutung der Arzneimittel-Rezeptor-Wechselwirkungen
 - 17.4.2. Techniken der molekularen Simulation in der Pharmakologie
 - 17.4.3. KI-Algorithmen zur Vorhersage molekularer Wechselwirkungen
 - 17.4.4. Tools wie Cresset zur Simulation von Wechselwirkungen
- 17.5. Erstellung von Bibliotheken bioaktiver Wirkstoffe
 - 17.5.1. Erstellung von Bibliotheken mit Wirkstoffen in der Arzneimittelentwicklung
 - 17.5.2. KI bei der Generierung und Klassifizierung von Wirkstoffen
 - 17.5.3. Virtuelles Screening bioaktiver Wirkstoffe
 - 17.5.4. Beispiel für Tools wie ChemAxon Chemoinformatics
- 17.6. Hypothesenvalidierung in der präklinischen Phase mit KI
 - 17.6.1. Hypothesenvalidierung in präklinischen Phasen
 - 17.6.2. KI-Modelle für Tests in der präklinischen Forschung
 - 17.6.3. Tools für präklinische prädiktive Analysen
 - 17.6.4. Beispiel von BenevolentAI in der präklinischen Forschung
- 17.7. Vorhersage von Nebenwirkungen und Toxizität
 - 17.7.1. Bewertung von Nebenwirkungen durch KI
 - 17.7.2. Toxizitätsmodelle in frühen Entwicklungsphasen
 - 17.7.3. KI für Sicherheits- und Toxizitätsanalysen von Arzneimitteln
 - 17.7.4. DeepChem-Anwendungen für die Toxizität von Wirkstoffen
- 17.8. Optimierung von Dosierungen und Formulierungen
 - 17.8.1. Grundsätze der Formulierung und Optimierung von Dosierungen
 - 17.8.2. KI bei der Bestimmung der wirksamen und sicheren Dosis
 - 17.8.3. Prädiktive Modelle zur Optimierung von Formulierungen
 - 17.8.4. Beispiel von Genentech für Dosis- und Formulierungsstudien
- 17.9. In-silico-Tests in frühen Entwicklungsphasen
 - 17.9.1. Konzept der In-silico-Tests in der pharmazeutischen Entwicklung

- 17.9.2. Algorithmen für Simulation und virtuelle Tests
- 17.9.3. KI bei der Reduzierung von In-vitro- und In-vivo-Tests
- 17.9.4. Beispiel von Simulations Plus bei der In-silico-Vorhersage
- 17.10. KI-gestützte klinische Studien
 - 17.10.1. KI-gestützter Entwurf von klinischen Studien
 - 17.10.2. Optimierung der Rekrutierungsphase in klinischen Studien
 - 17.10.3. Modellierung von Reaktionen und Überwachung in klinischen Studien
 - 17.10.4. Fälle wie Medidata Solutions bei der Optimierung klinischer Studien

Modul 18. Künstliche Intelligenz in der Diagnose und bei personalisierten Therapien

- 18.1. Früherkennung von Krankheiten
 - 18.1.1. Bedeutung der Früherkennung bei der Behandlung von Krankheiten
 - 18.1.2. KI-Algorithmen zur Früherkennung von Krankheiten
 - 18.1.3. KI zur prädiktiven Analyse von Risikofaktoren
 - 18.1.4. Beispiele wie PathAI für die automatisierte Diagnose
- 18.2. Personalisierte Therapien auf der Grundlage von KI
 - 18.2.1. Einführung in die personalisierte Medizin und ihre Bedeutung
 - 18.2.2. KI zur Personalisierung von Behandlungen entsprechend dem Patientenprofil
 - 18.2.3. Prädiktive Modelle zur Anpassung der personalisierten Dosis
 - 18.2.4. Anwendungen wie Tempus in der personalisierten Onkologie
- 18.3. Erkennung von Biomarkern durch KI
 - 18.3.1. Konzept und Arten von Biomarkern in der Medizin
 - 18.3.2. KI-Algorithmen zur Identifizierung von entscheidenden Biomarkern
 - 18.3.3. Bedeutung von Biomarkern bei Diagnose und Behandlung
 - 18.3.4. Tools wie Freenome zur Erkennung von Biomarkern
- 18.4. Genomik und Pharmakogenomik in der Medizin
 - 18.4.1. Genomik und Pharmakogenomik zur Personalisierung von Therapien
 - 18.4.2. KI-Anwendungen bei der Analyse genetischer Profile
 - 18.4.3. KI bei der Untersuchung genetischer Variationen für die personalisierte Medizin
 - 18.4.4. Fälle wie 23andMe in der personalisierten Genanalyse
- 18.5. KI in der Immuntherapie und Onkologie

- 18.5.1. Einführung in die Immuntherapie und ihre Auswirkungen auf die Krebsbehandlung
- 18.5.2. Anwendung von KI zur Personalisierung von Immuntherapien
- 18.5.3. KI-Modelle zur Optimierung der Wirksamkeit von Immuntherapien
- 18.5.4. Beispiele wie GNS Healthcare für die Immuntherapie in der Onkologie
- 18.6. Personalisierte pharmakologische Beratung
 - 18.6.1. Bedeutung der personalisierten pharmakologischen Beratung
 - 18.6.2. KI für Behandlungsempfehlungen unter bestimmten Bedingungen
 - 18.6.3. KI-Modelle zur Optimierung der Arzneimittelauswahl
 - 18.6.4. Beispiel IBM Watson for Oncology bei Behandlungsempfehlungen
- 18.7. Vorhersage von Reaktionen auf Behandlungen
 - 18.7.1. KI-Techniken zur Vorhersage von Reaktionen auf verschiedene Behandlungen
 - 18.7.2. Prädiktive Modelle für die Wirksamkeit und Sicherheit von Behandlungen
 - 18.7.3. KI-Algorithmen für die Personalisierung von Behandlungen
 - 18.7.4. Tools wie Foundation Medicine für die Analyse von Reaktionen auf Behandlungen
- 18.8. Entwicklung von Algorithmen für spezifische Therapien
 - 18.8.1. Grundsätze der Entwicklung von Algorithmen für gezielte Therapien
 - 18.8.2. KI zur Identifizierung und Entwicklung spezifischer Therapien
 - 18.8.3. Personalisierte Algorithmen je nach Art der Krankheit
 - 18.8.4. Anwendungen wie Owkin im Verbundlernen für die Onkologie
- 18.9. Fernüberwachung von Patienten
 - 18.9.1. Bedeutung der Fernüberwachung bei chronischen Patienten
 - 18.9.2. KI zur Fernüberwachung von Parametern und Vitalzeichen
 - 18.9.3. Prädiktive Modelle zur Vorhersage von Komplikationen bei Patienten
 - 18.9.4. Tools wie Biofourmis zur Fernüberwachung
- 18.10. KI in tragbaren Diagnosegeräten
 - 18.10.1. Auswirkungen tragbarer Geräte auf die Gesundheitsdiagnose
 - 18.10.2. KI-Algorithmen zur Analyse von Daten tragbarer Geräte
 - 18.10.3. KI zur Erkennung von Gesundheitszuständen in Echtzeit
 - 18.10.4. Beispiele wie Butterfly iQ, tragbares KI-unterstütztes Ultraschallgerät

Modul 19. Künstliche Intelligenz in der pharmazeutischen Produktion und im Vertrieb

- 19.1. Optimierung von Herstellungsprozessen mit KI
 - 19.1.1. Einführung in die pharmazeutische Herstellung und aktuelle Herausforderungen
 - 19.1.2. KI-Algorithmen zur Verbesserung der Produktionseffizienz
 - 19.1.3. Prädiktive Modelle zur Verkürzung der Herstellungszeiten
 - 19.1.4. Beispiel Siemens Pharma zur Prozessautomatisierung
- 19.2. Qualitätskontrolle bei der Arzneimittelherstellung
 - 19.2.1. Bedeutung der Qualitätskontrolle in der pharmazeutischen Industrie
 - 19.2.2. KI-Algorithmen zur Inspektion und Fehlererkennung
 - 19.2.3. KI zur Sicherstellung einer gleichbleibenden Produktqualität
 - 19.2.4. Anwendungen wie Aizon zur Qualitätsanalyse in der Produktion
- 19.3. KI für Bestandsverwaltung und Vertrieb
 - 19.3.1. Einführung in die Bestandsverwaltung in der Pharmabranche
 - 19.3.2. KI-Modelle zur Optimierung von Beständen und Nachfrage
 - 19.3.3. Vorhersage der Nachfrage durch Datenanalyse
 - 19.3.4. Tools wie SAP Integrated Business Planning
- 19.4. Vorausschauende Wartung in Produktionsanlagen
 - 19.4.1. Konzept der vorausschauenden Wartung und ihre Vorteile
 - 19.4.2. KI-Algorithmen zur Vorhersage von Maschinenausfällen
 - 19.4.3. KI zur Optimierung von Wartungszyklen
 - 19.4.4. Beispiele für vorausschauende Wartung mit GE Digital
- 19.5. Erkennung von Arzneimittelfälschungen
 - 19.5.1. Auswirkungen von Arzneimittelfälschungen auf die öffentliche Gesundheit
 - 19.5.2. KI zur Authentifizierung von Arzneimitteln
 - 19.5.3. Computer-Vision-Algorithmen zur Erkennung von Fälschungen
 - 19.5.4. Tools wie TruTag zur Überprüfung der Echtheit
- 19.6. Automatisierung bei Verpackung und Etikettierung
 - 19.6.1. Verpackungsprozesse in der Pharmaindustrie
 - 19.6.2. KI zur Optimierung der automatisierten Etikettierung und Verpackung
 - 19.6.3. Computer-Vision-Techniken bei der Etikettenkontrolle
 - 19.6.4. Anwendungen von Rockwell Automation für die Verpackung
- 19.7. Optimierung der Logistik und sicherer Vertrieb von Arzneimitteln

- 19.7.1. Logistik von Arzneimitteln und ihre Auswirkungen auf die Verfügbarkeit
- 19.7.2. KI-Algorithmen zur Optimierung von Vertriebswegen
- 19.7.3. KI zur Überwachung von Lieferungen und Transportbedingungen
- 19.7.4. Beispiele wie UPS Healthcare für einen sicheren Vertrieb
- 19.8. KI zur Verbesserung der Kühlkette im Vertrieb
 - 19.8.1. Bedeutung der Kühlkette bei empfindlichen Arzneimitteln
 - 19.8.2. Prädiktive Modelle zur Aufrechterhaltung optimaler Temperaturen
 - 19.8.3. Algorithmen zur Echtzeit-Überwachung
 - 19.8.4. Tools wie Carrier Sensitech zur Kontrolle der Kühlkette
- 19.9. Automatisierung der Lagerverwaltung in Apotheken
 - 19.9.1. Einführung in die Lagerverwaltung in Apotheken
 - 19.9.2. KI-Algorithmen zur Optimierung der Produktnachbestellung
 - 19.9.3. KI-Systeme zur Vorhersage von Nachfrage und Verbrauch
 - 19.9.4. Anwendungen wie Omnicell für die automatisierte Bestandsverwaltung
- 19.10. KI-gestützte Optimierung von Lieferrouten
 - 19.10.1. Herausforderungen bei der Lieferung in der Pharmaindustrie
 - 19.10.2. Algorithmen zur Routenoptimierung für eine effiziente Lieferung
 - 19.10.3. KI für dynamische Routenplanung in Echtzeit
 - 19.10.4. Beispiel DHL SmartSensor für die Medikamentenlogistik

Modul 20. Regulierung, Sicherheit und Ethik der künstlichen Intelligenz in der Pharmazie

- 20.1. Vorschriften für KI in pharmazeutischen Produkten
 - 20.1.1. Einführung in die Regulierungsvorschriften für KI im Gesundheitswesen
 - 20.1.2. Wichtigste Regulierungsbehörden (FDA, EMA) und ihre Rolle bei der KI
 - 20.1.3. Regelungen für die Zulassung von KI-Technologien in der Pharmazie
 - 20.1.4. Beispiele für die Zertifizierung von KI-Software für Gesundheitsprodukte
- 20.2. KI-Compliance im Gesundheitswesen
 - 20.2.1. Schlüsselkonzepte für die KI-Compliance
 - 20.2.2. Gesetzliche Anforderungen für die Entwicklung von KI in der Pharmazie
 - 20.2.3. KI-Audits zur Sicherstellung der Einhaltung gesetzlicher Vorschriften
 - 20.2.4. Beispiele für KI-Compliance gemäß der europäischen MDR
- 20.3. Datensicherheit bei KI-Anwendungen

- 20.3.1. Einführung in die Datensicherheit im Gesundheitsbereich
- 20.3.2. Sicherheitsprotokolle für die Speicherung medizinischer Daten
- 20.3.3. KI zur Bedrohungserkennung und zum Datenschutz
- 20.3.4. Microsoft-Azure-Tools für sicheres Datenmanagement
- 20.4. Datenschutz und Ethik bei KI-Anwendungen
 - 20.4.1. Ethische Konzepte im Umgang mit Patientendaten
 - 20.4.2. Verantwortungsvolle KI und Datenschutzgrundsätze in der Pharmazie
 - 20.4.3. Tools zur Anonymisierung sensibler Daten
 - 20.4.4. Beispiele für Datenschutz in Google Health
- 20.5. Transparenz von Algorithmen in der KI für den Gesundheitsbereich
 - 20.5.1. Bedeutung der Transparenz in der KI im Gesundheitsbereich
 - 20.5.2. Erklärbarkeit von Algorithmen und ihre Interpretation im Gesundheitsbereich
 - 20.5.3. Methoden zur Gewährleistung der Transparenz in KI-Modellen
 - 20.5.4. Anwendung von IBM Explainable AI für die Gesundheit
- 20.6. Vermeidung von Verzerrungen in KI-Systemen
 - 20.6.1. Identifizierung von Verzerrungen in medizinischen und pharmazeutischen Daten
 - 20.6.2. Techniken zur Minimierung von Verzerrungen in KI-Algorithmen
 - 20.6.3. Beispiele für häufige Verzerrungen in der KI für die Pharmazie
 - 20.6.4. Verwendung des Fairness Toolkit von Google zur Verringerung von Verzerrungen
- 20.7. Audit von KI-Systemen in der Pharmazie
 - 20.7.1. Konzept und Ziele des Audits von KI im Gesundheitswesen
 - 20.7.2. Auditmethoden zur Validierung von KI-Systemen
 - 20.7.3. Audit-Kriterien zur Gewährleistung von Qualität und Ethik
 - 20.7.4. Beispiel für ein KI-Audit mit TÜV SÜD
- 20.8. Zustimmung nach Inkenntnissetzung bei Gesundheitsdaten mit KI
 - 20.8.1. Bedeutung der Zustimmung bei der Verwendung personenbezogener Daten
 - 20.8.2. KI-Tools für die Verwaltung der Zustimmung nach Inkenntnissetzung
 - 20.8.3. KI bei der Einholung und sicheren Speicherung von Einwilligungen
 - 20.8.4. Beispiel für die Verwaltung von Einwilligungen in Epic Systems
- 20.9. KI zur Aufdeckung von Betrug in der Pharmazie

- 20.9.1. Auswirkungen von Betrug in der Pharmaindustrie
- 20.9.2. KI-Algorithmen zur Identifizierung betrügerischer Aktivitäten
- 20.9.3. KI zur Verhinderung von Arzneimittelfälschungen und illegalem Verkauf
- 20.9.4. Beispiel SAS Fraud Framework für den Gesundheitsbereich
- 20.10. Verantwortung und Rechenschaftspflicht in der KI
 - 20.10.1. Konzept der Rechenschaftspflicht in KI-Anwendungen
 - 20.10.2. Definition von Rollen und Verantwortlichkeiten in der KI für den Gesundheitsbereich
 - 20.10.3. KI zur Verfolgung von Entscheidungen und Maßnahmen in Gesundheitsprozessen
 - 20.10.4. Initiativen wie die Partnerschaft für KI für Richtlinien zur Rechenschaftspflicht





“

Mit diesem Programm werden Sie nicht nur Ihr theoretisches Wissen erweitern, sondern auch praktische Instrumente zur Innovation, Führung und Transformation der Zukunft der Pharmazie erwerben“

04

Lehrziele

Das Hauptziel dieses Aufbaustudiengangs besteht in der Fortbildung von Fachleuten, um die Integration der fortschrittlichsten Technologie in ihrem Bereich zu leiten. Auf diese Weise vermittelt das Programm den Studenten die erforderlichen Kenntnisse und Fähigkeiten, um die pharmazeutische Versorgung zu transformieren, indem es Prozesse optimiert, die Sicherheit von Behandlungen verbessert und die Patientenerfahrung personalisiert. Außerdem werden sie den Umgang mit KI-Tools beherrschen, um große Mengen pharmakologischer und klinischer Daten zu analysieren. Schließlich werden sie zu Experten für die Identifizierung von Arzneimittelwechselwirkungen und die Entwicklung innovativer Lösungen, die sich positiv auf die Gesundheit der Patienten auswirken.



“

Die technologische Revolution ist bereits da, und TECH wird Sie darauf vorbereiten, ein Teil davon zu sein! Nehmen Sie an diesem innovativen Studiengang teil und bringen Sie Ihre Fähigkeiten als Pharmazeut auf die nächste Stufe“



Allgemeine Ziele

- ♦ Analysieren und Anwenden von KI-Tools in pharmazeutischen Prozessen
- ♦ Optimieren der Verwaltung klinischer und pharmakologischer Daten durch fortschrittliche Technologien
- ♦ Identifizieren von Arzneimittelwechselwirkungen durch KI-Vorhersagemodelle
- ♦ Entwerfen innovativer Strategien für die Entwicklung neuer Arzneimittel
- ♦ Leiten von Projekten zur digitalen Transformation im pharmazeutischen Bereich
- ♦ Implementieren technologischer Lösungen zur Verbesserung der Sicherheit bei der Abgabe von Arzneimitteln
- ♦ Verstehen der globalen Trends bei der Integration von KI in Gesundheitssysteme
- ♦ Entwickeln von Führungsqualitäten in multidisziplinären Teams, die sich auf technologische Innovation konzentrieren





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
- ♦ Beherrschen der Grundsätze und Anwendungen von genetischen Algorithmen und Analysieren ihrer Nützlichkeit bei der Lösung komplexer Probleme
- ♦ Bewerten 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
- ♦ Bewerten des *Datawarehouse*-Konzepts mit Schwerpunkt auf seinen Bestandteilen und seinem Aufbau

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
- ♦ Analysieren der Struktur und der Eigenschaften von *Datasets* und verstehen ihre Bedeutung für die Aufbereitung und Nutzung von Daten für KI-Modelle
- ♦ Verwalten von überwachten und unüberwachten Modellen, einschließlich Methoden und Klassifizierung

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
- ♦ 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, Verstehen 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 der Softwaretechnik
- ♦ 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
- ♦ Implementieren semantischer *Reasoner*, wissensbasierter Systeme und Expertensysteme und Verstehen ihrer Funktionalität und Anwendungen in der intelligenten Entscheidungsfindung

Modul 7. Maschinelles Lernen und *Data Mining*

- ♦ Einführen in die Prozesse der Wissensentdeckung und in die grundlegenden Konzepte des maschinellen Lernens
- ♦ Implementieren 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
- ♦ Untersuchen neuronaler Netze und Verstehen ihrer Funktionsweise und Architektur, um komplexe Probleme des maschinellen Lernens zu lösen
- ♦ Erforschen von Bayesschen Methoden und deren Anwendung im maschinellen Lernen, einschließlich Bayesscher Netze und 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
- ♦ Erforschen der Verbindung zwischen biologischen und künstlichen Neuronen für ein tieferes Verständnis des Modelldesigns
- ♦ Anpassen von Hyperparametern für das *Fine Tuning* neuronaler Netze, um ihre Leistung bei bestimmten Aufgaben zu optimieren

Modul 9. Training Tiefer Neuronaler Netze

- ♦ Lösen von Problemen im Zusammenhang mit Gradienten beim Training von tiefen neuronalen Netzen
- ♦ Anwenden praktischer Richtlinien, um ein effizientes und effektives Training von tiefen neuronalen Netzen zu gewährleisten
- ♦ Implementieren von *Transfer Learning* als fortgeschrittene Technik zur Verbesserung der Modellleistung bei bestimmten Aufgaben

- ♦ Erforschen und Anwenden von Techniken der *Data Augmentation* zur Anreicherung von Datensätzen und Verbesserung der Modellgeneralisierung
- ♦ Entwickeln praktischer Anwendungen mit *Transfer Learning* zur Lösung realer Probleme
- ♦ Verstehen und Anwenden von Regularisierungstechniken zur Verbesserung der Generalisierung und zur Vermeidung von *Overfitting* in tiefen neuronalen Netzen

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

- ♦ Beherrschen der Grundlagen von *TensorFlow* und seiner Integration mit NumPy für effiziente Datenverwaltung und Berechnungen
- ♦ Anpassen von Modellen und Trainingsalgorithmen mit den fortgeschrittenen Fähigkeiten von *TensorFlow*
- ♦ 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

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
- ♦ Untersuchen der Strategien zur Objekterkennung und -verfolgung mit Convolutional Neural Networks
- ♦ Implementieren von semantischen Segmentierungstechniken, um Objekte in Bildern im Detail zu verstehen und zu klassifizieren

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

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

Modul 13. Autoencoder, GANs und Diffusionsmodelle

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

Modul 14. Bio-inspiriertes Computing

- ♦ Einführen in die grundlegenden Konzepte des bio-inspirierten Computings
- ♦ Analysieren sozialer Anpassungsalgorithmen als wichtiger Ansatz im bio-inspirierten Computing
- ♦ Untersuchen von Modellen des evolutionären Rechnens im Kontext der Optimierung
- ♦ Bewältigen der Komplexität von Multi-Objektiv-Problemen im Rahmen des bio-inspirierten Computings
- ♦ Erforschen der Anwendung von neuronalen Netzen im Bereich des bio-inspirierten Computings
- ♦ Vertiefen der Implementierung und des Nutzens von neuronalen Netzen im Bereich des bio-inspirierten Computings

Modul 15. Künstliche Intelligenz: Strategien und Anwendungen

- ♦ Entwickeln von Strategien für die Implementierung von künstlicher Intelligenz in Finanzdienstleistungen
- ♦ Analysieren der Auswirkungen von künstlicher Intelligenz auf die Erbringung von Dienstleistungen im Gesundheitswesen
- ♦ Identifizieren und Bewerten der Risiken im Zusammenhang mit dem Einsatz von künstlicher Intelligenz im Gesundheitssektor
- ♦ Bewerten der potenziellen Risiken im Zusammenhang mit dem Einsatz von künstlicher Intelligenz 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

Modul 16. Verwaltung und Analyse von biomedizinischen Informationen und wissenschaftlicher Literatur mit künstlicher Intelligenz

- ♦ Beherrschen von Werkzeugen zur Verarbeitung natürlicher Sprache (NLP), um große Mengen wissenschaftlicher und biomedizinischer Literatur zu analysieren
- ♦ Anwenden von *Text-Mining*-Techniken zur Ermittlung wichtiger Trends und Beziehungen in wissenschaftlichen Veröffentlichungen
- ♦ Verwenden fortgeschrittener Systeme zur Informationsbeschaffung wie PubMed AI, um die Suche in biomedizinischen Datenbanken zu optimieren
- ♦ Anwenden von Ontologien und semantischen Annotationen, um das Verständnis und die Organisation biomedizinischer Daten zu verbessern.

Modul 17. Entwicklung von neuen Medikamenten mit künstlicher Intelligenz

- ♦ Identifizieren von therapeutischen Zielen mithilfe von Algorithmen der künstlichen Intelligenz und Computermodellierung
- ♦ Entwerfen und Optimieren von Molekülen mithilfe von *Deep Learning* und molekularen Simulationstechniken
- ♦ Durchführen von In-silico-Tests zur Bewertung von Arzneimittel-Rezeptor-Interaktionen, Toxizität und Wirksamkeit in präklinischen Phasen
- ♦ Integrieren von KI in virtuelles Screening und Generieren von Bibliotheken bioaktiver Substanzen

Modul 18. Künstliche Intelligenz in der Diagnose und bei personalisierten Therapien

- ♦ Anwenden von KI für die Frühdiagnose von Krankheiten und die Identifizierung wichtiger Biomarker
- ♦ Entwickeln personalisierter Therapien auf der Grundlage genomischer und pharmakogenomischer Profile
- ♦ Verwenden von prädiktiven Modellen zur Anpassung von Behandlungen und zur Personalisierung der Medikamentendosierung
- ♦ Implementieren fortschrittlicher Algorithmen zur Optimierung immunologischer Therapien und onkologischer Behandlungen

Modul 19. Künstliche Intelligenz in der pharmazeutischen Produktion und im Vertrieb

- ♦ Optimieren von Fertigungsprozessen durch Algorithmen der künstlichen Intelligenz, um die Effizienz zu steigern und die Kosten zu senken
- ♦ Implementieren automatisierter Systeme für Qualitätskontrolle, Verpackung und Etikettierung in der Pharmaindustrie
- ♦ Verwalten von Lagerbeständen und Optimieren der Vertriebslogistik mithilfe von KI, um die Sicherheit und Rückverfolgbarkeit von Medikamenten zu gewährleisten
- ♦ Erkennen von Fälschungen und Garantieren der Echtheit von pharmazeutischen Produkten mit Hilfe von KI-Tools

Modul 20. Regulierung, Sicherheit und Ethik der künstlichen Intelligenz in der Pharmazie

- ♦ Verstehen der internationalen Vorschriften für den Einsatz von KI in der Pharmaindustrie
- ♦ Anwenden von Protokollen zur Gewährleistung des Datenschutzes und der Datensicherheit bei KI-Anwendungen
- ♦ Identifizieren und Abschwächen von Verzerrungen in Systemen der künstlichen Intelligenz, um Fairness und Transparenz zu gewährleisten
- ♦ Verwalten der ethischen Verantwortung und Erklärbarkeit von Algorithmen im klinischen und pharmazeutischen Umfeld



“

TECH wird Ihnen das berufliche und persönliche Wachstum ermöglichen, das Sie für eine bessere berufliche Zukunft benötigen. Nehmen Sie jetzt an einer einzigartigen akademischen Erfahrung teil!”

05

Karrieremöglichkeiten

Dieser Weiterbildende Masterstudiengang öffnet die Tür zu einer Vielzahl von Möglichkeiten in einem Sektor, der das Gesundheitswesen revolutioniert. Angesichts der wachsenden Nachfrage nach Experten, die in der Lage sind, Technologien in den pharmazeutischen Bereich zu integrieren, werden sich die Absolventen auf einem hart umkämpften Arbeitsmarkt als Führungskräfte positionieren. Zu den herausragendsten Möglichkeiten gehören Positionen in den Abteilungen für Arzneimittelforschung und -entwicklung, wo sie in der Lage sein werden, Vorhersagemodelle anzuwenden, um die Entwicklung innovativer Arzneimittel zu beschleunigen. Sie werden auch in der Lage sein, strategische Funktionen bei der Verwaltung großer Mengen pharmakologischer Daten zur Optimierung von Prozessen zu übernehmen.



“

*Die Zukunft der Pharmazie liegt in der Technologie!
Wenn Sie sich für diesen Abschluss entscheiden,
verschaffen Sie sich einen Wettbewerbsvorteil, um
sich in einem sich ständig weiterentwickelnden Umfeld
abzuheben. Machen Sie die Zukunft zu Ihrer Gegenwart!*

Profil des Absolventen

Der Absolvent wird sich als visionäre Fachkraft auszeichnen, die in der Lage ist, fortschrittliche technologische Lösungen im pharmazeutischen Bereich zu integrieren. Auf diese Weise wird dieser hochqualifizierte Experte darauf vorbereitet sein, sich den aktuellen Herausforderungen des Sektors zu stellen und die digitale Transformation der Apotheke anzuführen. Dank seiner technischen Fähigkeiten im Umgang mit Werkzeugen der künstlichen Intelligenz wird er in der Lage sein, innovative Strategien zur Optimierung von Prozessen, zur Personalisierung von Behandlungen und zur Verbesserung der Verwaltung von klinischen und pharmakologischen Daten zu entwickeln. Darüber hinaus wird er über ein globales Verständnis von KI-Anwendungen im Gesundheitsbereich verfügen, das ihn in die Lage versetzt, effektive Lösungen in verschiedenen internationalen Kontexten zu implementieren.

Sind Sie bereit, sich in einem dynamischen Sektor hervorzutun? Dank dieses Programms werden Sie Lösungen anbieten, die einen Unterschied machen, und sich als führend in der Pharmazie der Zukunft positionieren.

- ♦ **Kritisches Denken und Problemlösung:** Analyse und Lösung komplexer Herausforderungen im Zusammenhang mit der Integration von künstlicher Intelligenz in pharmazeutische Prozesse
- ♦ **Effektive Kommunikationsfähigkeiten:** Vermittlung innovativer Ideen und Leitung multidisziplinärer Teams in technologischen und pharmazeutischen Umgebungen
- ♦ **Zeitmanagement und selbständiges Lernen:** Umgang mit sich verändernden Umgebungen und Aufrechterhaltung des Wissens über neue Technologien
- ♦ **Fähigkeit zur Teamarbeit:** Zusammenarbeit mit Fachleuten aus verschiedenen Bereichen bei der Umsetzung fortschrittlicher technologischer Lösungen



Nach Abschluss des Studiengangs werden Sie in der Lage sein, Ihre Kenntnisse und Fähigkeiten in den folgenden Positionen anzuwenden:

- 1. Pharmazeutischer Datenanalyst:** Spezialist für die Verwaltung und Analyse großer Mengen klinischer und pharmakologischer Daten unter Verwendung von Tools der künstlichen Intelligenz.
- 2. Berater für die digitale Transformation der Pharmaindustrie:** Fachberater für die Umsetzung innovativer technologischer Lösungen im Pharmasektor.
- 3. Leiter für Innovation in der Pharmazie:** Führend in der Entwicklung und Umsetzung von technologischen Strategien zur Verbesserung pharmazeutischer Prozesse.
- 4. Leiter von Technologieprojekten in der Pharmazie:** Verantwortlich für die Planung und Leitung von Technologieinitiativen zur Optimierung von Prozessen in Apotheken und Laboratorien.
- 5. Spezialist für KI-gestützte Arzneimittelentwicklung:** Fachkraft, die sich mit der Entwicklung und Optimierung neuer Arzneimittel mithilfe von Algorithmen der künstlichen Intelligenz befasst.
- 6. Innovationsmanager für die pharmazeutische Biotechnologie:** Experte für die Leitung von Initiativen im Bereich der künstlichen Intelligenz in Biotech-Unternehmen des Pharmasektors.
- 7. Koordinator für intelligente Systeme in Krankenhäusern:** Verantwortlich für die Integration von intelligenten Technologien in das pharmazeutische Management von Krankenhäusern.
- 8. Forscher für KI und pharmazeutische Gesundheit:** Fachkraft, die sich auf die Entwicklung von Studien konzentriert, die künstliche Intelligenz mit Fortschritten in der Pharmazie verbinden.
- 9. Direktor für digitale pharmazeutische Abläufe:** Manager für die Digitalisierung und Automatisierung von Prozessen in Apothekenketten und Labors.
- 10. Spezialist für die Personalisierung von pharmazeutischen Behandlungen:** Verantwortlich für die Entwicklung personalisierter Therapien durch Datenanalyse und den Einsatz intelligenter Algorithmen.



Eine einzigartige, wichtige und entscheidende Fortbildung, um Ihre berufliche Entwicklung zu fördern“

06

Studienmethodik

TECH ist die erste Universität der Welt, die die Methodik der **case studies** mit **Relearning** kombiniert, einem 100%igen Online-Lernsystem, das auf geführten Wiederholungen basiert.

Diese disruptive pädagogische Strategie wurde entwickelt, um Fachleuten die Möglichkeit zu bieten, ihr Wissen zu aktualisieren und ihre Fähigkeiten auf intensive und gründliche Weise zu entwickeln. Ein Lernmodell, das den Studenten in den Mittelpunkt des akademischen Prozesses stellt und ihm die Hauptrolle zuweist, indem es sich an seine Bedürfnisse anpasst und die herkömmlichen Methoden beiseite lässt.



“

TECH bereitet Sie darauf vor, sich neuen Herausforderungen in einem unsicheren Umfeld zu stellen und in Ihrer Karriere erfolgreich zu sein“

Der Student: die Priorität aller Programme von TECH

Bei der Studienmethodik von TECH steht der Student im Mittelpunkt.

Die pädagogischen Instrumente jedes Programms wurden unter Berücksichtigung der Anforderungen an Zeit, Verfügbarkeit und akademische Genauigkeit ausgewählt, die heutzutage nicht nur von den Studenten, sondern auch von den am stärksten umkämpften Stellen auf dem Markt verlangt werden.

Beim asynchronen Bildungsmodell von TECH entscheidet der Student selbst, wie viel Zeit er mit dem Lernen verbringt und wie er seinen Tagesablauf gestaltet, und das alles bequem von einem elektronischen Gerät seiner Wahl aus. Der Student muss nicht an Präsenzveranstaltungen teilnehmen, die er oft nicht wahrnehmen kann. Die Lernaktivitäten werden nach eigenem Ermessen durchgeführt. Er kann jederzeit entscheiden, wann und von wo aus er lernen möchte.

“

*Bei TECH gibt es KEINE
Präsenzveranstaltungen (an denen man nie
teilnehmen kann)“*



Die international umfassendsten Lehrpläne

TECH zeichnet sich dadurch aus, dass sie die umfassendsten Studiengänge im universitären Umfeld anbietet. Dieser Umfang wird durch die Erstellung von Lehrplänen erreicht, die nicht nur die wesentlichen Kenntnisse, sondern auch die neuesten Innovationen in jedem Bereich abdecken.

Durch ihre ständige Aktualisierung ermöglichen diese Programme den Studenten, mit den Veränderungen des Marktes Schritt zu halten und die von den Arbeitgebern am meisten geschätzten Fähigkeiten zu erwerben. Auf diese Weise erhalten die Studenten, die ihr Studium bei TECH absolvieren, eine umfassende Vorbereitung, die ihnen einen bedeutenden Wettbewerbsvorteil verschafft, um in ihrer beruflichen Laufbahn voranzukommen.

Und das von jedem Gerät aus, ob PC, Tablet oder Smartphone.

“

Das Modell der TECH ist asynchron, d. h. Sie können an Ihrem PC, Tablet oder Smartphone studieren, wo immer Sie wollen, wann immer Sie wollen und so lange Sie wollen“

Case studies oder Fallmethode

Die Fallmethode ist das am weitesten verbreitete Lernsystem an den besten Wirtschaftshochschulen der Welt. Sie wurde 1912 entwickelt, damit Studenten der Rechtswissenschaften das Recht nicht nur auf der Grundlage theoretischer Inhalte erlernten, sondern auch mit realen komplexen Situationen konfrontiert wurden. Auf diese Weise konnten sie fundierte Entscheidungen treffen und Werturteile darüber fällen, wie diese zu lösen sind. Sie wurde 1924 als Standardlehrmethode in Harvard etabliert.

Bei diesem Lehrmodell ist es der Student selbst, der durch Strategien wie *Learning by doing* oder *Design Thinking*, die von anderen renommierten Einrichtungen wie Yale oder Stanford angewandt werden, seine berufliche Kompetenz aufbaut.

Diese handlungsorientierte Methode wird während des gesamten Studiengangs angewandt, den der Student bei TECH absolviert. Auf diese Weise wird er mit zahlreichen realen Situationen konfrontiert und muss Wissen integrieren, recherchieren, argumentieren und seine Ideen und Entscheidungen verteidigen. All dies unter der Prämisse, eine Antwort auf die Frage zu finden, wie er sich verhalten würde, wenn er in seiner täglichen Arbeit mit spezifischen, komplexen Ereignissen konfrontiert würde.



Relearning-Methode

Bei TECH werden die *case studies* mit der besten 100%igen Online-Lernmethode ergänzt: *Relearning*.

Diese Methode bricht mit traditionellen Lehrmethoden, um den Studenten in den Mittelpunkt zu stellen und ihm die besten Inhalte in verschiedenen Formaten zu vermitteln. Auf diese Weise kann er die wichtigsten Konzepte der einzelnen Fächer wiederholen und lernen, sie in einem realen Umfeld anzuwenden.

In diesem Sinne und gemäß zahlreicher wissenschaftlicher Untersuchungen ist die Wiederholung der beste Weg, um zu lernen. Aus diesem Grund bietet TECH zwischen 8 und 16 Wiederholungen jedes zentralen Konzepts innerhalb ein und derselben Lektion, die auf unterschiedliche Weise präsentiert werden, um sicherzustellen, dass das Wissen während des Lernprozesses vollständig gefestigt wird.

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.



Ein 100%iger virtueller Online-Campus mit den besten didaktischen Ressourcen

Um ihre Methodik wirksam anzuwenden, konzentriert sich TECH darauf, den Studenten Lehrmaterial in verschiedenen Formaten zur Verfügung zu stellen: Texte, interaktive Videos, Illustrationen und Wissenskarten, um nur einige zu nennen. Sie alle werden von qualifizierten Lehrkräften entwickelt, die ihre Arbeit darauf ausrichten, reale Fälle mit der Lösung komplexer Situationen durch Simulationen, dem Studium von Zusammenhängen, die für jede berufliche Laufbahn gelten, und dem Lernen durch Wiederholung mittels Audios, Präsentationen, Animationen, Bildern usw. zu verbinden.

Die neuesten wissenschaftlichen Erkenntnisse auf dem Gebiet der Neurowissenschaften weisen darauf hin, dass es wichtig ist, den Ort und den Kontext, in dem der Inhalt abgerufen wird, zu berücksichtigen, bevor ein neuer Lernprozess beginnt. Die Möglichkeit, diese Variablen individuell anzupassen, hilft den Menschen, sich zu erinnern und Wissen im Hippocampus zu speichern, um es langfristig zu behalten. Dies ist ein Modell, das als *Neurocognitive context-dependent e-learning* bezeichnet wird und in diesem Hochschulstudium bewusst angewendet wird.

Zum anderen, auch um den Kontakt zwischen Mentor und Student so weit wie möglich zu begünstigen, wird eine breite Palette von Kommunikationsmöglichkeiten angeboten, sowohl in Echtzeit als auch zeitversetzt (internes Messaging, Diskussionsforen, Telefondienst, E-Mail-Kontakt mit dem technischen Sekretariat, Chat und Videokonferenzen).

Darüber hinaus wird dieser sehr vollständige virtuelle Campus den Studenten der TECH die Möglichkeit geben, ihre Studienzeiten entsprechend ihrer persönlichen Verfügbarkeit oder ihren beruflichen Verpflichtungen zu organisieren. Auf diese Weise haben sie eine globale Kontrolle über die akademischen Inhalte und ihre didaktischen Hilfsmittel, in Übereinstimmung mit ihrer beschleunigten beruflichen Weiterbildung.



Der Online-Studienmodus dieses Programms wird es Ihnen ermöglichen, Ihre Zeit und Ihr Lerntempo zu organisieren und an Ihren Zeitplan anzupassen“

Die Wirksamkeit der Methode wird durch vier Schlüsselergebnisse belegt:

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

Die von ihren Studenten am besten bewertete Hochschulmethodik

Die Ergebnisse dieses innovativen akademischen Modells lassen sich an der Gesamtzufriedenheit der Absolventen der TECH ablesen.

Die Studenten bewerten die pädagogische Qualität, die Qualität der Materialien, die Struktur und die Ziele der Kurse als ausgezeichnet. Es überrascht nicht, dass die Einrichtung im global score Index mit 4,9 von 5 Punkten die von ihren Studenten am besten bewertete Universität ist.

Sie können von jedem Gerät mit Internetanschluss (Computer, Tablet, Smartphone) auf die Studieninhalte zugreifen, da TECH in Sachen Technologie und Pädagogik führend ist.

Sie werden die Vorteile des Zugangs zu simulierten Lernumgebungen und des Lernens durch Beobachtung, d. h. Learning from an expert, nutzen können.



In diesem Programm stehen Ihnen die besten Lehrmaterialien zur Verfügung, die sorgfältig vorbereitet wurden:



Studienmaterial

Alle didaktischen Inhalte werden von den Fachkräften, 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 ein audiovisuelles Format übertragen, das unsere Online-Arbeitsweise mit den neuesten Techniken ermöglicht, die es uns erlauben, Ihnen eine hohe Qualität in jedem der Stücke zu bieten, die wir Ihnen zur Verfügung stellen werden.



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.



Interaktive Zusammenfassungen


Wir präsentieren die Inhalte auf attraktive und dynamische Weise in multimedialen Pillen, Audios, Videos, Bildern, Diagrammen und konzeptionellen Karten enthalten, um das Wissen zu festigen.


Dieses einzigartige System für die Präsentation multimedialer Inhalte wurde von Microsoft als „Europäische Erfolgsgeschichte“ ausgezeichnet.



Weitere Lektüren

Aktuelle Artikel, Konsensdokumente, internationale Leitfäden... In unserer virtuellen Bibliothek haben Sie Zugang zu allem, was Sie für Ihre Ausbildung benötigen.





Case Studies



Testing & Retesting



Meisterklassen



Kurzanleitungen zum Vorgehen



07

Lehrkörper

Dieser Weiterbildende Masterstudiengang zeichnet sich durch einen Lehrkörper aus, der sich aus international anerkannten Fachleuten auf dem Gebiet der Pharmakologie, der künstlichen Intelligenz und der im Gesundheitssektor angewandten Technologie zusammensetzt. Jeder von ihnen ist hoch qualifiziert und verfügt über umfangreiche Erfahrungen sowohl in der Wissenschaft als auch in der Industrie, was eine praxisnahe, aktuelle und zukunftsweisende Fortbildung garantiert. Die Mentoren verfügen nicht nur über einen soliden theoretischen Hintergrund, sondern bringen auch reale Fälle und Kenntnisse mit, die direkt auf die neuesten Markttrends angewendet werden.



“

Die hochqualifizierten Lehrkräfte von TECH sorgen nicht nur für eine hervorragende Fortbildung, sondern auch für eine bereichernde akademische Erfahrung“

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 an 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
- ♦ Kommunalen Ernährungsberater und Diätassistent
- ♦ Gemeinschaftsapotheker
- ♦ Forscher
- ♦ Masterstudiengang in Ernährung und Gesundheit an der Offenen Universität von Katalonien
- ♦ Masterstudiengang in Psychopharmakologie an der Universität von Valencia
- ♦ Hochschulabschluss in Pharmazie an der Universität Complutense von Madrid
- ♦ Ernährungsberater-Diätassistent von der Europäischen Universität Miguel de Cervantes

Hr. Del Rey Sánchez, Alejandro

- ♦ Verantwortlich für die Umsetzung von Programmen zur Verbesserung der taktischen Versorgung in Notfällen
- ♦ Hochschulabschluss in Ingenieurwesen für industrielle Organisation
- ♦ Zertifizierung in *Big Data* und *Business Analytics*
- ♦ Zertifizierung in Microsoft Excel Advanced, VBA, KPI und DAX
- ♦ Zertifizierung in CIS Telekommunikation und Informationssysteme

Fr. Del Rey Sánchez, Cristina

- ♦ Verwalterin für Talentmanagement bei Securitas Seguridad España, SL
- ♦ Koordinatorin von Zentren für außerschulische Aktivitäten
- ♦ Unterstützungsunterricht und pädagogische Interventionen mit Schülern der Grund- und Sekundarstufe
- ♦ Aufbaustudiengang in Entwicklung, Lehre und Betreuung von e-Learning-Schulungsmaßnahmen
- ♦ Aufbaustudiengang in Frühförderung
- ♦ Hochschulabschluss in Pädagogik an der Universität Complutense von Madrid

Hr. Martín-Palomino Sahagún, Fernando

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

Dr. Carrasco González, Ramón Alberto

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

08

Qualifizierung

Der Weiterbildender Masterstudiengang in Künstliche Intelligenz in der Pharmazie garantiert neben der präzisesten und aktuellsten Fortbildung auch den Zugang zu einem von der TECH Global University ausgestellten Diplom.



“

*Schließen Sie dieses Programm erfolgreich ab
und erhalten Sie Ihren Universitätsabschluss
ohne lästige Reisen oder Formalitäten”*

Mit diesem Programm erwerben Sie den von **TECH Global University**, der größten digitalen Universität der Welt, bestätigten eigenen Titel **Weiterbildender Masterstudiengang in Künstliche Intelligenz in der Pharmazie**

TECH Global University ist eine offizielle europäische Universität, die von der Regierung von Andorra (**Amtsblatt**) öffentlich anerkannt ist. Andorra ist seit 2003 Teil des Europäischen Hochschulraums (EHR). Der EHR ist eine von der Europäischen Union geförderte Initiative, die darauf abzielt, den internationalen Ausbildungsrahmen zu organisieren und die Hochschulsysteme der Mitgliedsländer dieses Raums zu vereinheitlichen. Das Projekt fördert gemeinsame Werte, die Einführung gemeinsamer Instrumente und die Stärkung der Mechanismen zur Qualitätssicherung, um die Zusammenarbeit und Mobilität von Studenten, Forschern und Akademikern zu verbessern.


Dieser eigene Abschluss der **TECH Global University** ist ein europäisches Programm zur kontinuierlichen Weiterbildung und beruflichen Fortbildung, das den Erwerb von Kompetenzen in seinem Wissensgebiet garantiert und dem Lebenslauf des Studenten, der das Programm absolviert, einen hohen Mehrwert verleiht.

Titel: **Weiterbildender Masterstudiengang in Künstliche Intelligenz in der Pharmazie**

Modalität: **online**

Dauer: **12 Monate**

Akkreditierung: **90 ECTS**



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



Weiterbildender
Masterstudiengang
Künstliche Intelligenz
in der Pharmazie

- » Modalität: online
- » Dauer: 12 Monate
- » Qualifizierung: TECH Global University
- » Akkreditierung: 90 ECTS
- » Zeitplan: in Ihrem eigenen Tempo
- » Prüfungen: online

Weiterbildender Masterstudiengang Künstliche Intelligenz in der Pharmazie