

**Satzung zur Änderung der Satzung
zur Durchführung von Zertifikatsstudien
an der Ostbayerischen Technischen Hochschule Regensburg**

Vom 12. Juni 2024

Aufgrund von Art. 9 Satz 1 in Verbindung mit Art. 80 Abs. 1 Satz 1 und Art. 84 Abs. 2 Satz 1 des Bayerischen Hochschulinnovationsgesetzes (BayHIG) vom 5. August 2022 (GVBl. S. 414, BayRS 2210-1-3-WK), das zuletzt durch § 2 des Gesetzes vom 24. Juli 2023 (GVBl. S. 455) geändert worden ist, erlässt die Ostbayerische Technische Hochschule Regensburg (Hochschule) folgende Satzung:

§ 1

Die Satzung zur Durchführung von Zertifikatsstudien an der Hochschule vom 3. September 2020 wird wie folgt geändert:

Die Anlage 2 wird durch folgende zusätzliche Seiten in der Anlage ergänzt.

§ 2

Diese Satzung tritt am Tage nach der Bekanntmachung in Kraft.

Ausgefertigt aufgrund des Beschlusses des Senats der Hochschule vom 23. Mai 2024 und der rechtsaufsichtlichen Genehmigung durch den Präsidenten der Ostbayerischen Technischen Hochschule Regensburg.

Regensburg, 12. Juni 2024

Prof. Dr. Ralph Schneider
Präsident

Anlage

2. Künstliche Intelligenz

2.1 Qualifikationsvoraussetzungen

Bachelorabschluss oder vergleichbarer Studienabschluss (technisch oder nicht technisch) mit einschlägiger Berufserfahrung im mathematisch-technischem Bereich)

2.2 Modulbeschreibung Künstliche Intelligenz

Wissenschaftliche Leitung		
Prof. Dr. Frank Herrmann		
Lehrform		
seminaristischer Unterricht mit Übungen		
Lehrumfang [UE]	Lehrsprache	Arbeitsaufwand [ECTS-Credits]
150 (53 Präsenz, 97 Eigenstudium)	deutsch	5
Studien- und Prüfungsleistung		
schriftliche Prüfung		
Zugelassene Hilfsmittel für Leistungsnachweis		
nicht-programmierbarer Taschenrechner; keine weiteren Hilfsmittel		
Inhalte und Qualifikationsziele		
siehe Beschreibungen der Lehrveranstaltungen		
Lernziele: Fachkompetenz		
siehe Beschreibungen der Lehrveranstaltungen		
Lernziele: Persönliche Kompetenz		
siehe Beschreibungen der Lehrveranstaltungen		
Lehrveranstaltungen		
<ul style="list-style-type: none"> • Grundlagen der Bildverarbeitung • Industrielle Anwendungsfälle • KI-basierte Datenverarbeitung und Maschinelles Lernen • Machine Learning Operations (MLOps) • Machine Learning (Theorie) • Python und PyTorch 		

2.3 Lehrveranstaltungen

2.3.1 Grundlagen der Bildverarbeitung

Lehrveranstaltung		LV-Kurzbezeichnung
Grundlagen der Bildverarbeitung		
Lehrende/r / Dozierende/r		
Prof. Dr. Jürgen Frikel		
Präsenzstudium [UE]	Eigenstudium [UE]	
10	18	
Inhalte und Qualifikationsziele		
<ul style="list-style-type: none"> • Digitale Bilder: Einführung und Begriffsbildung, Bildmodelle und grundlegende Konzepte (wie Sampling, Quantisierung, Interpolation etc.) • Bildarithmetik und Punktoperationen (homogen und inhomogen) mit Anwendungen zur Bildverbesserung • Geometrische Transformationen • Statistische Kenngrößen und Histogramme • Einführung in statistische Bildanalyse und Anwendung zur Kontrastverbesserung (Histogrammausgleich) • Schwellwertverfahren (global und adaptiv) • Praxisbeispiele zur Bildsegmentierung (Binärisierung) • Lineare Filter: Typen, Eigenschaften, Faltung, Anwendungsbereiche • Kantendetektion 		
Lernziele: Fachkompetenz		
<p>Nach der erfolgreichen Absolvierung der Lehrveranstaltung sind die Teilnehmenden in der Lage,</p> <ul style="list-style-type: none"> • zentrale Konzepte der Bildverarbeitung zu kennen und zu verstehen (1), (3) • grundlegende Algorithmen der Bildverarbeitung zu kennen, zu verstehen und zu implementieren (1), (2) • geeignete Lösungsstrategien für einfache Problemstellungen der Bildverarbeitung zu entwickeln (3) • Bildverarbeitungsmethoden kritisch zu hinterfragen und deren Grenzen zu erkennen (2) • weiterführende Literatur selbständig zu verstehen, anzuwenden und zu bewerten (3). 		
Lernziele: Persönliche Kompetenz		
<p>Nach der erfolgreichen Absolvierung der Lehrveranstaltung sind die Teilnehmenden in der Lage,</p> <ul style="list-style-type: none"> • die gelernten Inhalte in korrekter Fachsprache zu kommunizieren (1) • fachliche Diskussionen zu Themen der Bildverarbeitung zu führen (1), (2) • kreativ und lösungsorientiert zu denken (im Bereich der Bildverarbeitung) (3) • im Team an Problemen der Bildverarbeitung zu arbeiten (3). 		
Angebotene Lehrunterlagen		
Kurzschrift (Folien) mit integrierten Übungen		
Lehrmedien		
Tafel, Beamer, Laptop		
Literatur		
<ul style="list-style-type: none"> • Burger, Wilhelm und Mark James Burge (2015). Digitale Bildverarbeitung: Eine algorithmische Einführung mit Java. 3. Aufl. X.media.press. Berlin: Springer Vieweg. ISBN: 978-3-642-04603-2. DOI: 10.1007/978-3-642-04604-9. • Gonzalez, Rafael C. und Richard E. Woods (2008). Digital image processing. Prentice Hall. 		
Weitere Informationen zur Lehrveranstaltung		
Grundkenntnisse in Matlab sind vorteilhaft.		

2.3.2 Industrielle Anwendungsfälle

Lehrveranstaltung		LV-Kurzbezeichnung
Industrielle Anwendungsfälle		
Lehrende/r / Dozierende/r		
Prof. Dr. Michael Colombo		
Präsenzstudium []	Eigenstudium [UE]	
5	10	
Inhalte und Qualifikationsziele		
<p>Die Vorlesung „Industrielle Anwendungsfälle“ schafft eine Brücke zwischen den Grundlagen des maschinellen Lernens und seiner Anwendung in der industriellen Praxis. Sie gibt dazu einen Überblick von Sensordaten-basierten Anwendungsgebieten und zeigt, wie typische Herausforderungen in Bezug auf die Daten angegangen werden können, insbesondere die Konstruktion geeigneter Merkmale und der Umgang mit fehlenden Zielwerten („Labels“). Dazu werden Ansätze des überwachten, unüberwachten und verstärkenden maschinellen Lernens betrachtet.</p> <p>Inhalte:</p> <ul style="list-style-type: none"> • <u>Übersicht industrieller Anwendungsfälle</u>: Wertschöpfungskette der fertigen Industrie, Fokusbereich Produktion, Beispiele für sensorbasierte Anwendungsfälle • <u>Vorausschauende Wartung</u>: geschäftlicher Kontext und Lösungs idee, Generation von Testbett-Daten für das überwachte Lernen, Konstruktion geeigneter Merkmale aus den Sensordaten, überwachtes „Deep Learning“, unüberwachtes Lernen mit Autoencodern • <u>Robotik</u>: Cyber-physische Systeme, verstärkendes Lernen, maschinelles Lernen mit dem digitalen Zwilling 		
Lernziele: Fachkompetenz		
<p>Nach der erfolgreichen Absolvierung der Lehrveranstaltung sind die Teilnehmenden in der Lage,</p> <ul style="list-style-type: none"> • typische Anwendungsfälle für den Einsatz maschinellen Lernens in der fertigen Industrie und speziell der Produktion erklären zu können • konkrete KI-Anwendungsfälle im eigenen Umfeld anhand von Analogien zu finden • passende Ansätze des maschinellen Lernens zu identifizieren, um mit den vielen praktischen Herausforderungen in der Arbeit mit Daten umzugehen. 		
Lernziele: Persönliche Kompetenz		
<p>Nach der erfolgreichen Absolvierung der Lehrveranstaltung sind die Teilnehmenden in der Lage,</p> <ul style="list-style-type: none"> • KI-Ansätze in die eigene Umgebung zu transferieren • KI-Ideen bewerten zu können (Urteilsfähigkeit) • eigenständig bei der Konzeption und Umsetzung eigener KI-Anwendungen zu handeln. 		
Angebotene Lehrunterlagen		
Skript (Folien) mit integrierten Übungen		
Lehrmedien		
Beamer, Laptop, Whiteboard/Flipchart		
Literatur		
P. Larranaga et. al., Industrial Applications of Machine Learning, CRC Press, 2020		
Weitere Informationen zur Lehrveranstaltung		

2.3.3 KI-basierte Datenverarbeitung und Maschinelles Lernen

Lehrveranstaltung		LV-Kurzbezeichnung
KI-basierte Datenverarbeitung und Maschinelles Lernen		
Lehrende/r / Dozierende/r		
Prof. Dr. Timo Baumann		
Präsenzstudium [UE]	Eigenstudium [UE]	
11	20	
Inhalte und Qualifikationsziele		
<ul style="list-style-type: none"> • Sequenzdaten, ihre Eigenschaften (zeitdiskret vs. kontinuierlich, wertdiskret vs. kontinuierlich, atomar vs. zusammengesetzt) und praktische Vorkommen • Abgrenzung zu strukturierten Daten und Abwägungen in der Modellierung • Neuronale Netze, Berechnungsgraphen und Funktion von NN-Toolkits (PyTorch etc.) • Rekurrente neuronale Netze zur Modellierung von Sequenzdaten und die resultierenden Berechnungsgraphen (auch im Vergleich zu Konvolutionsnetzen) • Überwachte Sequenzlernprobleme: $n:n$, $n:1$, $1:n$, $n:m$ • Klassifikation von Sequenzen am Beispiel Textverarbeitung • Transduktion/Tagging mit RNN am Beispiel Named-Entity-Recognition • Generative Sequenzmodellierung am Beispiel Sprachmodelle • Autoregressives Decoding zur Sequenzgenerierung • Encoder-Decoder-Architektur am Beispiel maschinelle Übersetzung • Embedding und Tokenisierung für wertdiskrete Eingaben • Fensterung und Taktung für zeitkontinuierliche Signale • Bi-RNNs und Stacked RNNs, alternative rekurrente Einheiten (LSTM und GRU) • Wege des Lernsignals und Flaschenhälse; Aufmerksamkeitssteuerung • Transformer: Aufmerksamkeitssteuerung und Positionskodierung anstatt Rekurrenz • weitere aktuelle Themen zum Sequenzlernen in aktuellen LLMs 		
Lernziele: Fachkompetenz		
<p>Nach der erfolgreichen Absolvierung der Lehrveranstaltung sind die Teilnehmenden in der Lage,</p> <ul style="list-style-type: none"> • Sequenzdaten grundlegend zu verstehen, relevante Eigenschaften zu kennen und bei der Modellierung abzuwägen • die Typen von Sequenzlernproblemen und ihre Unterscheidung zu kennen • neuronale Netze und Berechnungsgraphen und ihren Einsatz bei Sequenzlernproblemen vertieft zu verstehen, insbesondere rekurrente Netze und Aufmerksamkeitssteuerung • mit neuronalen Netz-Toolkits (z. B. PyTorch) Sequenzlernproblemen zu lösen. 		
Lernziele: Persönliche Kompetenz		
<p>Nach der erfolgreichen Absolvierung der Lehrveranstaltung sind die Teilnehmenden in der Lage,</p> <ul style="list-style-type: none"> • eigenständig theoretische und angewandte Inhalte anhand von Vorlesungsfolien nachzuarbeiten • Code-Beispiele zu analysieren und Code und Beschreibungen in Vorlesungsfolien oder der Literatur miteinander in Beziehung zu setzen • unterschiedliche Herangehensweisen bei der Modellierung und Lösung von Sequenzlernproblemen zu diskutieren. 		
Angebotene Lehrunterlagen		
Folien und Übungen in Jupyter-Notebooks		
Lehrmedien		
Beamer, Tafel, interaktive Übungsbearbeitung auf dem JupyterHub		
Literatur		
<ul style="list-style-type: none"> • Dan Jurafsky, James Martin: Speech and Language Processing, 3rd ed. draft, 2023. • Yoav Goldberg: Neural Network Methods for Natural Language Processing, Springer, 2017. • Ian Goodfellow, Yoshua Bengio, Aaron Courville: Deep Learning, MIT Press, 2016. 		
Weitere Informationen zur Lehrveranstaltung		

2.3.4 Machine Learning Operations (MLOps)

Lehrveranstaltung		LV-Kurzbezeichnung
Machine Learning Operations (MLOps)		
Lehrende/r / Dozierende/r		
Prof. Dr. Michael Colombo		
Präsenzstudium [UE]		Eigenstudium [UE]
6		11
Inhalte und Qualifikationsziele		
<p>Die Lehrveranstaltung schärft das Bewusstsein für die Herausforderungen des Wegs von KI-Modellen aus den Laboren in die Praxis sowie für die Voraussetzungen eines dauerhaften und zuverlässigen Betriebs dieser Modelle. Sie gibt dazu einen Überblick des von den DevOps Prinzipien der Software-Entwicklung inspirierten MLOps Zyklus.</p> <p>Inhalte:</p> <ul style="list-style-type: none"> • <u>Konzept MLOps</u>: Vorgehensweisen Data Mining und DevOps, Transfer auf Entwicklung und Betrieb von KI-Modellen • <u>MLOps Zyklus</u>: Nutzenbetrachtung als Ausgangspunkt, Integration des KI-Modells in die Gesamt-Architektur, agiles Vorgehen in Datenprojekten, KI-Engineering als Voraussetzung für den produktiven Betrieb, Replizierbarkeit von Trainingsergebnissen, automatisiertes Deployment, Monitoring der KI-Modelle im Betrieb 		
Lernziele: Fachkompetenz		
<p>Nach der erfolgreichen Absolvierung der Lehrveranstaltung sind die Teilnehmenden in der Lage,</p> <ul style="list-style-type: none"> • wesentliche Unterschiede zum Data Mining einerseits und zur Software-Entwicklung andererseits im Entwicklungsvorgehen von KI-Modellen umzusetzen, um produktionsreife KI-Modelle zu erstellen • Anforderungen an den zukünftigen Betrieb der KI-Modelle schon in der Entwicklung zu berücksichtigen • KI-Modelle zügig in die Produktion zu bringen, ihre Leistung durchgehend zu überwachen und möglichst laufend zu verbessern. 		
Lernziele: Persönliche Kompetenz		
<p>Nach der erfolgreichen Absolvierung der Lehrveranstaltung sind die Teilnehmenden in der Lage,</p> <ul style="list-style-type: none"> • KI-Ansätze in die eigene Umgebung zu transferieren • KI-Ideen bewerten zu können (Urteilsfähigkeit) • eigenständig bei der Konzeption, Umsetzung und dem Betrieb eigener KI-Anwendungen zu handeln. 		
Angebotene Lehrunterlagen		
Skript (Folien) mit integrierten Übungen		
Lehrmedien		
Beamer, Laptop, Whiteboard/Flipchart		
Literatur		
<ul style="list-style-type: none"> • M. Treveil et al, Introducing MLOps: How to Scale Machine Learning in the Enterprise, O'Reilly, 2021 • N. Gift, A. Deza, Practical MLOps: Operationalizing Machine Learning Models, O'Reilly, 2021 		
Weitere Informationen zur Lehrveranstaltung		

2.3.5 Machine Learning (Theorie)

Lehrveranstaltung		LV-Kurzbezeichnung
Machine Learning (Theorie)		
Lehrende/r / Dozierende/r		
Prof. Dr. Carsten Kern		
Präsenzstudium [UE]		Eigenstudium [UE]
11		20
Inhalte und Qualifikationsziele		
<ul style="list-style-type: none"> • Grundlegende Einordnung von Machine Learning (ML) im Bereich künstliche Intelligenz • Definition grundlegender Begriffe (z. B. überwachtes, unüberwachtes und verstärkendes Lernen, Offline- und Online-Learning, Test- vs. Trainingsdaten, Regression vs. Klassifikation, Over- und Underfitting) • Lineare und logistische Regression • Entscheidungsbäume und Random Forests für Klassifikation und Regression • Nachbarschaftsbasierte Verfahren (z. B. k-Nearest-Neighbors-Algorithmus) • Clusteringverfahren (z. B. k-Means-Algorithmus) • Neuronale Netze (Feed-Forward-Netze, Einstieg in CNNs) 		
Lernziele: Fachkompetenz		
<p>Nach der erfolgreichen Absolvierung der Lehrveranstaltung sind die Teilnehmenden in der Lage,</p> <ul style="list-style-type: none"> • die grundlegenden Algorithmen und Methoden des maschinellen Lernens zu benennen und ihre Funktionsweise zu verstehen (1), (2) • die zugrundeliegenden mathematischen Konzepte und Aussagen zu benennen und ihre Implikationen für ML zu verstehen (1), (2) • die ML-Algorithmen der richtigen Problemklasse zuzuordnen (1) • die ML-Algorithmen auf Probleme einfacher und mittlerer Komplexität anzuwenden (3). 		
Lernziele: Persönliche Kompetenz		
<p>Nach der erfolgreichen Absolvierung der Lehrveranstaltung sind die Teilnehmenden in der Lage,</p> <ul style="list-style-type: none"> • die gelernten Inhalte den Kommilitoninnen und Kommilitonen zu kommunizieren (1) • fachliche Diskussion zu ML-Themen zu führen (1), (2) • selbständig weiterführende Literatur zu lesen und kritisch zu bewerten (3). 		
Angebotene Lehrunterlagen		
Folien, Übungsblätter inkl. Codegerüste, Jupyter-Notebooks		
Lehrmedien		
Tafel, Beamer, Laptop		
Literatur		
<ul style="list-style-type: none"> • Künstliche Intelligenz – Ein moderner Ansatz, S. Russel und P. Norvig, Pearson, 3. Auflage, 2012 • Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, A. Geron, O'Reilly, 3. Auflage, 2022 • Maschinelles Lernen – Grundlagen und Algorithmen in Python, J. Frochte, Hanser Verlag, 3. Auflage, 2020 • Data Mining – Practical Machine Learning Tools and Techniques, I. Witten et al., Morgan Kaufmann, 4. Auflage, 2016 		
Weitere Informationen zur Lehrveranstaltung		

2.3.6 Python und PyTorch

Lehrveranstaltung		LV-Kurzbezeichnung
Python und PyTorch		
Lehrende/r / Dozierende/r		
David Rauber		
Präsenzstudium [UE]		Eigenstudium [UE]
10		18
Inhalte und Qualifikationsziele		
<ul style="list-style-type: none"> • Einführung in Python <ul style="list-style-type: none"> - Grundlegende Einführung in die Programmiersprache Python - Konzepte der objektorientierten Programmierung • Verwendung von Bibliotheken <ul style="list-style-type: none"> - Installieren und Importieren von Bibliotheken - Grundlegende Bibliotheken zum Einlesen, Verarbeiten, Visualisieren und Speichern von Daten (NumPy, Pandas, OpenCV, Matplotlib etc.) • Einführung in PyTorch <ul style="list-style-type: none"> - Entwickeln eigener Neuronaler Netzwerke - Laden vortrainierter Neuronaler Netzwerke - Aufbereitung der Trainingsdaten - Training eines Neuronalen Netzwerkes 		
Lernziele: Fachkompetenz		
<p>Nach der erfolgreichen Absolvierung der Lehrveranstaltung sind die Teilnehmenden in der Lage,</p> <ul style="list-style-type: none"> • einfache Python Skripte zu entwickeln (2) • Pakete zu installieren und zu verwenden (1) • Daten verschiedener Modalität einzulesen, zu verarbeiten und zu speichern (2) • Daten für das Training von Neuronalen Netzen aufzubereiten (2) • einfache Neuronale Netze zur Klassifikation zu erstellen, zu trainieren und anzuwenden (3) • Ergebnisse zu visualisieren (2) • die Leistung verschiedener trainierter Modelle zu bewerten und zu vergleichen (2) • Metriken für die Bewertung des Trainings zu verwenden, zu speichern und zu bewerten (2). 		
Lernziele: Persönliche Kompetenz		
<p>Nach der erfolgreichen Absolvierung der Lehrveranstaltung sind die Teilnehmenden in der Lage,</p> <ul style="list-style-type: none"> • Fähigkeiten von Deep Learning Techniken realistischer einzuschätzen (1) • ähnliche Problemstellungen eigenständig zu behandeln (3) • sich eigenständig in weiterführende Techniken einzuarbeiten (2). 		
Angebotene Lehrunterlagen		
Jupyter Notebooks		
Lehrmedien		
Rechner, Beamer, Tafel		
Literatur		
Ian Goodfellow, Yoshua Bengio and Aaron Courville. Deep Learning. MIT Press, 2016		
Weitere Informationen zur Lehrveranstaltung		