

Satzung zur Durchführung von Zertifikatsstudien an der Ostbayerischen Technischen Hochschule Regensburg

vom 3. September 2020

geändert durch Satzung vom
12. Juni 2024

Konsolidierte (nicht amtliche) Fassung in Form der Änderungssatzung vom 12. Juni 2024¹⁾

Aufgrund von Art. 13 Abs. 1 Satz 2, Art. 4 Abs. 4, Art. 58 Abs. 1 Satz 1 und Art. 61 Abs. 2, Abs. 8 Satz 2 des Bayerischen Hochschulgesetzes (BayHSchG, GVBl. S. 245) in der derzeit gültigen Fassung erlässt die Ostbayerische Technische Hochschule Regensburg (Hochschule) folgende Satzung:

§ 1 Zweck der Satzung

Diese Satzung regelt die Struktur, die Prüfungsanforderungen und das Prüfungsverfahren für die in der Anlage beschriebenen Zertifikatsstudien an der Hochschule.

§ 2 Studienziel

Ziel der Zertifikatsstudien ist es, weiterführende wissenschaftliche oder berufliche Qualifikation zu erlangen. Sie ermöglichen den Teilnehmenden, sich mit arbeitsmarktrelevanten Fach-, Methoden- und Sozialkompetenzen in einem bestimmten Bereich auseinanderzusetzen. Die an der Hochschule angebotenen Zertifikatsstudien werden in der Anlage aufgeführt.

§ 3 Qualifikationsvoraussetzung

- (1) Die konkreten Qualifikationsvoraussetzungen sowie das Bewerbungsverfahren sind für die jeweiligen Angebote in der Anlage definiert. Grundsätzlich stehen Zertifikatsstudien neben Bewerberinnen und Bewerbern mit abgeschlossenem Hochschulstudium und anschließender Berufserfahrung auch solchen Bewerberinnen und Bewerbern mit Berufserfahrung offen, die die für die Teilnahme erforderliche Eignung im Beruf oder auf andere Weise erworben haben.
- (2) Die Anmeldung erfolgt entsprechend den Angaben für die einzelnen Zertifikatsstudien auf der Homepage des Zentrums für Weiterbildung und Wissensmanagement an der Hochschule.
- (3) Eine Immatrikulation der Teilnehmenden erfolgt nicht.

¹⁾ Diese Satzung tritt am 13. Juni 2021 in Kraft.

§ 4 Struktur der Zertifikatsstudien, Bestehen

- (1) Die einzelnen Angebote der Zertifikatsstudien finden innerhalb eines oder mehrerer Semester statt. Die Lehrveranstaltungen können auch in Form von Blockveranstaltungen und/oder (mehreren) Wochenendterminen stattfinden. Die Angebote sind in ein oder mehrere Module unterteilt.
- (2) Für die erbrachten Studienleistungen werden ECTS-Credits²⁾ vergeben.
- (3) Das Zertifikatsstudium ist bestanden, wenn alle Modulprüfungen erfolgreich abgelegt wurden.

§ 5 Anrechnung

Die in Zertifikatsstudien erworbenen Credits können unter Umständen in einem späteren Bachelor- oder Masterstudiengang angerechnet werden. Ob eine Anrechnung möglich ist, entscheidet im Einzelfall die zuständige Prüfungskommission.

§ 6 Prüfungsleistungen

- (1) Die Module der Zertifikatsstudien schließen mit mindestens einer Prüfungsleistung ab. Die im jeweiligen Zertifikatsstudium geforderten Prüfungsleistungen sind in der Anlage zu dieser Satzung festgelegt.
- (2) Die Prüfungstermine und Prüfungsmodalitäten werden von den Dozierenden rechtzeitig bekannt gegeben.

§ 7 Täuschung, Ablaufstörung

- (1) Mit der Note „nicht ausreichend“ oder dem Prädikat „ohne Erfolg abgelegt“ werden Prüfungsleistungen von Teilnehmenden bewertet, die bei Abnahme der Prüfung eine Täuschungshandlung versucht oder begangen oder durch schuldhaftes Verhalten einen ordnungsgemäßen Ablauf der Prüfung unmöglich gemacht haben.
- (2) Täuschungshandlungen sind insbesondere die Benutzung unerlaubter Hilfsmittel, die Verwendung erlaubter Hilfsmittel mit unzulässigen Ergänzungen, die Kommunikation mit anderen Prüfungsteilnehmenden oder Dritten oder der Einsatz mobiler Kommunikationsgeräte.

§ 8 Bewertung der Leistungen

- (1) Soweit Prüfungsleistungen mit Noten bewertet werden, erfolgt die differenzierte Bewertung mit den Notenziffern:

1,0 und 1,3 = sehr gut
1,7; 2,0 und 2,3 = gut
2,7; 3,0 und 3,3 = befriedigend
3,7 und 4,0 = ausreichend und
5,0 = nicht ausreichend.

²⁾ Leistungspunkte nach dem European Credit Transfer and Accumulation System (ECTS), im Folgenden kurz mit Credits bezeichnet.

- (2) Werden Prüfungsleistungen eines Moduls nicht benotet, sondern mit den Prädikaten „mit Erfolg abgelegt“ oder „ohne Erfolg abgelegt“ bewertet, ist dies in der jeweiligen Modulbeschreibung in der Anlage ausgewiesen.

§ 9 Notenbekanntgabe

Die erzielten Ergebnisse der einzelnen Prüfungsleistungen werden unverzüglich nach Feststellung bekannt gegeben.

§ 10 Wiederholung

Nicht bestandene Prüfungsleistungen können jeweils einmal wiederholt werden. Nicht bestandene Prüfungsleistungen sind jeweils am nächsten Termin nach Bekanntgabe der Bewertung der Prüfung erneut abzulegen. Werden sie an diesem Termin nicht abgelegt, gelten sie als endgültig nicht bestanden.

§ 11 Zertifikat

Bei Bestehen des Zertifikatsstudiums wird über die Studien- und Prüfungsleistungen ein Zertifikat nach dem Muster der Hochschule entsprechend der Anlage 1 erteilt.

§ 12 Inkrafttreten und Übergangsbestimmungen

Diese Satzung tritt am Tage nach der Bekanntmachung in Kraft.

Regensburg, 3. September 2020

Prof. Dr. Wolfgang Baier
Präsident

Anlage 2

1. Data Literacy

1.1 Qualifikationsvoraussetzungen:

Abgeschlossenes Bachelorstudium

1.2 Modulbeschreibung Data Literacy

Lehrveranstaltung		LV-Kurzbezeichnung
Data Literacy		DaL
Lehrende/r / Dozierende/r		Wissenschaftliche Leitung
Ghassan Al-Falouji		Prof. Dr. rer. nat. Roland Mandl
Lehrform		
Seminaristischer Unterricht, Online-Konsultationen, praktische Übungen im Unterricht		
Lehrumfang [UE]	Lehrsprache	Arbeitsaufwand [ECTS-Credits]
70 (Block ca. 7 Tage)	Deutsch/Englisch	10
Präsenzstudium	Eigenstudium	
70 h	130 h + 50 h (Projektarbeit) + 50 h (Vertiefung des Wissens anhand von praxisrelevanten Daten)	
Studien- und Prüfungsleistung		
Präsentation und eine schriftliche Projektarbeit		
Zugelassene Hilfsmittel für Leistungsnachweis		
alle		

Inhalte und Qualifikationsziele

- Introduction to Python for data science
 - Basic introduction to the Python programming language
 - Introduction to essential data-science libraries such as NumPy, Pandas, Matplotlib and SciPy
 - Introduction to IPython and Jupyter notebook/lab
- Data Manipulation and Visualization
 - Import different file formats using Python libraries
 - Data cleaning and preprocessing
 - Data representation and visualization
- Feature Engineering
 - Implementation of missing data
 - Exploratory data analysis
 - Features scaling and normalization
 - Features selection
- Applied Machine Learning in Python
 - Categories of Machine Learning
 - Introduction to Scikit-Learn
 - Regression and prediction
 - Linear Regression
 - Gradient Descent (Batch-, Stochastic- and Mini-batch gradient descent)
 - Polynomial Regression
 - The curse of dimensionality
 - Regularized Linear Models
 - Logistic Regression
 - Classification
 - K-Nearest Neighbors
 - Support Vector Machines
 - Model Validation
 - Naive Bayes
 - Decision Trees and Random Forests
 - Dimensionality Reduction
 - Projection and Manifold Learning
 - Principal Component Analysis (PCA)
 - Clustering
 - K-means
 - Hierarchical clustering

Lernziele: Fachkompetenz

Nach der erfolgreichen Absolvierung des Moduls sind die Teilnehmenden in der Lage,

- Daten zu lesen, zu importieren, zu bearbeiten und zu visualisieren (3);
- praktisches Verständnis für Datenverarbeitung (2), Manipulation (2) und statistische Analyse zu entwickeln (1);
- praktisches Verständnis der wesentlichen „supervised-“ und „unsupervised learning“ Algorithmen für „Machine Learning“ zu entwickeln (2);
- Begriffe wie „Features“, „Regression“, „Classification“ and „Clustering“ zu benennen (1) und zu erklären (2);
- praktisches Verständnis verschiedener Regressionsverfahren, Klassifikation und Clustering-Methoden (2) zu entwickeln und geeignete Algorithmen zur Problemlösung anzuwenden (3);
- praktisches Verständnis für den Lebenszyklus des maschinellen Lernens von der Datenverarbeitung bis zum Export eines trainierten Modells für die Anwendung zu entwickeln (2);
- Methoden zur Reduktion der Merkmalsraumdimension wie „Principal Component Analysis“ einzusetzen (3);
- eine geeignete Optimierungsmethode zu verwenden, um ein Modell zu trainieren (3);
- die Leistung verschiedener trainierter Modelle zu bewerten und zu vergleichen (2);
- das Problem des „Curse of Dimensionality“ zu verstehen und das Risiko, ein „overfitted“ oder „biased“ Modell zu trainieren, zu vermeiden;
- praktische Implementierung des Exportieren/Importieren der trainierten Modellpipeline mit der Programmiersprache Python (3);
- Hyper-Parameter eines Lernverfahrens bzw. eines Modells gezielt zu optimieren (3);
- mit den praktischen Daten die geeignete Datenverarbeitung (2), das Feature-Engineering (2) und das Modelltraining auszuwählen (1) und zu implementieren (3).

Lernziele: Persönliche Kompetenz

Nach der erfolgreichen Absolvierung des Moduls sind die Teilnehmenden in der Lage,

- den eigenen Lernfortschritt und Lernbedarf zu analysieren (3) und gegebenenfalls Handlungsweisen daraus abzuleiten (3);
- zielorientiert mit anderen zusammenzuarbeiten (2), deren Interessen und soziale Situation zu erfassen (2), sich mit ihnen rational und verantwortungsbewusst auseinanderzusetzen und zu verständigen (2) sowie die Arbeits- und Lebenswelt mitzugestalten (3);
- wissenschaftlich im Sinne der „Regeln guter wissenschaftlicher Praxis“ zu arbeiten (2);
- fachliche Inhalte darzustellen (2) und vor einem Publikum in korrekter Fachsprache zu präsentieren (2);
- sich in ähnliche Aufgabenstellungen selbständig einzuarbeiten (3).

Angebotene Lehrunterlagen

Skript und Übungen in Jupyter Notebooks, Google Colabs

Lehrmedien

Rechner, Beamer, Tafel

Literatur

- VanderPlas, Jake. Python data science handbook: Essential tools for working with data. O'Reilly Media, Inc., 2016.
- Bruce, Peter, Andrew Bruce, and Peter Gedeck. Practical Statistics for Data Scientists: 50+ Essential Concepts Using R and Python. O'Reilly Media, 2020.
- Bishop, Christopher M. Pattern recognition and machine learning. Springer, 2006.
- Géron, Aurélien. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems. O'Reilly Media, 2019.

Weitere Informationen zur Lehrveranstaltung

Bitte eigenen Rechner mitbringen. Grundkenntnisse in GitLab vorteilhaft, um Inhalte zum/vom OTH-R GitLab-Server zu transferieren.

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"> • Übersicht industrieller Anwendungsfälle: Wertschöpfungskette der fertigen Industrie, Fokusbereich Produktion, Beispiele für sensorbasierte Anwendungsfälle • Vorausschauende Wartung: 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 • Robotik: 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 Flaschenhalse; 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"> • Konzept MLOps: Vorgehensweisen Data Mining und DevOps, Transfer auf Entwicklung und Betrieb von KI-Modellen • MLOps Zyklus: 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 verstärktes 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	