

Deep Learning and Artificial Intelligence

Titel	Deep Learning and Artificial Intelligence	
Typ	Vorlesung mit Übung	
Credits	6 ECTS	
Lehrform/SWS	3V + 2Ü	
Sprache	Englisch	
Modulniveau	Master	
Arbeitsaufwand	Präsenzstunden	75 Stunden
	Eigenstudium	105 Stunden
	Gesamtaufwand	180 Stunden
Angestrebte Lernergebnisse	<p>Die Studierenden haben ein fundiertes Verständnis von maschinellem Lernen mit neuronalen Netzen und wie sie trainiert werden. Insbesondere verstehen die Studenten die Problemstellungen die durch tiefe Netzwerkarchitekturen entstehen und die Lösungsmöglichkeiten für diese Probleme. Des Weiteren kennen die Studierenden die grundlegenden Methoden zum Trainieren autonomer Agenten und können einschätzen welche Technik für welches Anwendungsszenario am besten geeignet ist.</p> <p>Die Studierenden sollen in die Lage versetzt werden eigene Methoden zu entwickeln und diese in gängigen Software frameworks zu implementieren.</p>	
Intended Learning Outcomes	<p>Students have a sound understanding of machine learning with neural networks and how they are trained. In particular, the students understand the problems created by deep network architectures and the solutions to these problems. Furthermore, the students know the basic methods for training autonomous agents and can assess which technique is most suitable for which application scenario.</p> <p>The students are enabled to develop their own methods and implement them in common software frameworks.</p>	
	<p>Grundlagen maschinelles Lernen mit Neuronalen Netzen:</p> <ul style="list-style-type: none"> • Grundlegende Funktionsbausteine • Fehlerfunktionen • Evaluationsmethoden <p>Training neuronaler Netzwerke:</p> <ul style="list-style-type: none"> • Methoden der Optimierung • Berechnungsgraphen • Gradienten und Gradientenabstieg 	

	<ul style="list-style-type: none"> • Backpropagation • Adaptive Lernraten • Initialisierung der Gewichte • Regularisierung • Hyperparameter Tuning <p>Convolutional Neural Networks:</p> <ul style="list-style-type: none"> • Convolutional Layer • Batchnormalization und Dropout • Pooling Operationen • Gängige Architekturen in der Bildverarbeitung <p>Rekurrente Neuronale Netzwerke:</p> <ul style="list-style-type: none"> • Sequenzmodellierung • Backpropagation-through-time Netzwerke • Exploding gradients • Architekturen mit Gating • Attention Mechanismen <p>Bayesian Deep Learning:</p> <ul style="list-style-type: none"> • Verbindung Neuronalen Netzwerken und Bayesianischem Lernen • Arten der Modelunsicherheit • Epistemische oder aleatorische Unsicherheit • Integration von Unsicherheit in Neuronale Netzwerke <p>Representation Learning:</p> <ul style="list-style-type: none"> • Embedings • Auto-Encoder • Restricted Boltzmann Machines • Metric Learning <p>Deep Learning Tools:</p> <ul style="list-style-type: none"> • Hardwareplattformen • Implementierungsframeworks • Verteiltes Training • Model Deployment <p>Generative Modelle:</p> <ul style="list-style-type: none"> • Neuronale Netzwerke zur Verteilungsmodellierung • Variational Autoencoders • Generative Adversarial Networks • Anwendungsbereiche <p>Sequentielle Entscheidungsprobleme:</p> <ul style="list-style-type: none"> • Deterministisches und undeterministische Planungsprobleme
--	---

	<ul style="list-style-type: none"> • Markow Entscheidungsprozesse • Policy Evaluierung und Ableitungen von optimalen Kontrolfunktionen • Lösungen mittels dynamischer Programmierung <p>Modelfrei Ansätze zur Planung</p> <ul style="list-style-type: none"> • Monte-Carlo Lernen • Temporal Difference Learning • Modelfreies Lernen von Policies • On-Policy und Off-Policy Methoden <p>Value Function Approximation:</p> <ul style="list-style-type: none"> • Zustands- und Beobachtungsräume • Approximation der Value Function mittels maschinellem Lernen • Monte-Carlo Lernen mit Funktionsapproximation • Temporal Difference Learning mit Funktionsapproximation <p>Policy Gradienten:</p> <ul style="list-style-type: none"> • Stochastische Policies • Monte-Carlo Policy Gradient Methoden • Actor-Critic Methoden • Kompatible Funktionsapproximationen <p>Wissensgraphen:</p> <ul style="list-style-type: none"> • Wissensgraphen und Ontologien • Lernen auf Wissensgraphen • Ansätze mit Tensorfaktorisierung • Ansätze mit Graph-Embeddings
	<p>Fundamentals of Machine Learning with Neural Networks:</p> <ul style="list-style-type: none"> • basic function blocks • loss functions • evaluation Methods <p>Training of neural networks:</p> <ul style="list-style-type: none"> • optimization methods • computational graph • gradients and gradient descent • backpropagation • adaptive learning rates • weight initialization • regularization • hyper parameter tuning

	<p>Convolutional Neural Networks:</p> <ul style="list-style-type: none"> • convolutional layers • batch normalization and dropout • pooling operations • common architectures in image processing <p>Recurrent neural networks:</p> <ul style="list-style-type: none"> • sequence modeling • backpropagation-through-time networks • exploding and vanishing gradients • architectures with gating • attention mechanisms <p>Bayesian Deep Learning:</p> <ul style="list-style-type: none"> • connection of neural networks and Bayesian learning • types of model uncertainty • epistemic or aleatory uncertainty • integration of uncertainty into neural networks <p>Representation Learning:</p> <ul style="list-style-type: none"> • embedding spaces • auto-encoder • restricted Boltzmann machines • metric learning <p>Deep Learning Tools:</p> <ul style="list-style-type: none"> • hardware platforms • software frameworks • distributed training • model deployment <p>Generative models:</p> <ul style="list-style-type: none"> • neural networks for distribution modeling • variational autencoders • generative adversarial networks • applications <p>Sequential decision problems:</p> <ul style="list-style-type: none"> • deterministic and undeterministic planning problems • Markov decision processes • policy evaluation and derivation of optimal control functions • solutions using dynamic programming <p>Model free approaches to planning</p> <ul style="list-style-type: none"> • Monte Carlo learning • temporal difference Learning • model-free learning of policies • on-policy and off-policy methods
--	---

	<p>Value Function Approximation:</p> <ul style="list-style-type: none"> • state and observation spaces • approximation of the value function with machine learning • Monte Carlo learning with function approximation • temporal difference learning with function approximation <p>Policy Gradients:</p> <ul style="list-style-type: none"> • stochastic policies • Monte Carlo policy gradient methods • Actor-Critic methods • compatible function approximations <p>Knowledge graph:</p> <ul style="list-style-type: none"> • knowledge graphs and ontologies • learning on knowledge graphs • tensor factorization approaches • approaches with graph embeddings
Prüfung	<p>Prüfungsleistung (benotet):</p> <p>- Klausur: 90-180 min</p> <p>Wiederholungsklausur zu Ende des Semesters. Details werden zu Beginn des Moduls bekannt gegeben.</p> <p>In der Klausur weisen die Studierenden nach, inwieweit sie die vorgestellten Prozesse, Modelle und Verfahren verstanden haben, komprimiert wiedergeben und anwenden sowie auf verwandte Problemstellungen übertragen können. In der Klausur werden 7 bis 10 Aufgaben gestellt, die eine eigenständige Anwendung der Prozessdefinition, Modelle und Verfahren aus der Vorlesung erfordern</p>
Examination	<p>Examination requirements (graded):</p> <p>- written exam: 90-180 min</p> <p>A makeup exam will be offered at the end of the semester, details will be announced at the beginning of the course.</p> <p>Within the written exam, students demonstrate that they understand the presented processes, models, and methods, that they can reproduce and apply them as well as that they can transfer and extend models and methods to similar problems. The written exam consist of 7 to 9 assignments, which require independent application of process definitions, models, and methods</p>

	presented in the lecture.
Literatur/Literature	<ul style="list-style-type: none"> • Ian Goodfellow, Yoshua Bengio, and Aaron Courville. 2016. <i>Deep Learning</i>. The MIT Press. • Richard S. Sutton and Andrew G. Barto. 2018. <i>Introduction to Reinforcement Learning</i> (2nd ed.). MIT Press, Cambridge, MA, USA,
Medienformen	Beamer-Präsentation, Tafelpräsentation, Handout
Media	slides show, blackboard presentation, handouts
Lehr- und Lernmethode	Vorlesung, Übung, Aufgaben zum Selbststudium. Das Modul besteht aus einer Vorlesung und Übungen in kleinen Gruppen (als Tutorübungen). In den Hausaufgaben, die freiwillig abzugeben sind, analysieren die Studierenden die in der Vorlesung vorgestellten Prozesse, Modelle und Verfahren, wenden diese auf konkrete Daten an und erweitern diese für ähnliche Problemstellungen. In den Hausaufgaben werden selbstständig anspruchsvolle Übungsaufgaben bearbeitet, die ähnlich zu den Klausuraufgaben sind (siehe oben) und daher zur Vorbereitung darauf dienen. In der Übung werden mögliche Lösungsstrategien diskutiert.
Teaching and Learning Methods	Lecture, tutorial, assignments for individual study. Within the assignments (the submission is optional) students analyze the processes, models, and methods presented in the corresponding lectures, apply them to real data, and extend these to similar problems. The assignments consist of demanding problems similar to the assignments in the written exam (for details see above) and serve as a preparation for the exam. Within the tutorials possible approaches for solutions of the assignments will be discussed.
Turnus	Wintersemester
Modulverantwortlicher	Prof. Dr. Matthias Schubert
Dozenten	Prof. Dr. Matthias Schubert