

<b>Advanced Machine Learning</b>						
<b>Modulnummer</b>	<b>Workload</b>	<b>Präsenzzeit</b>	<b>Selbststudium</b>	<b>Studiensemester</b>	<b>Angebot im</b>	<b>Dauer</b>
60881	150 h	75 h	75 h	7. Semester	SO-SE	1 Semester
<b>Lehrveranstaltungen</b>		<b>Credits</b>	<b>Zuordnung zu den Curricula</b>			
Vorlesung (3 SWS) Praktikum (1 SWS)		5 CP	Bachelorstudiengänge: alle			
<b>1</b>	<b>Lernergebnisse (Learning outcomes) / Kompetenzen (Competences)</b>					
	<p>Die Studierenden</p> <ul style="list-style-type: none"> <li>• erlernen grundlegende Ansätze und für die Praxis relevante Verfahren des maschinellen Lernens und können diese erklären,</li> <li>• können die erlernten ML-Methoden unterscheiden und entsprechend einer Aufgabenstellung auswählen,</li> <li>• sind mit dem typischen Workflow (Datenaufbereitung, Training, Validierung, Test) und Softwaretools zur Lösung einer praktischen ML-Problemstellung vertraut,</li> <li>• sind in der Lage eine Lösung hinsichtlich Plausibilität zu hinterfragen und zurück in den Kontext der Ausgangsfragestellung einzuordnen,</li> <li>• können eigenständig Machine Learning auf neue Anwendungsszenarien anwenden.</li> </ul>					
<b>2</b>	<b>Inhalte (Contents)</b>					
	<p>Die Vorlesung vermittelt die Grundlagen und darauf aufbauend praxisrelevante Verfahren des maschinellen Lernens. Neben der theoretischen Betrachtung werden in anwendungsorientierten Beispielen, wie Bilderkennung oder das Erlernen von Spielstrategien, die erlernten Methoden angewendet und damit die Kompetenz erlangt diese zu erklären, einzuordnen, und auf andere Anwendungsszenarien zu übertragen. Im Einzelnen werden folgende Themen behandelt:</p> <ul style="list-style-type: none"> <li>▪ Stochastische Entscheidungs-/Lerntheorie: Bayes'sche Entscheidungstheorie, Klassifikation und Regression, Un-/Supervised Learning</li> <li>▪ Maximum-Likelihood und Bayes'sche Parameterschätzung: LDA, PCA</li> <li>▪ Nicht-parametrische Verfahren: k-Nearest-Neighbour, Parzen Windows, Decision Trees, Ensemble Methods</li> <li>▪ Kernel-basierte Verfahren: Support Vector Machines, Kernel-PCA, Kernel-FDA</li> <li>▪ Neuronale Netze: Deep NN, Convolutional NN, Recurrent NN, Autoencoders, GANs</li> <li>▪ Boltzmann-Learning, Restricted Boltzmann Machines</li> <li>▪ Reinforcement Learning: (Deep) Q-Learning</li> </ul>					
<b>3</b>	<b>Lehrformen (Forms of teaching)</b>					
	<ul style="list-style-type: none"> <li>• Vorlesung mit seminaristischen Elementen</li> <li>• Praktikum mit Workshop-Charakter</li> </ul>					
<b>4</b>	<b>Empfohlene Voraussetzungen (Recommended prerequisites)</b>					
	<ul style="list-style-type: none"> <li>• Das Wahlfach Machine Learning sollte absolviert sein oder parallel gehört werden.</li> </ul>					

	<ul style="list-style-type: none"> <li>• Mathematik I + II sollten absolviert sein</li> <li>• Informatik I sollte absolviert sein (Grundlegende Python-Kenntnisse sind von Vorteil)</li> <li>• Gutes englisches Leseverständnis, da teilweise Fachliteratur und Hilfe zu Softwarepaketen in Englisch verfasst sind.</li> </ul>
5	<p><b>Prüfungsformen (Types of examination)</b></p> <ul style="list-style-type: none"> <li>• Mündliche Prüfung (30 Min. Dauer) oder schriftliche Klausur (120 Minuten Dauer). Die Prüfungsform wird zu Beginn der Lehrveranstaltung bekanntgegeben.</li> </ul>
6	<p><b>Voraussetzungen für die Vergabe von Leistungspunkten (Requirements for award of credits)</b></p> <ul style="list-style-type: none"> <li>• Bestandene Modulprüfung</li> </ul>
7	<p><b>Modulverantwortliche(r) (Person responsible for the module)</b></p> <p>Prof. Dr.-Ing. André Stuhlsatz</p>
8	<p><b>Sprache (Language of instruction)</b></p> <ul style="list-style-type: none"> <li>• Deutsch (Fachliteratur ist fast ausschließlich auf Englisch) / wahlweise Englisch</li> </ul>
9	<p><b>Sonstige Informationen / Literaturempfehlungen (Further information and references)</b></p> <p>Das Wahlfach ist für Studierende ab dem dritten Fachsemester geöffnet.</p> <p>Literatur:</p> <ul style="list-style-type: none"> <li>• DUDA, Richard O., Peter E. HART und David G. STORK, 2001. <i>Pattern classification</i>. 2. ed. New York [u.a.]: Wiley. ISBN 0-471-05669-3</li> <li>• HASTIE, Trevor, Robert TIBSHIRANI und Jerome H. FRIEDMAN, 2017. <i>The elements of statistical learning: data mining, inference, and prediction</i>. Second edition, corrected at 12th printing 2017. New York, NY: Springer. ISBN 978-0-387-84857-0</li> <li>• SCHÖLKOPF, Bernhard und Alexander J. SMOLA, 2002. <i>Learning with kernels: support vector machines, regularization, optimization, and beyond</i>. Cambridge, Mass. [u.a.]: MIT Press. ISBN 0-262-19475-9</li> <li>• MACKAY, David J. C., 2008. <i>Information theory, inference, and learning algorithms</i>. 7. print. Cambridge [u.a.]: Cambridge Univ. Press. ISBN 978-0-521-64298-9</li> <li>• AGGARWAL, Charu C., 2018. <i>Neural networks and deep learning: a textbook</i>. Cham, Switzerland: Springer. ISBN 978-3-319-94462-3</li> <li>• CALIN, Ovidiu L., 2020. <i>Deep learning architectures: a mathematical approach</i>. Cham: Springer. ISBN 978-3-030-36721-3</li> <li>• SUTTON, Richard S. und Andrew BARTO, 2018. <i>Reinforcement learning: an introduction</i>. Second edition. Cambridge, Massachusetts; London, England: The MIT Press. ISBN 978-0-262-03924-6</li> </ul>