

<b>Kern (VMC)</b> <i>Core (VMC)</i>							Modulnummer:		
Bachelor Pflicht/Wahl <input checked="" type="checkbox"/> Wahlpflicht <input type="checkbox"/> Wahl <input type="checkbox"/> Sonderfall <input type="checkbox"/>				Modulbereich: Pflicht					
Anzahl der SWS	V	UE	K	S	Prak.	Proj.	$\Sigma$	Kreditpunkte: 6	Turnus i. d. R. angeboten alle 2 Semester
	2	2	0	0	0	0	4		
Formale Voraussetzungen: -									
Inhaltliche Voraussetzungen: Technische Informatik 2									
Vorgesehenes Semester: ab 1. Semester									
Sprache: Deutsch									
Ziele: Die wichtigsten Methoden moderner Bildverarbeitung verstehen <ul style="list-style-type: none"> <li>• Bildverarbeitung mit Deep Learning (Convolutional Neural Networks)</li> <li>• 3D Bildverarbeitung („von Pixeln zu Metern“)</li> </ul> Anwendungsprobleme mit diesen Methoden lösen können <ul style="list-style-type: none"> <li>• Passende Verarbeitungsketten für Anwendungsprobleme entwerfen</li> <li>• Anwendungsprobleme als Deep Learning Aufgabe formulieren</li> <li>• Trainingsdaten beschaffen und aufbereiten</li> <li>• Dreidimensionale geometrische Zusammenhänge in Bildern modellieren</li> <li>• Deep Learning und 3D Bildverarbeitungssysteme systematisch entwickeln</li> <li>• Implementierung mit TensorFlow / Keras und OpenCV</li> </ul>									

Inhalte: .

**Bildverarbeitung mit Deep Learning.**

All die folgenden Inhalte werden in ihrer formalen Definition, aber auch in einem intuitiven Verständnis für die Idee dahinter, die Bedeutung im Gesamthema und die Interaktion mit anderen Inhalten vermittelt.

- Paradigmen „analytisch entwickelt“ vs. „maschinell gelernt“
- Die Architektur von künstlichen neuronalen Netzen die Bilder verarbeiten („Big Picture“ - Überblick noch ohne die Details, die später folgen)
- Formen der Ausgabe: Klassifizierung, Semantic Segmentation, Heatmap, Boundingboxes, Objekt-Id pro Pixel, applikationsabhängige Werte
- Schichten: Convolution, Aktivierung, Pooling, Unpooling, Fully Connected
- Losses: Absoluter, quadratischer, relativer Fehler, Maximum-Likelihood, Crossentropy, Gewichtungen, Kombination mehrerer Losses
- Optimierung durch Gradientenabstieg, Sicht eines Netzes mit Loss als Graph von Tensoroperationen, Tensorformate, Backpropagation auf solch einem Graphen
- Rezeptives Feld als Architekturkenngroße
- Typische CNN-Backbonearchitekturen und ihre Nutzung im „pretrained“-Ansatz
- Decoder-Encoder Architektur für Bilder als Ausgabe, Bedeutung der Querverbindungen
- Objekterkennung: Ausgabeform für Boundingboxes, one-shot vs. two-shot Ansatz
- Vorgehen bei der Datenbeschaffung und Aufbereitung
- Vorgehen bei der Entwicklung und Evaluation von Deep Learning Bildverarbeitungssystemen
- Mediale Anwendungen von Deep Learning, besonders zur Bildgenerierung
- Generative Adversarial Networks (die Grundidee)

**3D – Bildverarbeitung**

- Paradigma von „Pixeln zu Metern durch Gleichungslösen“
- Punktfeatures
- Kameragleichung
- Geometrische Rekonstruktion (welche 3D Eigenschaften lassen sich aus wie vielen 2D Punktpaaren rekonstruieren)
- Quadratische Ausgleichsrechnung als generischer algorithmischer Ansatz dafür geometrische Rekonstruktion
- Partikelfilter für zeitliche Abläufe, Rolle der Bildverarbeitung als Messmodell darin

Lehrveranstaltung(en):

- 03-IMAP-D3BV Deep-Learning- und 3D-Bildverarbeitung

Unterlagen (Skripte, Literatur, Programme usw.):

- MIT 6.S191, Introduction to Deep Learning, <http://introtodeeplearning.com>
- Ian Goodfellow, Yoshua Bengio, Aaron Courville, Deep Learning, MIT Press, 2016 (<http://www.deeplearningbook.org>)
- Richard Hartley, Andrew Zisserman, Multiple View Geometry in Computer Vision (<https://www.robots.ox.ac.uk/~vgg/hzbook/>)
- Richard Szeliski, Computer Vision and Applications, Springer 2010 (<http://szeliski.org/Book/>, Computer Vision vor der Deep Learning Revolution)

Form der Prüfung:

MP, mündliche Prüfung, ggf. Bonusprüfung

Arbeitsaufwand	Präsenz	56 h
	Übungsbetrieb/Prüfungsvorbereitung	124 h
	Summe	180 h

Lehrende:  
Prof. Dr. U. Frese

Verantwortlich:  
Prof. Dr. U. Frese