

Certificate of Advanced Studies

# Data Science Applications

**Machine Learning und Artificial Intelligence entwickeln sich rasch und erschliessen neue Nutzungsmöglichkeiten. Das CAS Data Science Applications gibt Ihnen einen vertieften Einblick in aktuelle Technologien, Methoden, Anwendungsgebiete und Trends.**













# Inhaltsverzeichnis

1	Umfeld	3
2	Zielpublikum	3
3	Ausbildungsziele	3
4	Voraussetzungen	4
5	Kompetenzprofil	4
6	Kursübersicht	5
7	Kursbeschreibungen	6
	7.1 Predictive Maintenance and Industrial Analytics	6
	7.2 Operationalisierung von ML und AI Modellen	7
	7.3 Audio Analysis	8
	7.4 Ethik und soziale Auswirkungen	9
	7.5 Recommender Systems	10
	7.6 Deep Reinforcement Learning (DRL)	11
	7.7 Graph und Network Analytics	12
	7.8 Natural Language Processing	13
	7.9 Advanced Image Analysis	14
	7.10 Robotics Workshop	15
8	Semesterarbeit	16
9	Kompetenznachweis	17
10	Dozierende	17
11	Organisation	18

Stand: 24.02.2023

# 1 Umfeld

Data Science, Machine Learning (ML) und künstliche Intelligenz (Artificial Intelligence AI) stellen eine riesige Vielfalt an Methodiken und Algorithmen bereit. Diese schaffen ein enormes Potential für Innovationen, neue Anwendungsfelder, Optimierung von Prozessen und Dienstleistungen und ganz neuen Geschäftsmodellen. Das CAS Data Science Applications gibt Ihnen einen vertieften Einblick in aktuelle Technologien, Methoden, Anwendungsgebiete und Entwicklungen:

	Operationalisierung von ML- und AI-Systemen		Deep Reinforcement Learning
	Predictive Maintenance and Industrial Analytics		Graph und Network Analytics
	Audio Analysis		Natural Language Processing
	Ethik und soziale Auswirkungen		Advanced Image Analysis
	Recommender Systems		Robotics Workshop

## 2 Zielpublikum

- Informatiker\*innen, Ingenieur\*innen, wissenschaftliche Mitarbeitende in verschiedensten Fachgebieten, die sich in neue Gebiete des Machine Learnings und der künstlichen Intelligenz einarbeiten wollen.
- IT-Spezialist\*innen in verschiedensten Fachgebieten, die ML- und AI-Anwendungen planen, umsetzen und in die IT-Architektur ihres Unternehmens einfügen wollen.
- Für Studierende im MAS Data Science kommt das CAS Data Science Applications idealerweise im zweiten oder dritten Semester zum Zug, im Anschluss an das CAS Datenanalyse oder an das CAS Practical Machine Learning.

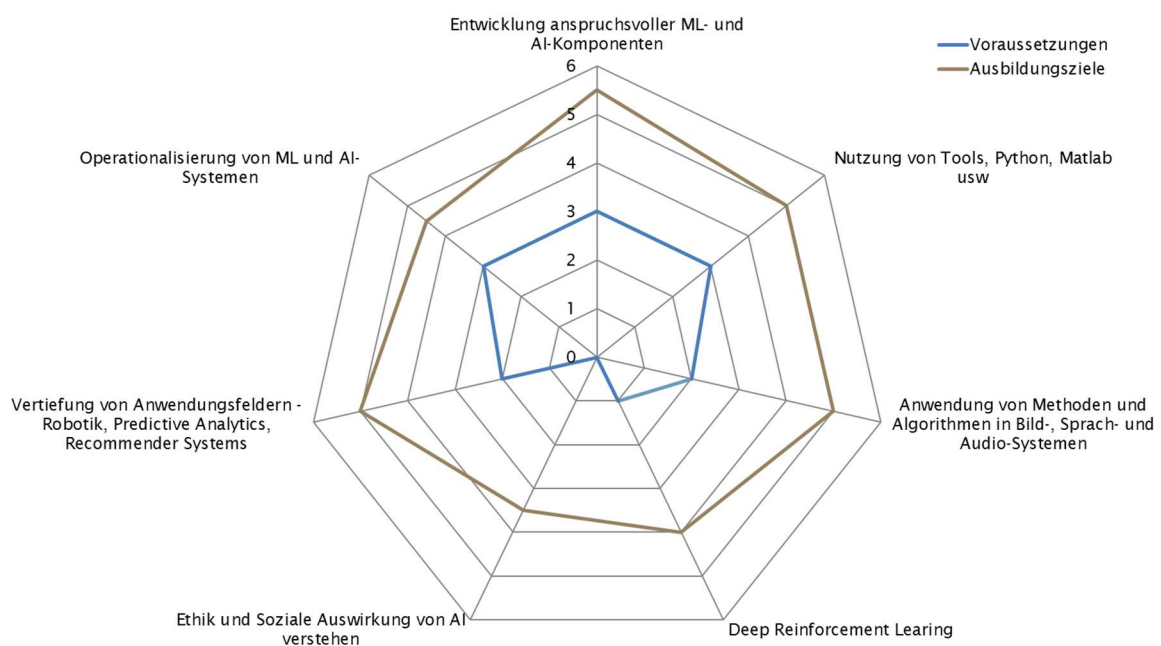
## 3 Ausbildungsziele

- Sie können Ihre Methodik- und Anwendungskompetenz in ausgewählten Fachgebieten entscheidend vertiefen.
- Sie sind befähigt, auch anspruchsvolle ML-Applikationen und Komponenten professionell zu entwickeln.
- Sie arbeiten als Fachspezialist\*in in Teams, die ML-Komponenten nutzen, konzipieren und bauen.

## 4 Voraussetzungen

- Sie bringen ein Bachelor-Studium mit, typischerweise in Informatik-, Ökonomie- oder Engineering-Disziplinen und haben Spass an einer algorithmischen Denkweise.
- Sie bringen Erfahrungen in Methoden und Algorithmen des Machine Learnings mit: Themen wie Supervised Learning, Unsupervised Learning, Feature Engineering und Evaluation sind Ihnen bekannt.
- Sie können mit der Sprache Python im Umfeld von ML-Anwendungen arbeiten.
- Die Themenblöcke 'Advanced Image Analysis' und 'Natural Language Processing' dieses CAS schliessen sich an die entsprechenden Wahlfächer 'Image Analysis' und 'Text Analysis' im CAS Practical Machine Learning an. Falls Sie das CAS Practical Machine Learning nicht bereits besucht haben, besteht die Möglichkeit, diese beiden Kurse vorgängig im Sommersemester zu besuchen und als Teil des CAS Data Science Applications anrechnen zu lassen.

## 5 Kompetenzprofil



### Kompetenzstufen

1. Kenntnisse/Wissen
2. Verstehen
3. Anwenden
4. Analyse
5. Synthese
6. Beurteilung

## 6 Kursübersicht

Kurs / Lehreinheit	Tage	Stunden	Dozierende
Predictive Maintenance and Industrial Analytics	3		Angela Meyer
Operationalisierung von ML- und AI-Modellen	2		Marcus Schwemmler
Audio Analysis	2		Christophe Lesimple
Ethik und soziale Auswirkungen	1		Andre Bodmer
Recommender Systems	2		(tbd)
Deep Reinforcement Learning	2		Ilija Rasin
Graph und Network Analytics	3		Angela Meyer
Advanced Image Analysis	3		Marcus Hudritsch
Natural Language Processing	3		Jürgen Vogel
Robotics Workshop	2		Robin Glauser Thomas Bürkle
Semesterarbeit		60	
<b>Total</b>	<b>23</b>	<b>60</b>	

Das CAS umfasst insgesamt 12 ECTS-Credits und entspricht 300-360 Stunden Workload. Zu Beginn des CAS können Sie sich in die einzelnen Kurse einschreiben. Sie können dabei eine individuelle Auswahl der Kurse treffen. Für das CAS-Zertifikat sind mindestens 15 Kurstage zu besuchen. Grundsätzlich werden alle Kurse durchgeführt, ausser bei geringer Interessenslage.

## 7 Kursbeschreibungen

Viele der ausgeschriebenen Themen sind hochdynamische Entwicklungsgebiete. Die Detailbeschreibungen in diesem Kapitel werden dem technologischen und methodischen Stand laufend angepasst und untereinander abgestimmt bis zum CAS-Start.

### 7.1 Predictive Maintenance and Industrial Analytics



Dieser Kurs gibt eine praxisorientierte Einführung in Predictive Maintenance und tiefgehende Kenntnisse und Fähigkeiten zu den dabei verwendeten Verfahren des maschinellen Lernens und der automatisierten Zustandsüberwachung. Mit Predictive-Maintenance-Verfahren lassen sich Probleme an Anlagen erkennen, bevor es zu Funktionsstörungen und Ausfällen kommt. Dadurch können Kosten eingespart, Stillstandszeiten reduziert und Unterhaltsarbeiten rechtzeitig geplant werden. Im Unterschied zu herkömmlichen Instandhaltungsverfahren kann dabei der tatsächliche Zustand der überwachten Anlagen mit Hilfe geeigneter Sensorsysteme erkannt und automatisiert überwacht werden. Predictive-Maintenance-Programme lernen mit Hilfe von statistischen und Maschine-Learning Verfahren optimale Instandhaltungszeitpunkte und -aktivitäten aus Anlagen- und Instandhaltungsdaten.

Lernziele	<p>Die Teilnehmenden</p> <ul style="list-style-type: none"><li>– kennen den Predictive-Maintenance-Prozess von der Datenerfassung bis zur betrieblichen Umsetzung.</li><li>– kennen die Methoden der zustandsbasierten und der vorausschauenden Instandhaltung.</li><li>– kennen Verfahren zur datenbasierten Zustandsüberwachung von Anlagen und Infrastruktur, zur automatisierten Fehleranalyse und Erkennung von Störungen und können diese Verfahren anwenden.</li><li>– können die Ergebnisse datenbasierter Modelle interpretieren und darauf basierend Entscheidungen für den Betrieb und die Instandhaltung treffen.</li><li>– kennen die Anwendungsfelder und Voraussetzungen für Predictive Maintenance im Betrieb.</li></ul>
Themen und Inhalte	<ul style="list-style-type: none"><li>– Einführung in die zustandsbasierte und die prädiktive Instandhaltung</li><li>– Statistische und Machine-Learning-Verfahren für die datenbasierte Instandhaltung</li><li>– Verfahren für die automatisierte Fehleranalyse und Früherkennung von Störungen</li><li>– Interpretation und Bewertung der entwickelten Modelle</li><li>– Anwendungsfälle und Voraussetzungen für die zustandsbasierte und prädiktive Instandhaltung von Anlagen und Infrastruktur</li></ul>
Lehrmittel	<ul style="list-style-type: none"><li>– Folien/Skript</li><li>– Jupyter Notebooks</li><li>– Literaturempfehlungen</li></ul>

## 7.2 Operationalisierung von ML- und AI-Modellen



Nach der Entwicklungsphase von ML- und AI-Modellen werden diese in der Regel in eine bestehende IT-Landschaft eingebaut. Dabei gibt es spezifische Herausforderungen, vom umgebenden Framework, in dem die ML-Modelle laufen, über die Daten- und Kommunikationsschnittstellen, bis hin zu Fragen von Lern- und Produktionszyklen, Nachvollziehbarkeit und vieles mehr. Dieser Kurs richtet sich an Data Scientists, Informatiker\*innen und IT-Architekt\*innen, die ML-Modelle in eine produktive Umgebung einbinden wollen.

Lernziele	<ul style="list-style-type: none"><li>– Herausforderungen der Operationalisierung von Machine Learning und deren Anwendungen verstehen</li><li>– Möglichkeiten und Einsatz moderner Tools kennen</li></ul>
Themen und Inhalte	(folgt)
Lehrmittel	<ul style="list-style-type: none"><li>– Folien/Skript</li><li>– Hands-On-Übungen</li><li>– Literaturangaben</li></ul>

## 7.3 Audio Analysis




Applikationen mit ML- und AI-Methoden auf Audiosignalen sind bereits weit verbreitet und haben fantastische Anwendungen in Industrie, IT, Dienstleistung, Gesundheitswesen und vielen mehr. Erkennung von Geräuschen für Predictive Maintenance, Erkennung von akustischen Situationen und Objekten, End-to-End AI-basierte Hörgeräte, Voice Cloning, Speech-to-Text und Text-to-Speech Anwendungen.

Lernziele	Anwendungsfelder von Audio Analysis mit AI- und ML-Methoden kennen. Eigene Lernbeispiele und Anwendungen schreiben können: <ul style="list-style-type: none"><li>– Umgang mit Audiodaten und Datensatz Aufbau für ML-Anwendungen,</li><li>– Verschiedene Lösungen evaluieren und optimieren.</li><li>– Erfahrung mit Tools und Bibliotheken in Python sammeln.</li></ul>
Themen und Inhalte	Je 4 Lektionen zu den Themen: <ul style="list-style-type: none"><li>– Audio Signal Analyse mit numpy, scipy und librosa. Feature Engineering optimieren</li><li>– Classification mit Sci-kit Learn libraries und mit Deep Learning</li><li>– Einführung in Automatic Speech Recognition mit Keyword Spotting</li><li>– Anwendung von Autoencoder für Daten Kompression und um Anomalien zu detektieren</li></ul>
Lehrmittel	<ul style="list-style-type: none"><li>– Folien/Skript</li><li>– Literaturempfehlungen</li><li>– Programmierumgebung Python</li></ul>



## 7.4 Ethik und soziale Auswirkungen



Bestimmte ML- und AI-Systeme haben heute eine enorme Breitenwirkung. In der Kritik stehen beispielsweise HR-Rekrutierungssysteme, polizeiliche Gefahrensysteme usw. Hier stellt sich unter anderem die Frage: Können Maschinen moralisch handeln? Maschinenethik ist ein neues Forschungsgebiet an der Schnittstelle von Informatik und Philosophie, das die Entwicklung moralischer Algorithmen zum Ziel hat. Es geht darum, auf der Grundlage von datenbasierter Computertechnologie Systeme zu gestalten, die selbst moralische Entscheidungen treffen und umsetzen können.

Sollen im Rahmen der Maschinenethik Verfahren der künstlichen Intelligenz eingesetzt werden, so spricht man analog zu "Artificial Intelligence" (AI) von "Artificial Morality" (AM). Während AI zum Ziel hat, die kognitiven Fähigkeiten von Menschen zu modellieren oder zu simulieren, geht es bei der AM darum, künstliche Systeme mit den Fähigkeiten moralisches Entscheiden und Handeln auszustatten.

Im Modul werden einige Anwendungsbereiche moralischer Maschinen vorgestellt. Dann wird thematisiert, inwiefern man überhaupt davon sprechen kann, dass Maschinen moralisch handeln können. Zum Abschluss werden ausgewählte ethische Argumente diskutiert, die dafür oder dagegen sprechen, Maschinen mit der Fähigkeit zum moralischen Handeln auszustatten.

Lernziele	<p>Die Studierenden</p> <ul style="list-style-type: none"> <li>– haben eine Übersicht über die historische Entwicklung der philosophischen Herangehensweisen im Bereich Machine Learning (ML) und Artificial Intelligence (AI).</li> <li>– kennen die wichtigsten moralischen Herausforderungen in Bezug auf ML und AI.</li> <li>– kennen ethische Konzepte, um eigene Anwendungen argumentativ und strukturiert zu beurteilen.</li> </ul>
Themen und Inhalte	<ul style="list-style-type: none"> <li>– Geschichte der Maschinenethik</li> <li>– Philosophische Konzepte von AI (schwache vs. starke AI)</li> <li>– Philosophische Konzepte von Daten und Datenanalyse</li> <li>– Moralische Herausforderungen von ML und AI im Licht von ethischen Theorien mit Best Practice Anwendungen</li> </ul>
Lehrmittel	<ul style="list-style-type: none"> <li>– Folien/Skript</li> <li>– Literaturempfehlungen</li> </ul>

## 7.5 Recommender Systems



Empfehlungssysteme sind vermutlich die weitverbreitetste Art von ML- und AI-Systemen im täglichen Leben.

Ein Strauß klassischer und moderner Ansätze und Algorithmen kommen zum Einsatz, vom Content Based Filtering, über Collaborative Filtering bis zum Reinforcement Learning. Gewinnen Sie in diesem Kurs einen Einblick in die Arbeitsweise von Empfehlungssystemen und lernen Sie solche Systeme für eigene Aufgaben zu planen, zu bauen und zu nutzen.

Lernziele	Sie kennen wichtige und erfolgskritische Faktoren beim Aufbau und Betrieb von Empfehlungssystemen und lernen anhand von konkreten Anwendungs- und Datenbeispielen die Funktionsweise von Empfehlungssystemen kennen.
Themen	<ul style="list-style-type: none"><li>– Was sind Empfehlungssysteme (Recommender Systems)?</li><li>– Anwendungsfälle, Nutzen und Ziele</li><li>– Ausgewählte Methoden und Algorithmen</li><li>– Aufbau und Betrieb von Empfehlungssystemen</li><li>– Projektbeispiele aus sozialen Medien, e-Commerce-Plattformen, Medienhäusern und Marktplätzen</li></ul> <p>Im Workshop werden anhand konkreter Daten (csv, R/Python) die Methodik, der Aufbau und die Herausforderung an Empfehlungssysteme vermittelt.</p>
Lehrmittel	<ul style="list-style-type: none"><li>– Folien/Skript</li></ul>


## 7.6 Deep Reinforcement Learning (DRL)



Reinforcement Learning (RL) ist in seiner Idee dem Verhalten von lebenden Organismen nachgebildet: Anhand von möglichen Aktionen oder Entscheidungen wird versucht, ein bestimmtes Ziel zu erreichen oder eine vorteilhafte Abfolge von Zuständen oder Situationen zu erreichen. Vorteilhaft Zustände werden dabei belohnt. Für die Auswahl einer Aktion kann das System (der sogenannte Agent) eine Strategie (Policy) verfolgen, um insgesamt eine maximale Belohnung zu erreichen. Deep Reinforcement Learning (DRL) kombiniert RL mit Deep Learning (mit neuronalen Netzen), welches die Analyse komplexer Situation für die Aktionsermittlung vornimmt. RL und DRL werden angewendet in der Robotik, der Sprachverarbeitung, in Spielen und Simulationen und als Alternative oder in Kombination zu klassischen Methoden wie Supervised Learning.

Lernziele	Die Studierenden lernen die Prinzipien von Reinforcement Learning und Deep Reinforcement Learning und kennen die Unterschiede zu den klassischen ML-Ansätzen.
Themen und Inhalte	<p>Tag 1 – Foundation of DRL</p> <ul style="list-style-type: none"> <li>– Markov Property</li> <li>– Markov Decision Process (MDP)</li> <li>– Reward and Return, Discount Factor, Policy</li> <li>– Bellmann Formula</li> <li>– State-Value, State-Action-Value, Advantage-Value</li> <li>– OpenAI Gym</li> <li>– Monte-Carlo Method</li> <li>– SARSA/TD(0)</li> <li>– Sarsamax – Q-Learning</li> </ul> <p>Tag 2 – Deep Q-Learning (DQN)</p> <ul style="list-style-type: none"> <li>– Off-Policy vs. On-Policy Methods – Why Off-Policy works?</li> <li>– Experience Replay Buffer</li> <li>– Online- and Target-Model</li> <li>– Epsilon-Greedy Policy</li> <li>– Training-Loop Definition</li> <li>– How DQN learns?</li> <li>– DQN Improvements <ul style="list-style-type: none"> <li>○ Learning with Advantages – Dueling DQN</li> <li>○ Advanced Environment Exploration – Noisy Networks</li> <li>○ Putting it all together</li> </ul> </li> <li>– Conclusion, Q&amp;A</li> </ul>
Lehrmittel	<ul style="list-style-type: none"> <li>– Hands-On-Übungen</li> <li>– Folien/Skript</li> <li>– Literaturempfehlungen</li> </ul>

## 7.7 Graph und Network Analytics



Komplexe Netzwerke kommen in sehr vielen Bereichen implizit oder explizit vor. Sie dienen als riesige Informationsträger und Strukturen (z.B. Social-Media-Netzwerke, Wissensnetzwerke, Verteilungsnetze in Logistik, Energie usw.). Netzwerkalgorithmen stellen Instrumente für die Verbreitung von Information und Prognosen zur Verfügung. Methodisch können Netzwerke als Graphen oder mit statistischen Verfahren beschrieben und analysiert werden. In der Informatik haben sich zahlreiche Datenbanksysteme und Programmbibliotheken etabliert, welche eine einfache und effiziente Nutzung ermöglichen.

Lernziele	<ul style="list-style-type: none"> <li>– Die Begriffe der Netzwerkanalyse verstehen</li> <li>– Netzwerkdatenstrukturen beschreiben</li> <li>– Information in Netzen quantifizieren</li> <li>– Netze strukturell vergleichen</li> <li>– Netzwerke visualisieren</li> <li>– Statistische Beschreibung von Netzen anwenden</li> <li>– Prozesse der Verteilung von Information in Netzwerken kennen</li> <li>– Nutzung von neuronalen Netzen für die Netzwerkanalyse</li> <li>– Erlernte Methoden in ihrem Arbeitsumfeld einsetzen</li> </ul>
Themen und Inhalte	<p>Methoden</p> <ul style="list-style-type: none"> <li>– Datenverwaltung und Visualisierung</li> <li>– Methoden zur Analyse von Netzwerken</li> <li>– Praktische Anwendungen</li> </ul>
Lehrmittel	<ul style="list-style-type: none"> <li>– Folien/Skript</li> </ul>

## 7.8 Natural Language Processing




Viele Daten sind textbasiert, seien es Projektberichte im Unternehmen, Kundenanfragen per E-Mail oder Produktbewertungen in sozialen Netzwerken. Mit Hilfe von Machine Learning lassen sich solche Texte analysieren und klassifizieren: Ist die empfangene E-Mail unerwünschte Werbung, eine Supportanfrage oder eine Beschwerde? Wird unser Unternehmen auf Twitter eher als positiv oder negativ gesehen? Wie lassen sich Texte erzeugen, zum Beispiel Antworten auf Support-Anfragen? Wie funktionieren ChatBots und ChatGPT und wie kann ich diese Technologien einsetzen?

Bei Interesse und entsprechenden Vorkenntnissen der Teilnehmenden wird dieser Kurs auf fortgeschrittene Themen ausgerichtet, mit Fokus auf Text-Synthese, Transformers und Pretrained Transformers (GPT-n).

Lernziele	Die Teilnehmenden erhalten einen Überblick zur maschinellen Textanalyse und lernen grundlegende Verfahren und Vorgehensweise zur Gewinnung von Information aus Texten kennen, wie beispielsweise für die Extraktion von spezifischen Informationen (z.B. genannter Personen oder Orte) oder die Klassifikation von Texten (z.B. Sentiment Analysis).
Themen und Inhalte	<ul style="list-style-type: none"><li>– Grundlegende Verfahren zur Text-Analyse (Natural Language Processing)</li><li>– Linguistische und ML-basierte Verfahren (Syntax-Analyse, Vektorisierung von Texten (Feature Engineering), Word Embedding und Deep Learning)</li><li>– Clustering und Klassifikation von Texten (z.B. Sentiment Analysis)</li><li>– Praktische Anwendung obengenannter Verfahren mit Hilfe von Python und spezifischen Open-Source-Bibliotheken auf ausgewählten Beispieldatensätzen</li><li>– Möglichkeiten der Textsynthese, Textgenerierung</li><li>– Nutzung von vortrainierten Transformatoren und Datensätzen</li><li>– Plattformen für Build-Train-Deployment von NLP-Modellen und Anwendungen</li></ul>
Lehrmittel	<ul style="list-style-type: none"><li>– Folien/Skript</li><li>– Literaturempfehlung 11</li><li>– Eingebettete Übungsaufgaben mit Python, Jupyter Notebooks, scikit-learn und nltk</li></ul>

## 7.9 Advanced Image Analysis




Bildanalyse erstreckt sich heute über ein breites Anwendungsfeld, von der Produktionsüberwachung in Industriebetrieben, bis hin zur Erkennung von bestimmten Objekten, wie Menschen, Pflanzen, Tiere, Gegenstände, Lebensmittel usw. Das Suchen von Bildern mit Hilfe von anderen Bildern, das Erkennen von Bewegung und Stimmung, das Segmentieren von Bildbereichen und viele weitere Methoden werden im täglichen Leben heute eingesetzt. Der Hauptfokus dieses Kurses ist die Erkennung von Objekten und die fachliche Beschreibung von Bilddaten (Feature Extraction).

Bei Interesse und entsprechenden Vorkenntnissen der Teilnehmenden wird dieser Kurs auf fortgeschrittene Themen ausgerichtet, mit Fokus auf Augmented Reality und Fotogrammetrie. Dabei spielt die Analyse von Videobildern und die Positionsbestimmung der Kamera (respektive des Betrachters) eine zentrale Rolle.

Lernziele	Die Studierenden erhalten eine Übersicht, wie Bilder analysiert und danach ML-Methoden zugeführt werden können.
Themen und Inhalte	<ul style="list-style-type: none"> <li>– Introduction: Point Operators &amp; Local Operators, Global Operators: Fourier Transform, Global Operators: Hough Transform, PCA</li> <li>– Segmentation: Threshold based, Region based, Model based</li> <li>– Region Representation</li> <li>– Feature Extraction</li> <li>– Classification: Without Learning, Shallow Neural Networks, Convolutional Neural Networks, CNN-Exercises</li> <li>– Detection &amp; Tracking</li> <li>– Geometric Analysis: Camera Model, Camera Calibration, Pose Estimation, Augmented Reality</li> </ul>
Lehrmittel	<ul style="list-style-type: none"> <li>– Detailliertes Skript und Folien</li> <li>– Übungen in Matlab</li> </ul>

## 7.10 Robotics Workshop



Einführung im Medizininformatik-Labor zum Einsatz von Robotern an praktischen Beispielen im Gesundheitswesen. Mithilfe einer Abstraktionsschicht können die Roboter auch ohne erweiterte Programmierkenntnisse programmiert und einfache Szenarien umgesetzt werden. Dies ermöglicht es Expert\*innen aus anderen Gebieten, Szenarien einfach anzupassen und zu erweitern. Über die Python-Schnittstelle ermöglicht die Abstraktionsschicht für Teilnehmende mit erweiterten Programmierkenntnissen die Möglichkeit, existierende Bibliotheken und AI-Funktionen (Machine Learning, neuronale Netze für Bild und Sprache) zu nutzen und mit dem Roboter zu verknüpfen.

Lernziele	<ul style="list-style-type: none"> <li>– Interaktionen zwischen Menschen und Robotern testen und erleben.</li> <li>– Limitationen und Schwierigkeiten der Robotik kennenlernen.</li> <li>– Robotik Szenarien selbständig umsetzen und erweitern.</li> </ul>
Themen und Inhalte	<ul style="list-style-type: none"> <li>– Installation der Robotik Middleware</li> <li>– Einführung in Robotik Middleware</li> <li>– Navigation mit Robotern</li> <li>– Roboter-Sprachsteuerung / Sprachausgabe</li> <li>– Roboter-Gesten und -Emotionen</li> <li>– Interaktionen über Display</li> <li>– Evtl. Einbinden von anderen Bibliotheken (Machine Learning, neuronale Netze, etc.)</li> </ul>
Lehrmittel	<ul style="list-style-type: none"> <li>– Drei verschiedene Anwendungsbeispiele für Roboter: Pepper, Cruzr und Lio</li> <li>– Robotik Middleware der BFH</li> <li>– Webinterface-Steuerung für Roboter</li> <li>– Python-Schnittstelle (PyCharm)</li> <li>– Gitlab</li> </ul>

## 8 Semesterarbeit

Zielsetzung und Thema	In der Projektarbeit (Semesterarbeit) bearbeiten die Studierenden ein Projekt oder vertiefen eine Fragestellung, die einen Bezug zu den besuchten Kursen hat.
Ablauf	<p>Die Semesterarbeit umfasst ca. 60 Stunden Arbeit und beinhaltet folgende Meilensteine (siehe auch Zeitplan):</p> <ul style="list-style-type: none"><li>– Einreichen einer Projektskizze (Vorlage), Gruppenarbeiten sind möglich</li><li>– Feedback durch ein Expertengremium, eventuell Überarbeitung der Projektskizze gemäss Feedback</li><li>– Zuweisung eines Experten / einer Expertin</li><li>– Durchführung der Arbeit in eigener Terminplanung.</li><li>– Während der Arbeit können die Expert*innen für methodische Beratung in Anspruch genommen werden</li><li>– Schlusspräsentation: 20' Präsentation, 20' Diskussion und Fachgespräch Während dem Fachgesprächen werden von den Expert*innen vertiefte Fachfragen gestellt</li><li>– Abgabe des Berichts: Die Schlusspräsentation (Power Point o.ä.) ist ebenfalls abzugeben</li></ul>
Ergebnis und Bewertung	<p>Die Semesterarbeit wird nach folgenden Kriterien bewertet:</p> <ul style="list-style-type: none"><li>– Vorbereitung und Definition</li><li>– Methodik und Ausführung</li><li>– Ergebnis</li><li>– Präsentation und Fachgespräch</li></ul>



## 9 Kompetenznachweis

Es wird erwartet, dass Sie mindestens 15 Kurstage belegen und allfällige Vorbereitungen, Übungen und Aufgaben vor, nach und während der Kurse bearbeiten.

Für die Anrechnung der 12 ECTS-Credits ist das erfolgreiche Bestehen der Qualifikationsnachweise (Prüfungen, Projektarbeiten) erforderlich, gemäss folgender Aufstellung:

Kompetenznachweis	Gewicht	Art der Qualifikation	Erfolgsquote
Semesterarbeit inklusive Präsentation und Fachgespräch	10	Projekt	0 - 100 %
Total	10		0 - 100 %

Der gewichtete Mittelwert der Erfolgsquoten der einzelnen Kompetenznachweise wird in eine Note zwischen 3 und 6 umgerechnet. Die Note 3 (gemittelte Erfolgsquote weniger als 50%) ist ungenügend, Die Noten 4, 4.5, 5, 5.5 und 6 (gemittelte Erfolgsquote zwischen 50% und 100%) sind genügend.

## 10 Dozierende

Vorname Name	Firma	E-Mail
Jürgen Vogel	Berner Fachhochschule	juergen.vogel@bfh.ch
Werner Dähler	Berner Fachhochschule	werner.daehler@bfh.ch
Marcus Hudritsch	Berner Fachhochschule	marcus.hudritsch@bfh.ch
Matthias Dehmer	UMIT	matthias.dehmer@umit.at
Angela Meyer	Berner Fachhochschule	angela.meyer@bfh.ch
Ilja Rasin	IBM	ilja.rasin@bfh.ch
Christophe Lesimple	Sonova AG	christophe.lesimple@bfh.ch
Thomas Bürkle	BFH	thomas.buerkle@bfh.ch
Robin Glauser	BFH	robin.glauser@bfh.ch
André Bodmer		linkedIn

- + Weitere Dozierende und Referent\*innen aus Wirtschaft und Lehre
- + Weitere Expert\*innen und Betreuer\*innen für die Projektarbeit

## 11 Organisation

### **CAS-Leitung:**

Arno Schmidhauser

Tel: +41 31 84 83 275

E-Mail: [arno.schmidhauser@bfh.ch](mailto:arno.schmidhauser@bfh.ch)

### **CAS-Administration:**

Andrea Moser

Tel: +41 31 84 83 211

E-Mail: [andrea.moser@bfh.ch](mailto:andrea.moser@bfh.ch)

Während der Durchführung des CAS können sich Anpassungen betreffend Inhalte, Lernziele, Dozierende und Kompetenznachweise ergeben. Es liegt in der Kompetenz der Dozierenden und der Studienleitung, aufgrund der aktuellen Entwicklungen in einem Fachgebiet, der konkreten Vorkenntnisse und Interessenslage der Teilnehmenden, sowie aus didaktischen und organisatorischen Gründen, Anpassungen im Ablauf eines CAS vorzunehmen.

### **Berner Fachhochschule**

Technik und Informatik

Weiterbildung

Telefon +41 31 848 31 11

Email: [weiterbildung.ti@bfh.ch](mailto:weiterbildung.ti@bfh.ch)

[bfh.ch/ti/weiterbildung](http://bfh.ch/ti/weiterbildung)

[bfh.ch/ti/cas-dsa](http://bfh.ch/ti/cas-dsa)