



Certificate of Advanced Studies

# Practical Machine Learning

Intelligente Software-Systeme analysieren Daten und Situationen, steuern Prozesse, erstellen Prognosen, treffen Entscheide oder geben Empfehlungen ab. Das CAS Practical Machine Learning rüstet Sie mit den Methoden und Werkzeugen aus, damit Sie solche Systeme bauen, einsetzen und nutzen können, und Sie können sich in verschiedenen Anwendungsbereichen spezialisieren.

# Inhaltsverzeichnis

|    |  |    |
|----|--|----|
| 1  | Umfeld   | 3  |
| 2  | Zielpublikum   | 3  |
| 3  | Ausbildungsziele   | 3  |
| 4  | Voraussetzungen  | 4  |
| 5  | Unterrichtssprache   | 4  |
| 6  | Durchführungsort   | 4  |
| 7  | Kompetenzprofil  | 5  |
| 8  | Kursübersicht  | 6  |
| 9  | Kursbeschreibungen   | 6  |
|    | 9.1 Einführung in die Denk- und Handlungsweise des Machine Learnings | 7  |
|    | 9.2 Python   | 8  |
|    | 9.3 Feature Engineering  | 9  |
|    | 9.4 Überwachtes Lernen   | 9  |
|    | 9.5 Nicht-überwachtes Lernen   | 10 |
|    | 9.6 Neuronale Netze  | 11 |
|    | 9.7 Wahlfach - Image Analysis  | 11 |
|    | 9.8 Wahlfach - Text Analytics und Natural Language Processing        | 12 |
|    | 9.9 Wahlfach MLOps   | 12 |
|    | 9.10 Projektarbeit   | 13 |
| 10 | Kompetenznachweis  | 15 |
| 11 | Lehrmittel   | 15 |
| 12 | Dozierende   | 16 |
| 13 | Organisation   | 16 |

Stand: 21.01.2024

# 1 Umfeld

Die Anforderungen an Optimierung, Effizienz und Qualität von Unternehmensprozessen und Dienstleistungen wächst laufend. Mit Machine Learning (ML) verschaffen Sie sich Einblicke in die Daten Ihrer Organisation, optimieren Ihre Dienstleistungen und Unternehmensprozesse und können präzisere Entscheide treffen. Die Anwendungen von ML sind äusserst vielseitig, beispielsweise:

- Präzisierung von Verbrauchs- und Beschaffungsprognosen in der Logistik
- Automatische Klassifikation von Dokumenten, E-Mails und Social-Media-Daten
- Produktempfehlungen für Kundschaft
- Analyse und Steuerung von IoT-Netzwerken
- Prognose von Störfällen
- Überwachungsaufgaben in der IT-Sicherheit
- Erkennen und Klassifizieren von Objekten in Bildern oder Tonmustern in audiovisuellen Daten

Heute stehen einfach zu bedienende und mächtige Softwarepakete für die Anwendung von Machine Learning zur Verfügung. Deren sinnvolle Nutzung erfordert allerdings gute Kenntnisse über die Wirkungsweise, die Rahmenbedingungen und die Qualitätsmessung der verschiedenen Algorithmen.

## 2 Zielpublikum

Das CAS Practical Machine Learning (PML) richtet sich an:

- Informatiker\*innen, die Machine-Learning-Komponenten in Software-Anwendungen integrieren wollen.
- Fachexpert\*innen aus IT und Business, die Machine-Learning-Techniken kennenlernen und anwenden möchten.

## 3 Ausbildungsziele

Dieses CAS befähigt Sie zur Anwendung von ML im eigenen Arbeitsgebiet sowie zur Mitarbeit in Teams, die ML-Methoden einsetzen oder implementieren. Das CAS:

- vermittelt Ihnen die methodischen Grundlagen, eine Übersicht zu Einsatzbereichen und Anwendungsmöglichkeiten von Machine Learning
- ermöglicht Ihnen, bei der Konzeption und Evaluation von Machine-Learning-Komponenten und Algorithmen mitzuarbeiten
- vermittelt Ihnen die Werkzeuge zur Bewertung der Leistungsfähigkeit von Machine-Learning-Algorithmen
- befähigt Sie, Machine-Learning-Applikationen und -Komponenten professionell zu entwickeln und mit der Programmiersprache Python zu arbeiten

Das CAS ermöglicht Ihnen eine Spezialisierung in einem oder mehreren Themenbereichen

- Image Analysis
- Text Analysis und Natural Language Processing NLP

## 4 Voraussetzungen

- Sie bringen ein Bachelor-Studium mit, typischerweise in Informatik-, Ökonomie- oder Engineering-Disziplinen und haben Spass an einer algorithmischen Denkweise.
- Notwendig sind Vorkenntnisse in Statistik und idealerweise erste Erfahrungen mit einer Skriptsprache wie R oder Python, welche im Machine-Learning- und Datenanalyse-Umfeld häufig verwendet werden.
- Wenn Sie schon länger nicht mehr mit Datenanalyse und Scripting gearbeitet haben, stellt das CAS Datenanalyse ([bfh.ch/cas-da](https://bfh.ch/cas-da)) eine ideale Vorbereitung dar.


## 5 Unterrichtssprache

Die Unterrichtssprache ist Deutsch, die Unterlagen sind teilweise in Englisch.

## 6 Durchführungsort

Berner Fachhochschule, Weiterbildung, Aarbergstrasse 46 (Switzerland Innovation Park Biel/Bienne),  
2503 Biel,  
Telefon +41 31 848 31 11, E-Mail [weiterbildung.ti@bfh.ch](mailto:weiterbildung.ti@bfh.ch).

## 7 Kompetenzprofil



### Kompetenzstufen

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

## 8 Kursübersicht

| Kurs / Lehreinheit  | Lektionen  | Stunden   | Dozierende       |
|---|------------|-----------|------------------|
| Einführung in die Denk- und Handlungsweise des Machine Learnings (fakultativ) | 16         |           | Jürgen Vogel     |
| Python  | 24         |           | Niklaus Johner   |
| Feature Engineering   | 8          |           | Werner Dähler    |
| Überwachtes Lernen  | 24         |           | Werner Dähler    |
| Nicht-überwachtes Lernen  | 16         |           | Matthias Dehmer  |
| Neuronale Netze   | 8          |           | Matthias Dehmer  |
| Wahlfach – Image Analysis   | 32         |           | Marcus Hudritsch |
| Wahlfach – ML Ops   | 16         |           | Violeta Vogel    |
| Wahlfach – Text Analytics und Natural Language Processing (NLP)               | 32         |           | Jürgen Vogel     |
| Projektarbeit: Präsentationen und Abschluss-Session                           | 8          | 90        | Div. Betreuer    |
| <b>Total (inkl. Einführung, 1 Wahlfach)</b>                                   | <b>128</b> | <b>90</b> |                  |

Das CAS umfasst insgesamt 12 ECTS-Credits. Für die einzelnen Kurse ist entsprechend Zeit für Selbststudium, Prüfungsvorbereitung etc. einzurechnen.

Für ein Wahlfach sind acht Teilnehmer\*innen erforderlich. Die Einschreibung erfolgt im Verlauf des CAS.

## 9 Kursbeschreibungen

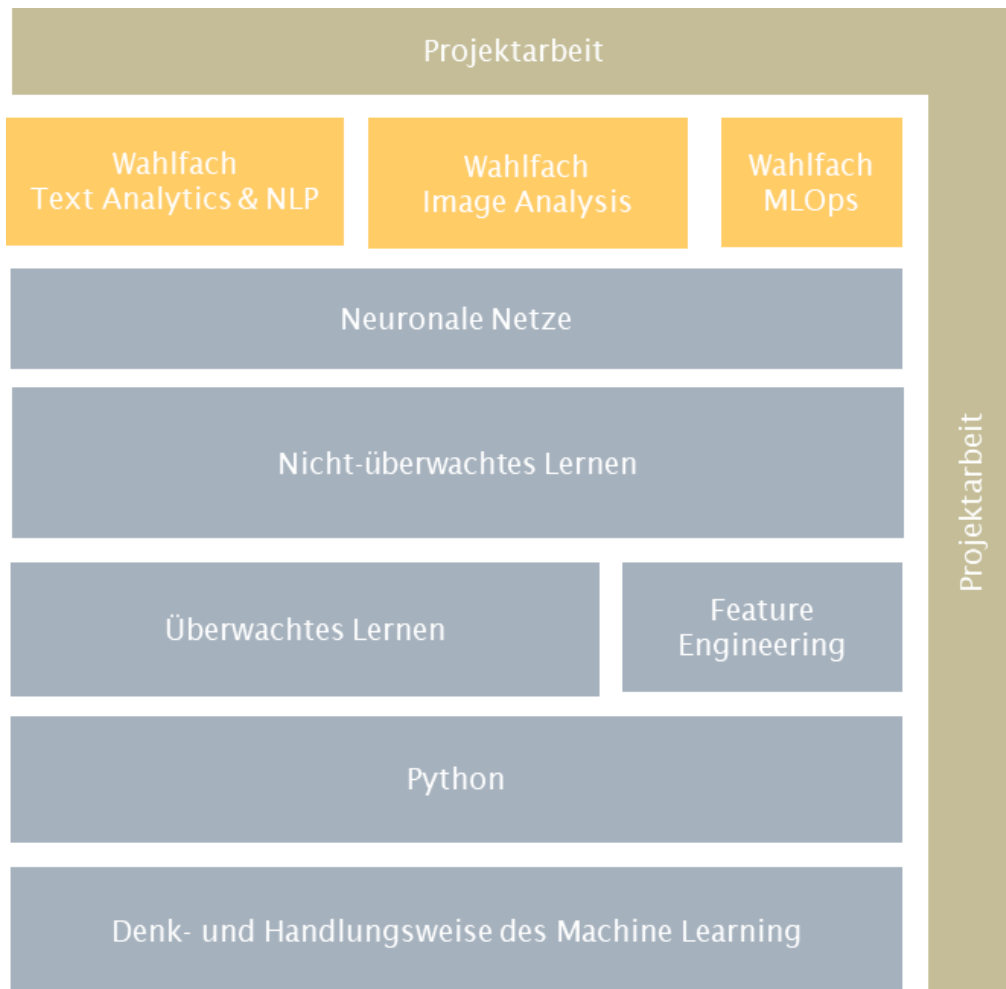
Das CAS beginnt mit einer generellen Einführung in die Denk- und Handlungsweise des Machine Learning, gefolgt von einem Kurs in Python, einem der zentralen Werkzeuge in diesem Fachgebiet. Anschliessend werden die beiden klassischen Lernmethoden – überwachtes und nicht-überwachtes Lernen – behandelt, mit jeweils ausgewählten Modellen und Algorithmen dazu. Ein wichtiger Schritt dabei ist auch die Bewertung des einzelnen und die Evaluation des optimalen Modells. Feature Extraction ist eine entscheidende Tätigkeit für alle Arten von Algorithmen, um einen Datenbestand für die Analyse geeignet vorzubereiten.

Neuronale Netze haben für verschiedenste Problemlösungen einen grossen Aufschwung genommen, insbesondere in der Bildanalyse, in der Text- und Sprachverarbeitung und in der Robotik sowie in vielen Erweiterungen der klassischen Machine-Learning-Aufgaben. In diesem Kurs wird der Grundstein für Anwendungen mit neuronalen Netzen gelegt.

Die Wahlfächer ermöglichen eine Vertiefung in einem spezifischen Gebiet. Teilnehmer\*innen besuchen eines oder mehrere Wahlfächer.

Eine Projektarbeit zu einem Thema nach Wahl, optimalerweise im eigenen beruflichen Umfeld, begleitet und vertieft die Lerninhalte.

Schematischer Aufbau des CAS Practical Machine Learning:



Nachfolgend sind die einzelnen Kurse dieses Studiengangs beschrieben.

### 9.1 Einführung in die Denk- und Handlungsweise des Machine Learnings

Diese Einführung richtet sich an Kursteilnehmende ohne grössere Vorkenntnisse in Datenanalyse und ML. Der Besuch ist optional, insbesondere für Teilnehmende, die vorgängig das CAS Datenanalyse belegt haben.

|                    |  |
|--------------------|--|
| Lernziele          | Die Teilnehmenden erhalten eine erste Orientierung zu Themen und Anwendungsbereichen von Machine Learning (ML). Sie lernen die typische Denk- und Vorgehensweise in ML-Projekten kennen und können entsprechend planen und handeln.  |
| Themen und Inhalte | <ul style="list-style-type: none"> <li>– Was ist Machine Learning?</li> <li>– Anwendungsbereiche und Anwendungsmuster</li> <li>– Arten von ML-Algorithmen</li> <li>– Typische Vorgehensweise             <ul style="list-style-type: none"> <li>– Fragestellung definieren</li> <li>– Daten beschaffen</li> <li>– Daten aufbereiten</li> </ul> </li> </ul> |

|            |  |
|------------|--|
|            | <ul style="list-style-type: none"> <li>– Methodik und Algorithmen auswählen</li> <li>– Arbeiten mit Lerndaten und Testdaten</li> <li>– Resultate evaluieren</li> <li>– Arbeiten mit Standarddatensätzen</li> <li>– Plattformen der ML-Community</li> <li>– Erste praktische Übungen mit Python zu ausgewählten Beispieldaten</li> <li>– Einführung der Methoden Decision Trees, K-Means, Naives Bayes</li> <li>– Erste Orientierung zur Semesterarbeit im CAS PML</li> </ul> |
| Lehrmittel | <ul style="list-style-type: none"> <li>– Folien/Skript</li> <li>– Literaturempfehlungen Nr. 1,2</li> <li>– Eingebettete Übungsaufgaben mit Python, Jupyter Notebooks und scikit-learn</li> </ul>   |

## 9.2 Python

Einführung in die Sprache mit Bezug auf Machine-Learning-Anwendungen. Die Einführung basiert auf Python 3.0.

|                    |   |
|--------------------|---|
| Lernziele          | Die Teilnehmenden lernen die Grundlagen der Python-Programmiersprache. Sie können Python-Skripte lesen, schreiben und ausführen. Sie kennen einen Teil der Standardbibliothek sowie die wichtigsten Bibliotheken für wissenschaftliches Rechnen. Sie können Dateien lesen und schreiben sowie Daten bearbeiten und grafisch darstellen.   |
| Themen und Inhalte | <ul style="list-style-type: none"> <li>– Datentypen und Strukturen</li> <li>– Operatoren und Vergleiche</li> <li>– Ablaufsteuerung (Schleifen, Bedingungen ...)</li> <li>– Zeichenketten (strings) Formatierung und Parsing</li> <li>– Dateien lesen und schreiben</li> <li>– Wissenschaftliches Rechnen mit numpy und scipy, scikit</li> <li>– Einführende Techniken des Feature Engineering</li> <li>– Grafische Darstellung von Daten mit matplotlib</li> <li>– Praktische Übungen zu allen Themen</li> <li>– Beispiele zum Datendateien lesen, Daten bearbeiten und Funktion fitten.</li> <li>– Pandas</li> </ul> |
| Lehrmittel         | <ul style="list-style-type: none"> <li>– Folien/Skript</li> <li>– Literaturempfehlungen Nr. 3</li> </ul>  |



### 9.3 Feature Engineering

|                    |  |
|--------------------|--|
| Lernziele          | Die Teilnehmenden erkennen die zentrale Stellung von Feature Exploration, Transformation, Konstruktion und Selektion im Machine-Learning-Prozess und können verschiedene Verfahren zur Aufbereitung ihrer Daten anwenden.  |
| Themen und Inhalte | <ul style="list-style-type: none"> <li>– Warum gute Features im Machine Learning wichtig sind</li> <li>– Analyse der vorliegenden Features (Exploration)</li> <li>– Wahl geeigneter Attribute aus vorhandenen Datensätzen (Feature-Selektion)</li> <li>– Feature-Extraktion durch Transformation</li> <li>– Dimensionsreduktion</li> <li>– Übungen in Python</li> <li>– Anwendungsbeispiele</li> </ul> |
| Lehrmittel         | <ul style="list-style-type: none"> <li>– Folien/Skript</li> <li>– Literaturempfehlungen Nr. 4,5</li> </ul>   |

### 9.4 Überwachtes Lernen

Überwachtes Lernen ist eine klassische Disziplin des Machine Learning. Einem Algorithmus wird anhand von Trainingsdaten ein bestimmtes Verhalten beigebracht, welches er dann auf neue Daten anwendet.

|                    |   |
|--------------------|---|
| Lernziele          | Die Teilnehmenden kennen die Prinzipien und einige typische Algorithmen aus dem Bereich des überwachten Lernens. Sie können Algorithmen aufgrund einer Fragestellung als angemessen auswählen, korrekt anwenden und die Ergebnisse beurteilen.  |
| Themen und Inhalte | <ul style="list-style-type: none"> <li>– Anwendungen und Eigenschaften von häufig eingesetzten Methoden: <ul style="list-style-type: none"> <li>– Klassifikationsmethoden <ul style="list-style-type: none"> <li>– Instanzbasierte Modelle</li> <li>– Regelbasierte Modelle</li> <li>– Mathematische Modelle</li> <li>– Gegenüberstellungen</li> </ul> </li> <li>– Regressionsmethoden <ul style="list-style-type: none"> <li>– Klassische Regressionsmodelle</li> <li>– Regression mit ML-Methoden</li> <li>– Gegenüberstellungen</li> </ul> </li> </ul> </li> <li>– Methoden zum Bewerten von Vorhersagemodellen <ul style="list-style-type: none"> <li>– Validierungsmethoden mittels Resampling</li> <li>– Performance-Metriken für Klassifikations- und Regressionsmodelle</li> <li>– Produktivsetzung von Modellen</li> </ul> </li> </ul> |
| Lehrmittel         | <ul style="list-style-type: none"> <li>– Folien/Skript</li> <li>– Literaturempfehlungen 6,7,8</li> </ul>  |

## 9.5 Nicht-überwachtes Lernen

Beim klassischen, nicht-überwachten Lernen versucht ein Algorithmus typischerweise, Daten in Cluster einzuteilen oder Abhängigkeiten zwischen Datenwerten zu finden. Die Nutzer\*innen kennen in der Regel die Cluster nicht im Voraus, sondern wollen anhand der automatischen Analyse neue Erkenntnisse gewinnen. Beispielsweise können Kundensegmentierungen, Bildanalysen oder Empfehlungssysteme mit nicht-überwachtem Lernen realisiert werden.

|                    |   |
|--------------------|---|
| Lernziele          | Die Teilnehmenden kennen die Prinzipien und einige typische Algorithmen aus dem Bereich des überwachten Lernens. Sie kennen Einsatzmöglichkeiten und können einen Algorithmus aufgrund der Fragestellung wählen und anwenden.   |
| Themen und Inhalte | <ul style="list-style-type: none"><li>– Partition-based Clustering, z.B. K-Means</li><li>– Hierarchisches Clustering</li><li>– Auswertung und Bewertung von Clusteraufgaben</li><li>– Recommender-Systeme und kollaboratives Filtern<ul style="list-style-type: none"><li>– Speicher- und modellbasierte Verfahren</li><li>– Matrix-Faktorisierung, latente Faktoren</li><li>– Explizite und implizite Bewertungen</li></ul></li><li>– Assoziationsanalyse<ul style="list-style-type: none"><li>– Warenkorbanalyse</li><li>– Apriori-Algorithmus</li></ul></li><li>– Anwendungsbeispiele<ul style="list-style-type: none"><li>– Detektion von Ausreißern (Anomaly Detection)</li><li>– Film-Empfehlungen (ähnlich zu Netflix) anhand des MovieLens-Datensatzes</li><li>– Kundensegmentierung</li></ul></li><li>– Übungen in Python mit scikit-learn</li></ul> |
| Lehrmittel         | <ul style="list-style-type: none"><li>– Folien/Skript</li><li>– Literaturempfehlungen 9,10</li></ul>  |

## 9.6 Neuronale Netze

Die Idee der neuronalen Netze entspringt einem vereinfachten Modell des Aufbaus und der Lernvorgänge eines biologischen Gehirns. Mit den heutigen Rechenkapazitäten können neuronale Netze ihr Potenzial immer besser ausschöpfen. Viele Erfolge in der Robotik, der Analyse von Bildern und dem dynamischen Lernen machen neuronale Netze zu einem populären Anwendungs- und Forschungsgebiet.

|                    |   |
|--------------------|---|
| Lernziele          | Die Teilnehmenden kennen die Prinzipien und einige typische Arten von neuronalen Netzen. Sie können grob abschätzen, welche Netze für welche Aufgaben in Frage kommen. Dieser Kurs dient als Vorbereitung für die weitere Vertiefung und das Arbeiten mit neuronalen Netzen in den Wahlfächern.             |
| Themen und Inhalte | <ul style="list-style-type: none"><li>– Ursprung und Idee</li><li>– Funktionsweise von neuronalen Netzen</li><li>– Arten und Typologien</li><li>– Netzwerktopologien und Eigenschaften</li><li>– Einsatzmöglichkeiten, Beispiele, Success Stories</li><li>– Schwierigkeiten mit neuronalen Netzen</li></ul> |

## 9.7 Wahlfach – Image Analysis

Hauptfokus dieses Kurses ist die Erkennung von Objekten und die fachliche Beschreibung von Bilddaten (Feature Extraction).

|                    |  |
|--------------------|--|
| Lernziele          | Die Teilnehmenden erhalten eine Übersicht, wie Bilder analysiert und danach klassischen Machine-Learning-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>  |

## 9.8 Wahlfach – Text Analytics und 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 Support-Anfrage oder eine Beschwerde? Wird unser Unternehmen auf Twitter eher positiv oder negativ gesehen? Und wie funktionieren eigentlich ChatBots und ChatGPT?

|                    |   |
|--------------------|---|
| Lernziele          | Die Teilnehmenden erhalten einen Überblick zur maschinellen Textanalyse und lernen grundlegende Verfahren und Vorgehensweise zur Gewinnung von Information aus Texten kennen, 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 Machine-Learning-basierte Verfahren (Syntax-Analyse, Vektorisierung von Texten (Feature Engineering), Word Embeddings und Deep Learning)</li> <li>– Clustering und Klassifikation von Texten (z.B. Sentiment-Analyse)</li> <li>– Praktische Anwendung obengenannter Verfahren mit Hilfe von Python und spezifischen Open-Source-Bibliotheken auf ausgewählten Beispiel-Datensätzen</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>   |

## 9.9 Wahlfach MLOps

Dieser Kurs richtet sich an Data Scientists, Informatiker\*innen und IT-Architekt\*innen, die Machine-Learning-Modelle in eine produktive Umgebung einbinden wollen. In diesem Kurs werden die klassischen Herausforderungen von MLOps, der Nachvollziehbarkeit und Produktionszyklen behandelt, aber auch die Einbettung in einer bestehenden IT-Landschaft und Geschäftsprozessen diskutiert.

|           |  |
|-----------|--|
| Lernziele | <p>Die Teilnehmenden</p> <ul style="list-style-type: none"> <li>– kennen Data Science Life Cycle und die Verbindung zu MLOps</li> <li>– kennen die Prinzipien von MLOps und verstehen den Unterschied zu DevOps</li> <li>– kennen die Komponenten von MLOps</li> <li>– kennen die Rollen von MLOps</li> <li>– kennen die Architektur von MLOps</li> <li>– verstehen die Notwendigkeit der Standardisierung von MLOps Frameworks</li> <li>– kennen unterschiedliche MLOps Tools (Best Practices von Google, AWS etc.) und können diese zur Sicherstellung der Nachvollziehbarkeit anwenden</li> <li>– verstehen, warum ein kontinuierliches Model- und Daten-Monitoring notwendig ist</li> <li>– wissen, wie man MLOps in einem Unternehmen einführen kann und wie man ein MLOps-Projekt startet</li> </ul> |
|-----------|--|

|                    |  |
|--------------------|--|
| Themen und Inhalte | <ul style="list-style-type: none"> <li>– Austausch zu den bisherigen Erfahrungen mit der Operationalisierung von Machine Learning</li> <li>– Einführung in MLOps und der Unterschied zu DevOps</li> <li>– Die Magie von Technologie-Plattformen</li> <li>– Hands-on mit GitLab</li> <li>– Einführung in das Monitoring eines Modells</li> <li>– Einführung in die Versionierung der Daten</li> </ul> |
| Lehrmittel         | <ul style="list-style-type: none"> <li>– Folien/Skript</li> <li>– GitLab</li> <li>– Jupyter Notebooks</li> <li>– Datenbank</li> <li>– Literaturempfehlungen</li> </ul>   |

### 9.10 Projektarbeit

|                       |  |
|-----------------------|--|
| Zielsetzung und Thema | <p>In der Projektarbeit (Semesterarbeit) bearbeiten die Teilnehmenden ein Projekt oder eine Fragestellung aus ihrer Firma zum Thema Machine Learning.</p> <p>Die Semesterarbeit soll den ganzen Zyklus einer typischen ML-Aufgabe umfassen, von der Fragestellung bis hin zur Evaluation der Resultate. Dabei dürfen aber Schwerpunkte auf bestimmte Prozessschritte gelegt werden. Anstelle einer Projektarbeit in der Firma können auch Themen aus eigenem Interesse heraus definiert und bearbeitet werden.</p> <p>Auch <a href="#">Kaggle Competitions</a> können bearbeitet werden, in der Regel aus der Kategorie Research, Featured, Getting started (mit Anpassungen). Das Arbeiten in Zweiertteams ist ausdrücklich möglich und erwünscht.</p>  |
| Ablauf                | <p>Die Semesterarbeit umfasst ca. 90 Stunden Arbeit und beinhaltet folgende Meilensteine (siehe auch Zeitplan):</p> <ol style="list-style-type: none"> <li>1. In der Firma ein Thema suchen, und mit Vorteil eine*n Ansprechpartner*in / Betreuer*in in der Firma definieren.</li> <li>2. Erstellen einer Projektskizze (Wordvorlage, 1–2 Seiten) und einer Kurzpräsentation (PowerPoint, wenige Slides):       <ol style="list-style-type: none"> <li>a. Titel</li> <li>b. Umfeld</li> <li>c. Problemstellung</li> <li>d. Lösungsansatz (Vorgehen, Methoden)</li> <li>e. Name und Kontaktadressen der Gruppenmitglieder und der Ansprechpartner*innen/Betreuer*innen in der Firma</li> </ol> </li> <li>3. Kurzpräsentation des Themas vor Dozierenden-Gremium, 5–10' Präsentation, 5–10' Diskussion, max. 15'.</li> <li>4. Eventuell Überarbeitung der Projektskizze gemäss Feedback.</li> <li>5. Zuordnung von Expert*innen durch die Schule.</li> <li>6. Durchführung der Arbeit in eigener Terminplanung.</li> <li>7. 2–3 Meetings mit den Expert*innen (durch Studierende organisiert)</li> <li>8. Schlusspräsentation vor Klasse, Expert*innen und Dozierende. 15' Präsentation, 15' Diskussion.</li> <li>9. Abgabe des Berichtes an die Expert*innen (per E-Mail, auf Wunsch in Papierform) und den*die CAS-Verantwortliche*n.</li> </ol> |

|                               |  |
|-------------------------------|--|
| <p>Ergebnis und Bewertung</p> | <p>Der Bericht ist in elektronischer Form als PDF-Dokument an die Betreuer*innen zu schicken und auf der Moodle-Plattform zu hinterlegen.</p> <p>Bericht: ca. 20–30 Seiten, Source Code soweit notwendig für die Projektbeurteilung.</p> <p>Die Semesterarbeit wird nach folgenden Kriterien bewertet:</p> <ul style="list-style-type: none"> <li>– Themeneingabe<br/>Projektskizze rechtzeitig und vollständig eingereicht. Themenpräsentation sorgfältig vorbereitet. Idee oder Aufgabe durchdacht und abgegrenzt, Quellen recherchiert, Rahmenbedingungen definiert, Teilziele priorisiert.</li> <li>– Methodik und Ausführung<br/>Gewählte Methode(n) systematisch und korrekt angewendet. Kreativ und agil in der Ausführung. Entscheidungen präzise begründet.</li> <li>– Ergebnis<br/>Nachvollziehbares und dokumentiertes Ergebnis. Aufgabenstellung erfüllt. Ergebnisse validiert, getestet, verifiziert. Vergleich von Zielsetzung und Ergebnis vorgenommen. Learnings und Ausblick vorhanden.</li> <li>– Bericht und Dokumentation<br/>Vollständig und verständlich. Rechtschreibung korrekt. Kapiteleinteilung sinnvoll. Angemessene Darstellung. Grafiken auf das Wesentliche reduziert und beschriftet.</li> <li>– Schlusspräsentation<br/>Roter Faden, logisches Vorgehen, klare Aussagen. Identifikation mit dem Thema spür- und erkennbar. Professionelle Präsentationstechnik, Zeitvorgaben genutzt und eingehalten. Fragen präzise und sicher beantwortet.</li> </ul> |
| <p>Vertraulichkeit</p>        | <p>Die Projektarbeiten werden als nicht-öffentlich behandelt. An den Präsentationen können jedoch auch interessierte Personen im Umfeld der Schule teilnehmen. Auf Wunsch steht ein kostenloses Standard-NDA der Schule zur Verfügung. Individuelle Vereinbarungen sind kostenpflichtig.</p>   |

## 10 Kompetenznachweis

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 Studierende |
|---|---------|--|--------------------------|
| Gesamtprüfung<br>Fragen zu allen Themengebieten +<br>Wahlfach der ersten Priorität. | 4       | Schriftliche Einzelprüfung,<br>Open Book | 0 - 100 %                |
| Projekt   | 6       | Semesterarbeit                           | 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.

## 11 Lehrmittel

Die nachfolgend aufgeführten Lehrmittel sind wesentlich für das Lernen während des geführten Unterrichtes. Sie sind durch die Studierenden zu beschaffen.

| Nr. | Titel   | Autoren   | Verlag               | Jahr |
|-----|---|---|----------------------|------|
| 1   | Data Mining   | Ian H. Witten, Eibe Frank, Mark A. Hall, Christopher J. Pal   | Morgan Kaufmann      | 2016 |
| 2   | Introduction to Machine Learning with Python                                    | A. Müller, S. Guido   | O'Reilly Media       | 2016 |
| 3   | Offizielle Python-Website   | Englisch<br><a href="https://docs.python.org/3/tutorial/index.html">https://docs.python.org/3/tutorial/index.html</a><br>Deutsch<br><a href="https://py-tutorial-de.readthedocs.io/de/python-3.3/">https://py-tutorial-de.readthedocs.io/de/python-3.3/</a> |                      |      |
| 4   | Feature Engineering for Machine Learning  | Zheng Alice, Casari Amanda  | O'Reilly             | 2018 |
| 5   | Feature Engineering and Selection   | Kjell Johnson, Max Kuhn   | CRC Press            | 2020 |
| 6   | Applied Predictive Modeling   | Kjell Johnson, Max Kuhn   | Springer             | 2018 |
| 7   | Hands-On Machine Learning with Scikit-Learn & TensorFlow (Kap 1-7)              | Aurélien Géron  | O'Reilly             | 2017 |
| 8   | scikit-learn: offizielle Website der im Kurs benutzten Library                  | <a href="https://scikit-learn.org/stable/">https://scikit-learn.org/stable/</a>   |                      |      |
| 9   | Large-Scale Collaborative Filtering for the Netflix Prize                       | Zhou et al.   | Proceedings of AAIM. | 2008 |
| 10  | Data Smart: Using Data Science to Transform Information into Insight, Chapter 2 | John W. Foreman   | John Wiley & Sons    | 2013 |

|    |   |                                       |                |      |
|----|---|---------------------------------------|----------------|------|
| 11 | Natural Language Processing with Python | Steven Bird, Ewan Klein, Edward Loper | O'Reilly Media | 2009 |
|----|---|---------------------------------------|----------------|------|

## 12 Dozierende

| Vorname Name     | Firma                             | E-Mail   |
|------------------|-----------------------------------|--|
| Jürgen Vogel     | Berner Fachhochschule             | <a href="mailto:juergen.vogel@bfh.ch">juergen.vogel@bfh.ch</a>         |
| Violeta Vogel    | Head of Data Science, Inselgruppe | <a href="mailto:violeta.vogel@bfh.ch">violeta.vogel@bfh.ch</a>         |
| Werner Dähler    | Berner Fachhochschule             | <a href="mailto:werner.daehler@bfh.ch">werner.daehler@bfh.ch</a>       |
| Marcus Hudritsch | Berner Fachhochschule             | <a href="mailto:marcus.hudritsch@bfh.ch">marcus.hudritsch@bfh.ch</a>   |
| Matthias Dehmer  | UMIT                              | <a href="mailto:matthias.dehmer@umit.at">matthias.dehmer@umit.at</a>   |
| Niklaus Johner   | 4Teamwork AG                      | <a href="mailto:niklaus.johner@gmail.com">niklaus.johner@gmail.com</a> |

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

## 13 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 31 848 32 11

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



Während der Durchführung des CAS können sich Anpassungen bezüglich Inhalte, Lernzielen, Dozierenden und Kompetenznachweisen ergeben. Es liegt in der Kompetenz der Dozierenden und der Studienleitung, aufgrund der aktuellen Entwicklungen in einem Fachgebiet, aufgrund 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

Aarbergstrasse 46 (Switzerland Innovation Park Biel/Bienne)

2503 Biel

Telefon +41 31 848 31 11

E-Mail: [weiterbildung.ti@bfh.ch](mailto:weiterbildung.ti@bfh.ch)

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

[bfh.ch/cas-pml](https://bfh.ch/cas-pml)