

Machine Learning

Data Science und künstliche Intelligenz

Die Themen Data Science, künstliche Intelligenz und Machine Learning bilden heute das Rückgrat jeder IoT- oder Digitalisierungslösung, versteckt sich dahinter doch die eigentliche Wertschöpfung. Dieses Training gibt einen Einblick, nach welchen Methoden und mit welchen Technologien digitale Daten aufbereitet, analysiert und für eine selbstlernende Business-Optimierung genutzt werden können. Der Kurs ist an den Erfordernissen der Industrie ausgerichtet und mit vielen interaktiven Übungen versehen, die sowohl für den direkten Anwender als auch den Entscheider aufbereitet sind. Somit wird ein fundierter sowie breiter Einstieg in die Bereiche künstliche Intelligenz und Machine Learning ermöglicht. Dabei werden die benötigten Kernkompetenzen für die Ausarbeitung neuer oder Bewertung bestehender Konzepte vermittelt und der Praxisbezug hergestellt.

Kursinhalt

- Einführung Data Science, Machine Learning und Künstliche Intelligenz
- Grundlagen Python rund um Datenverarbeitung, Statistik und Datenvisualisierung
- Machine Learning Workflow
- Lernszenarien und ihre Einsatzgebiete (u. a. Predictive Analytics, Bots, Empfehlungsdienste)
- Machine Learning Methoden im Vergleich (vom Decision Tree bis hin zu Deep Learning)- Künstliche neuronale Netze- Entscheidungsbäume- Support Vector Machines - Clustering
- Modelle richtig bewerten und validieren
- Überblick an Software und Tools
- Anwendungs- und Praxisbeispiele (Was ist Hype und was hat Potential?)
- Fragen und Ängste im gesellschaftlichen Kontext
- durchgehende, interaktive Hands-On mit Übungen

E-Book Sie erhalten das ausführliche deutschsprachige Unterlagenpaket aus der Reihe ExperTeach Networking – Print, E-Book und personalisiertes PDF! Bei Online-Teilnahme erhalten Sie das E-Book sowie das personalisierte PDF.

Zielgruppe

Der Kurs wendet sich an IT-affine Teilnehmer (vom Anwender bis hin zum Entscheider), die einen breiten Einstieg in die Themen Data Science, künstliche Intelligenz und Machine Learning für die Anwendung suchen.

Voraussetzungen

Die Teilnehmer sollten ein Verständnis und Interesse an den Trendthemen Digitalisierung, Big Data und IoT mitbringen. Grundlegende Programmierkenntnisse sind von Vorteil.

Dieser Kurs im Web



Alle tagesaktuellen Informationen und Möglichkeiten zur Bestellung finden Sie unter dem folgenden Link: www.experteach.ch/go/KIML

Vormerkung

Sie können auf unserer Website einen Platz kostenlos und unverbindlich für 7 Tage reservieren. Dies geht auch telefonisch unter 06074 4868-0.

Garantierte Kurstermine

Für Ihre Planungssicherheit bieten wir stets eine große Auswahl garantierter Kurstermine an.

Ihr Kurs maßgeschneidert

Diesen Kurs können wir für Ihr Projekt exakt an Ihre Anforderungen anpassen.

Training	Preise zzgl. MwSt.
Termine in Deutschland	3 Tage CHF 2.415,-
Online Training	3 Tage CHF 2.415,-
Termin/Kursort	Kurssprache Deutsch
17.06.-19.06.24 Frankfurt	27.11.-29.11.24 Frankfurt
17.06.-19.06.24 Online	27.11.-29.11.24 Online
23.09.-25.09.24 Frankfurt	03.02.-05.02.25 Frankfurt
23.09.-25.09.24 Online	03.02.-05.02.25 Online

Stand 10.03.2024



Inhaltsverzeichnis

Machine Learning – Data Science und künstliche Intelligenz

1 Machine Learning im Überblick	5.2.3 Reinforcement Learning	9.1.5 Die bekanntesten Chat-Bots
1.1 Was ist Machine Learning?	5.3 Aufgabenstellung	9.2 Empfehlungsdienste
1.1.1 Schon wieder Statistik	5.4 Was gibt es sonst noch?	9.2.1 Was ist ein Empfehlungssystem?
1.1.2 Die Zeit ist reif.	5.5 Zusammenfassung	9.2.2 Einflussgrößen
1.1.3 Künstliche Intelligenz		9.2.3 Beispiele
1.2 Aktuelle Beispiele	6 Vorbereitung der Daten	9.2.4 Der Netflix-Preis
1.2.1 AlphaGo	6.1 Intro und Motivation	9.3 Bilderkennung
1.2.2 Spracherkennung	6.2 Grundlagen: Features und Merkmale	9.3.1 Bilderkennung für das autonome Fahren
1.2.3 Online-Shopping	6.3 Bereinigung der Daten	9.3.2 Medizinische Bilderkennung
	6.3.1 Ausreißer	9.3.3 Ausblick
2 Machine Learning von A bis Z	6.3.2 Expertenwissen	9.4 Industrielle Anwendung und Herausforderung
2.1 Intro und Motivation	6.4 Feature Engineering	9.4.1 Predictive Maintenance
2.2 Grundlagen am Beispiel	6.4.1 Encoding	9.4.2 Predictive Quality
2.2.1 Vorbereitung der Daten	6.4.2 Runden, Diskretisierung	9.5 Natural Language Processing
2.2.2 Feature-Extraction	6.5 Feature Selection	9.5.1 Schrifterkennung
2.2.3 Feature Engineering	6.5.1 Korrelationen	9.5.2 Syntaktische Aufgaben
2.2.4 Training	6.5.2 Reduzierung	9.5.3 Semantische Aufgaben
2.2.5 Performance	6.6 Zusammenfassung	9.5.4 Weitere Anwendungsfelder
2.2.6 Optimierung		9.5.5 Techniken am Beispiel Sentimentanalyse
2.2.7 Validierung	7 Von Bäumen und Netzen	
2.3 Zusammenfassung	7.1 Intro und Motivation	10 ML-Methoden im Vergleich
	7.2 Abgrenzung zwischen Bäumen und Netzen	10.1 Intro und Motivation
3 Deskriptive Statistik	7.2.1 Entscheidungsbaum	10.2 Neue ML-Modelle
3.1 Intro und Motivation	7.2.2 Random Forest	10.2.1 Support Vector Machines
3.1.1 Survivorship Bias und die Excel-Frage	7.2.3 Perceptron	10.2.2 K-Nearest Neighbors
3.2 Grundlagen und Hands-On	7.2.4 Multi Layer Perceptron	10.2.3 Clustering-Methoden
3.3 Python - die Grundlagen	7.2.5 Abgrenzung zum Deep Learning	10.3 Testdatensätze
3.3.1 Scientific Computing in Python mit numpy und pandas	7.3 Klassifizierung von Murmeln	10.3.1 Entscheidungsbaum
3.3.2 Datenvisualisierung in Python mit matplotlib	7.3.1 Manuelle Trennung	10.3.2 Multi Layer Perceptron (MLP)
3.4 Grundlagen der Statistik	7.3.2 Aufbau der Daten-Pipeline	10.3.3 Deep MLP
3.4.1 Verteilungen	7.3.3 K-Means	10.3.4 K-Nearest Neighbors
3.4.2 Zentralwerte	7.3.4 Random Forest	10.3.5 Support Vector Machines
3.4.3 Klassenbildung	7.3.5 Multi-Layer-Perceptron	10.3.6 K-Means
3.4.4 Korrelationen	7.3.6 Features	10.3.7 Gaussian Mixture
3.5 Zusammenfassung	7.4 Zusammenfassung	10.3.8 DBSCAN
		10.4 Zusammenfassung
4 Anpassungen und Minimierungen	8 Validierung und Performance	11 Software und Tools
4.1 Intro und Motivation	8.1 Intro und Motivation	11.1 Intro und Motivation
4.1.1 Häufige Verteilungen	8.2 Performanceanalyse	11.2 Machine Learning as a Service
4.1.2 Normalverteilungen und Fits	8.2.1 Vorhersagewahrscheinlichkeiten	11.3 Machine Learning in Python
4.1.3 Erwartungen und Erfahrungen	8.2.2 Falsch Positive - Fall-Out	11.3.1 Weitere Pakete
4.2 Fitmethoden	8.2.3 Auch auf die Sensitivity kommt es an.	11.4 Andere Frameworks
4.2.1 Die Methode der kleinsten Quadrate	8.2.4 Confusion Matrix	11.4.1 Weitere Open Source Frameworks
4.2.2 Likelihood Fits	8.2.5 Abgeleitete Kennzahlen und Raten	11.4.2 Proprietäre Lösungen
4.3 Fits bewerten	8.2.6 ROC und AUC	11.5 Zusammenfassung
4.3.1 Goodness of Fit	8.3 Validierungsbeispiele	
4.3.2 Viele Dimensionen	8.3.1 Train-Test-Split	12 Gesellschaftliche Aspekte
4.3.3 Bias-Variance-Dilemma und Overfitting	8.3.2 K-Faltigkeiten	12.1 Intro und Motivation
4.3.4 Fitergebnisse richtig interpretieren	8.3.3 Kreuzvalidierung	12.2 Anreize für eine Diskussion
4.4 Materie-Antimaterie-Asymmetrie	8.4 Zusammenfassung	12.3 Robotergesetze
4.5 Zusammenfassung		12.4 Biased Data und Potentiale
5 Lernszenarien und Aufgabenstellung	9 Anwendungen und Praxisbeispiele	12.5 Technologische Singularität und die großen Fragestellungen
5.1 Intro und Motivation	9.1 Chatbots	12.6 Unterstützen statt Ersetzen
5.2 Lernszenarien	9.1.1 Was ist ein Chatbot?	12.7 Datenschutz und Privacy
5.2.1 Supervised Learning	9.1.2 Weitere Bot-Typen	12.8 Das Lernen
5.2.2 Unsupervised Learning	9.1.3 Turing-Test	
	9.1.4 Funktionsweise	

