

Grundlagen der Künstlichen Intelligenz(KI) und des KI-Projektmanagements



DIHSÜD

Erich Teppan

Ziel der Lehrveranstaltung

- Zwei Kernfragen bzgl. Anwendung von KI in der Wirtschaft:
 1. Welche unternehmerischen Aufgaben können grundsätzlich auf Basis der aktuell zur Verfügung stehenden KI-Technologien gelöst zu werden?
 2. Wie schwierig (d.h. wie kostenintensiv und wie risikobehaftet) ist die Lösung dieser Aufgaben mit KI?
- Um diese Fragen zu beantworten braucht man Wissen über:
 1. Betriebliche Prozesse, Personal und Kostenstrukturen
 - Kann nicht über eine Lehrveranstaltung vermittelt werden!
 2. Methoden der KI und welche Probleme mit welcher Methode gelöst werden können
 - Fallbeispiele ohne Kenntnis über die Methode können nicht generalisiert bzw. In weitere Anwendungsfälle übergeleitet werden
 3. Entmystifizierung von KI
 - KI als Black-Box führt zu
 - starker Überschätzung der Möglichkeiten von KI oder
 - Ablehnung

Inhalt

1. Tag (Vormittag):

- Was ist „Künstliche Intelligenz (KI)“?
 - Geschichte
 - Ziele
 - Überblick über Methoden und Fragestellungen

1. Tag (Nachmittag):

- Modellieren und Lösen
 - Zustandsbasierte Suche
 - ~~Logik und Constraints~~

2. Tag (Vormittag):

- Maschinelles Lernen
 - Warenkorbanalyse
 - ~~Clustering~~

2. Tag (Nachmittag):

- KI-Projektmanagement
 - KI Fragestellungen erkennen und beurteilen
 - Umsetzung Vorbereiten / Rahmenbedingungen
 - Risikomanagement

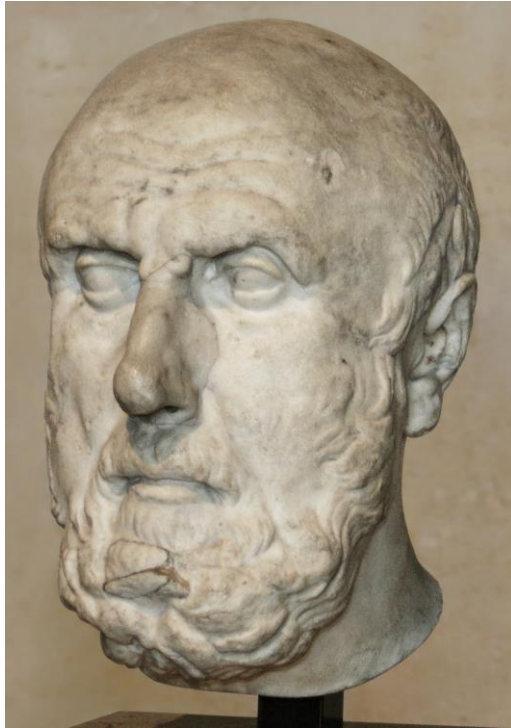
Was ist „Künstliche Intelligenz“?

- Es gibt keine allgemeingültige Definition
 - Der Begriff der Intelligenz ist auch in der Psychologie nicht wirklich definiert
- Allgemeines Begriffsverständnis, welches sich verändert bzw. erweitert
- Elementar für das Begriffsverständnis sind die Ziele
 - Ziele von KI haben änder(te)n sich über die Zeit
 - Geschichtliche Betrachtung hilfreich, um die Ziele zu verstehen
- In Abhängigkeit von den Zielen können relevante Probleme / Fragestellungen identifiziert werden
- In Abhängigkeit von den Problemen können Methoden identifiziert bzw. entwickelt werden

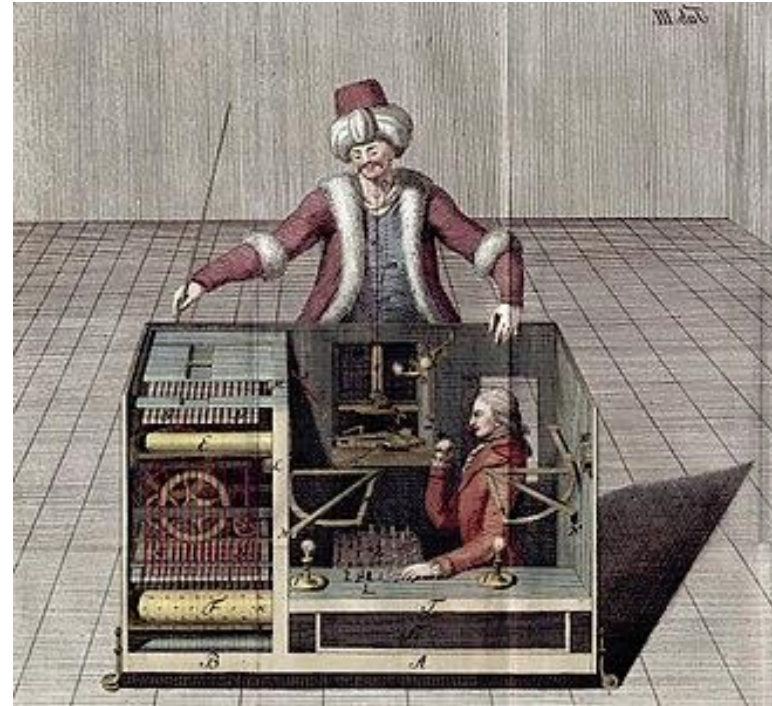
Eine kürzere Geschichte der KI

- 1940er:
 - Kybernetik (N. Wiener)
 - Konnektionismus / Neuronale Netze (W. S. McCulloch, W. Pitts)
 - Transistor (J. R. Pierce)
- 1950er:
 - Neuronale Netze (M. Minsky, F. Rosenblatt)
 - Begriff „Artificial Intelligence“ (J. McCarthy)
 - Ziel: „starke“ KI
 - XOR Problem führt zu erstem KI Winter
- 1970er:
 - Ziel: „schwache“ KI
 - Expertensysteme
 - Logik, Regel-basiert
- 1980er:
 - Renaissance von Neuronalen Netzen und maschinellen Lernmethoden
 - Kleinere Erfolge, z.B. Hopfield Netze für Travelling Salesman Problem
- 1990er:
 - Deep Blue
 - Wissensbasierte Systeme
- 2000er:
 - High Performance Computing
 - Monte Carlo Tree Search
 - Deep Learning
- 2010er:
 - Deep Learning
 - Alpha Go (DeepMind)
- 2020er:
 - Large Language Models (LLMs)
 - ChatGPT

Eine längere Geschichte der KI



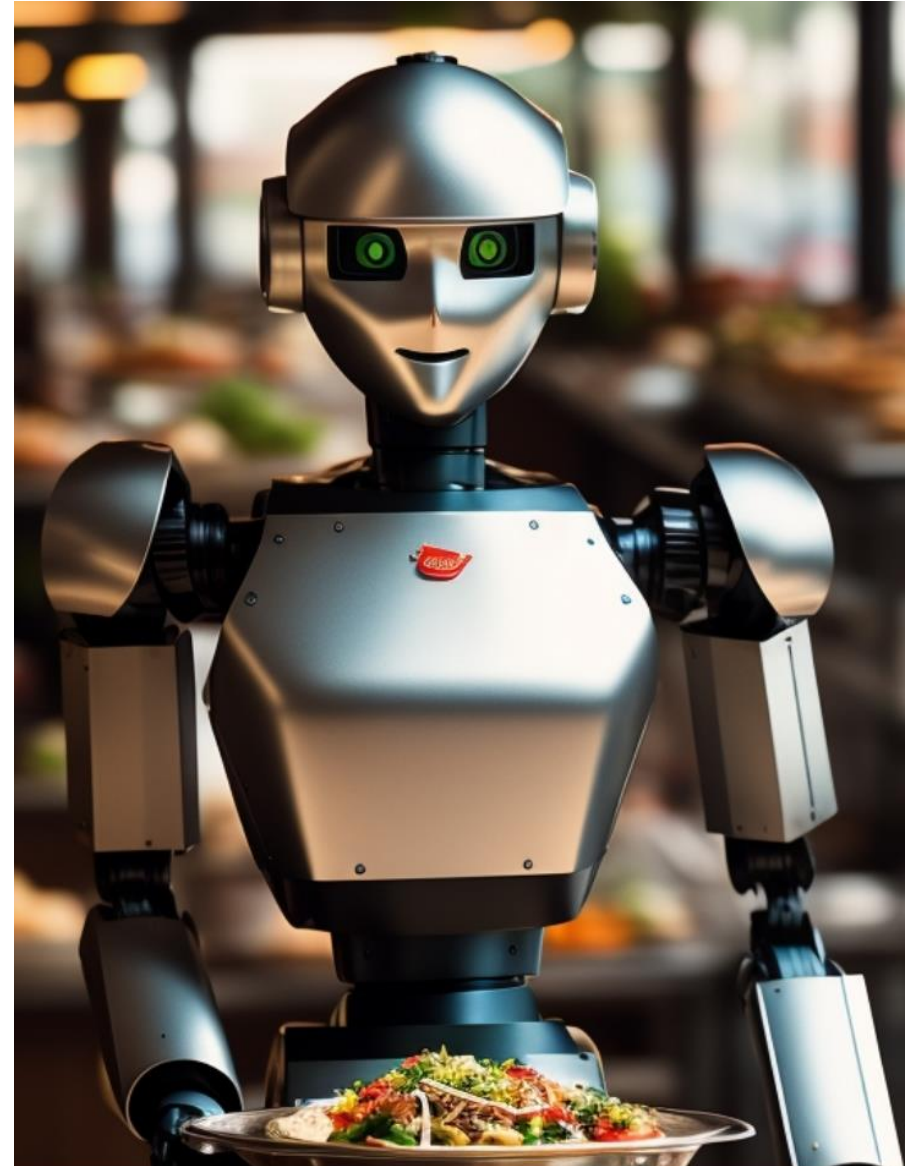
- Antike
 - hypothetischer Syllogismus (Chrysippos von Soloi, ca. 300 v.Chr.)
 - Lehre des Schlussfolgerns
 - Aussagenlogik



- Schachtürke (Kupferstich von Racknitz, 1789)
 - Der Wunsch denkende Maschinen zu bauen ist alt

Ziele von KI

- starke KI:
 - Generelle Intelligenz
 - Problem-unabhängig
 - Ursprüngliche Vision
 - Denkende Maschinen ähnlich dem Menschen
- Schwache KI:
 - Systeme/Algorithmen für spezielle Probleme, deren Lösung nach allgemeiner Ansicht höhere kognitive Fähigkeiten erfordert



Ziele von KI

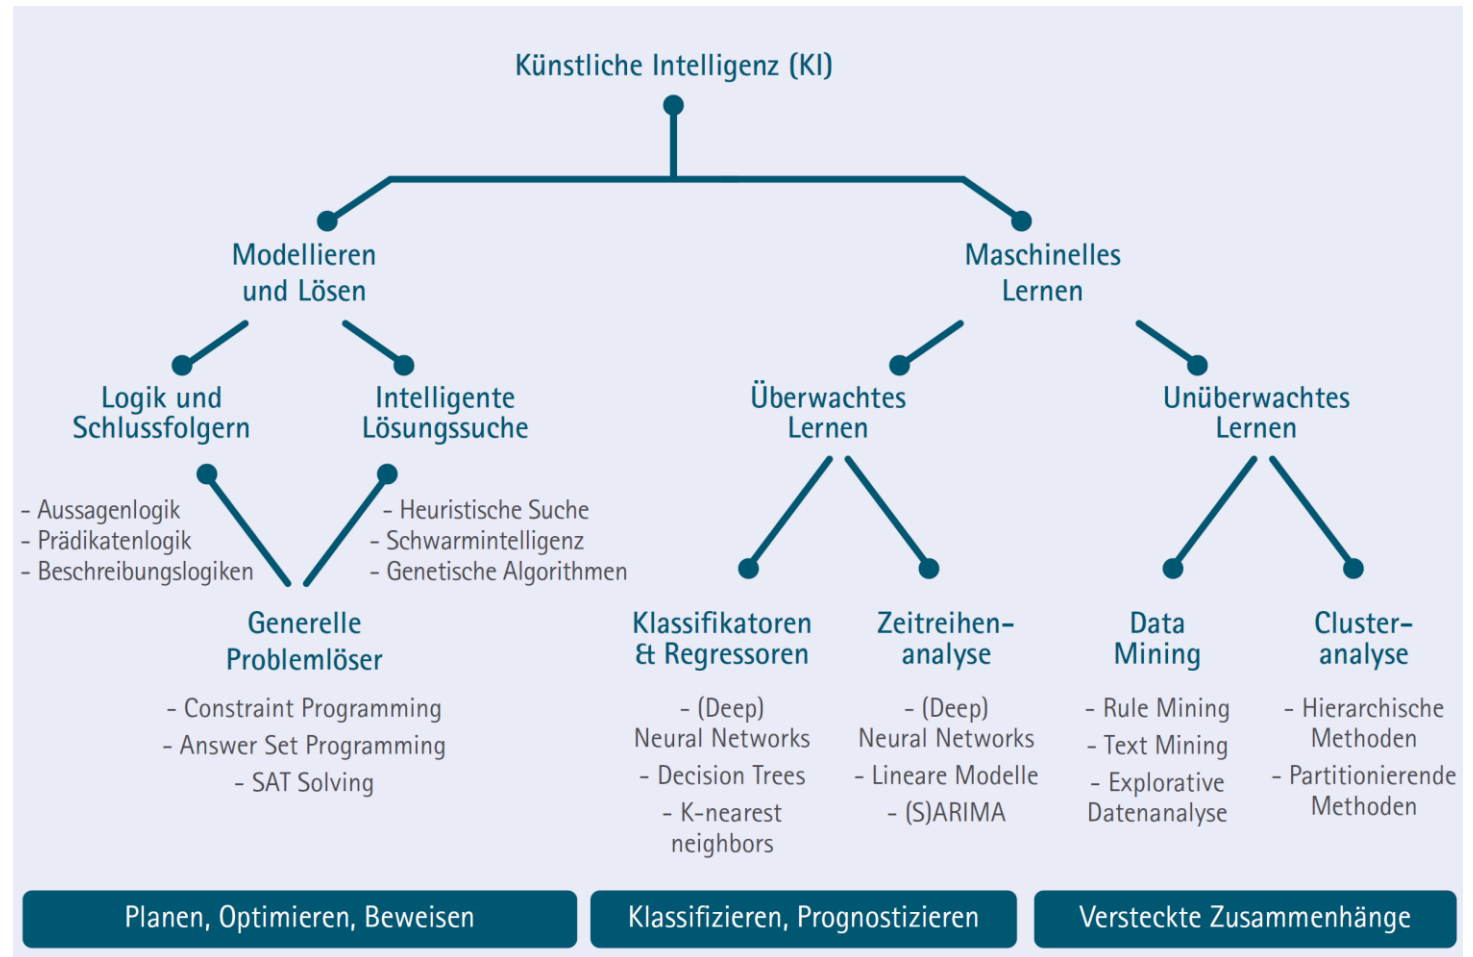
- Artificial Intelligence – A modern approach, Stuart Russel und Peter Norvig:

	menschlich	rational
Denken	Menschliches Denken	Rationales Denken
Verhalten	Menschliches Verhalten	Rationales Verhalten

- Was heißt ‚menschlich‘?
 - Ist ‚menschlich‘ überhaupt gut?
 - Rationalität ist ein Konzept, welches in vielen Bereichen formal klar definierbar ist
 - Z.B. Entscheidungstheorie, Spieltheorie
- Was ist ‚Denken‘?
 - Wie misst man einen Gedanken?
 - Verhalten kann man beobachten, also messen
 - Z.B. die getroffene(n) Entscheidung(en)
- Menschliches Denken -> starke KI
- Rationales Verhalten -> schwache KI

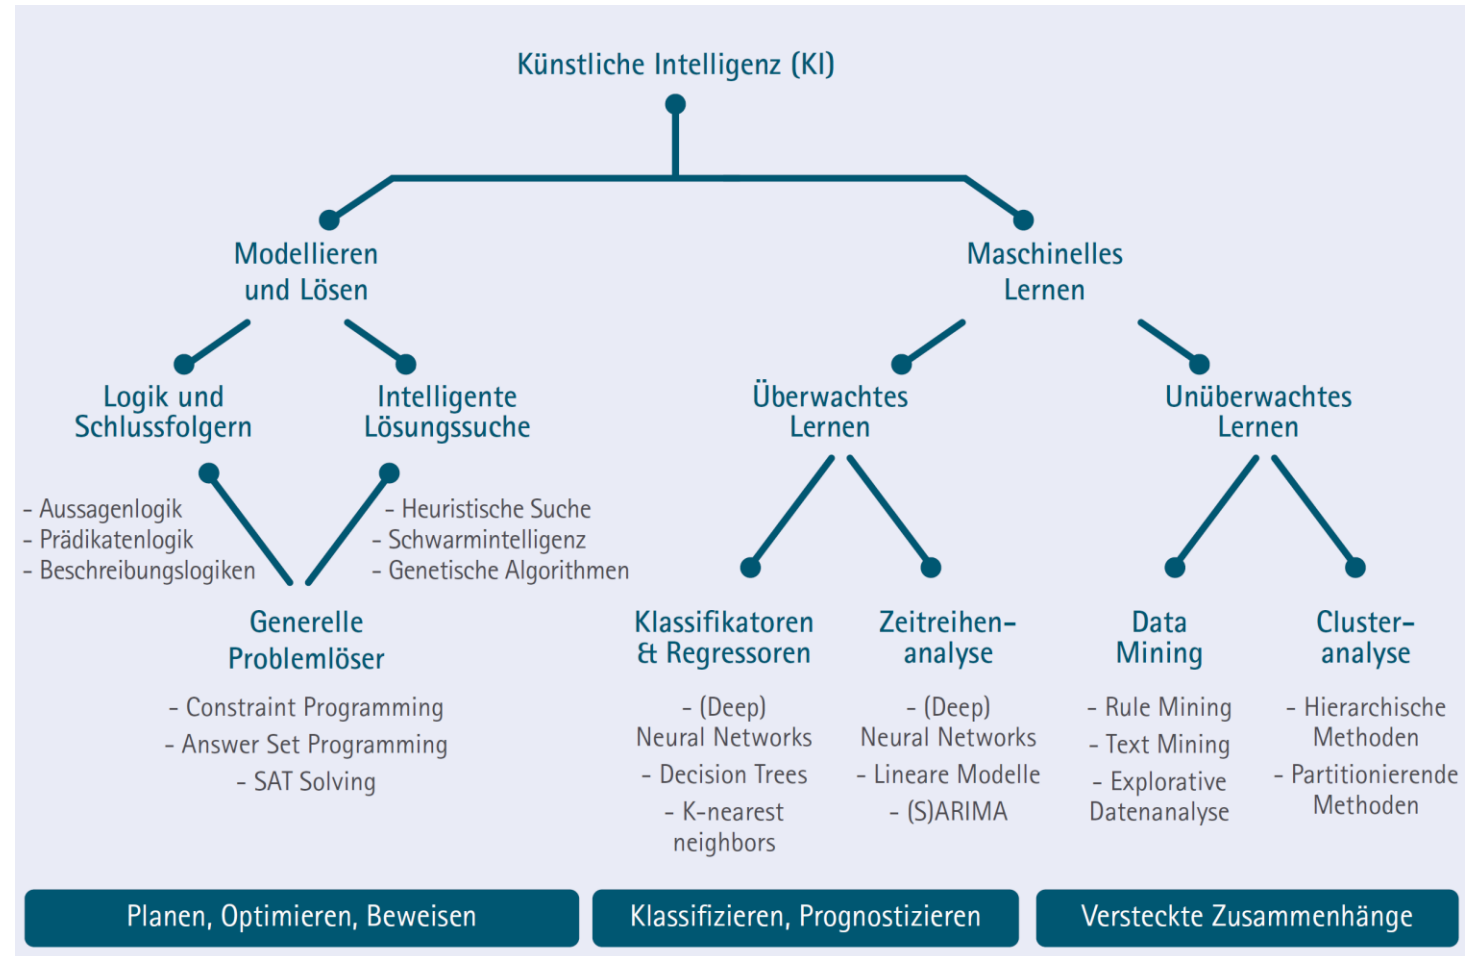
Methoden und Fragestellungen: Überblick

- Klassische KI:
 - Modellieren und Lösen
 - Symbolische KI
 - Modell-basiert
 - Logik
 - Regeln
 - Zustandsräume
 - Etc.
 - “Good, old fashioned AI”
 - Dominiert bis in die 90er
 - Expertensysteme
 - Knowledge Representation and Reasoning



Methoden und Fragestellungen: Überblick

- Überwachtes Maschinelles Lernen:
 - Trainingsdatensatz
 - Regression / Klassifikation
 - Function Fitting
 - Finde die richtigen Modellparameter
 - Derzeit dominieren subsymbolische Ansätze
 - Deep Learning
- Unüberwachtes Maschinelles Lernen
 - Finde Versteckte Zusammenhänge
 - Datensatz ist nicht zum Training, sondern selbst das Analyseobjekt
- ~~Reinforcement Learning~~
- ~~Self-Supervised Machine Learning~~



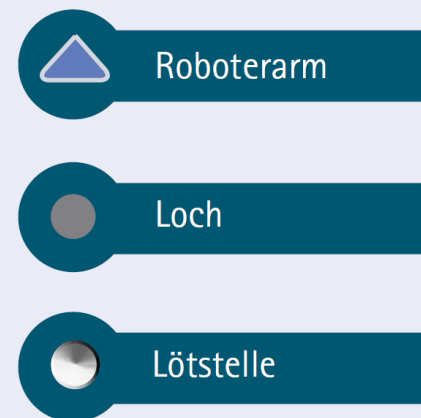
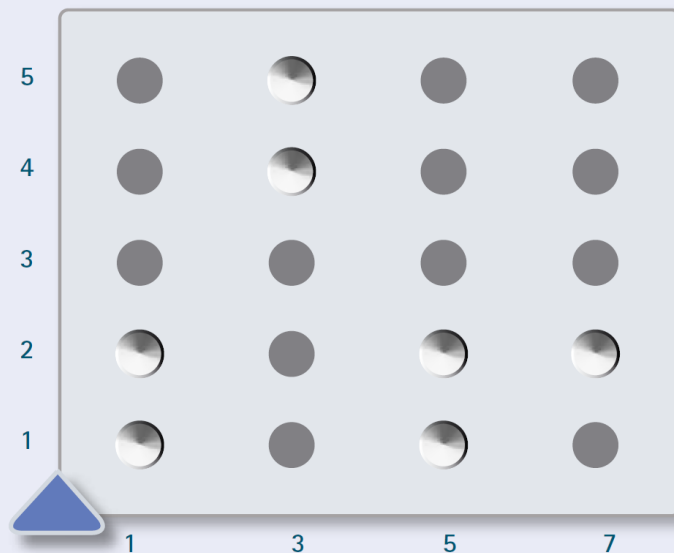
Modellieren und Lösen

- Zentrale Komponente: Beschreibung eines Teiles der Welt, z.B.
 - Verkehrsnetz
 - Schachregeln
 - Spielzustände
- Modell, Spezifikation oder Wissensbasis
 - Verschiedene Disziplinen der klassischen KI unterscheiden sich in der Sprache, welche zum Modellieren verwendet wird, z.B.
 - Aussagenlogik -> SAT Solving
 - Prädikatenlogik -> Logische Programmierung (Answer Set Programs, Prolog)
 - Zustandsräume -> Zustandsbasierte Suche, Heuristische Suche, Lokale Suche

Modellieren und Lösen: Beispiel

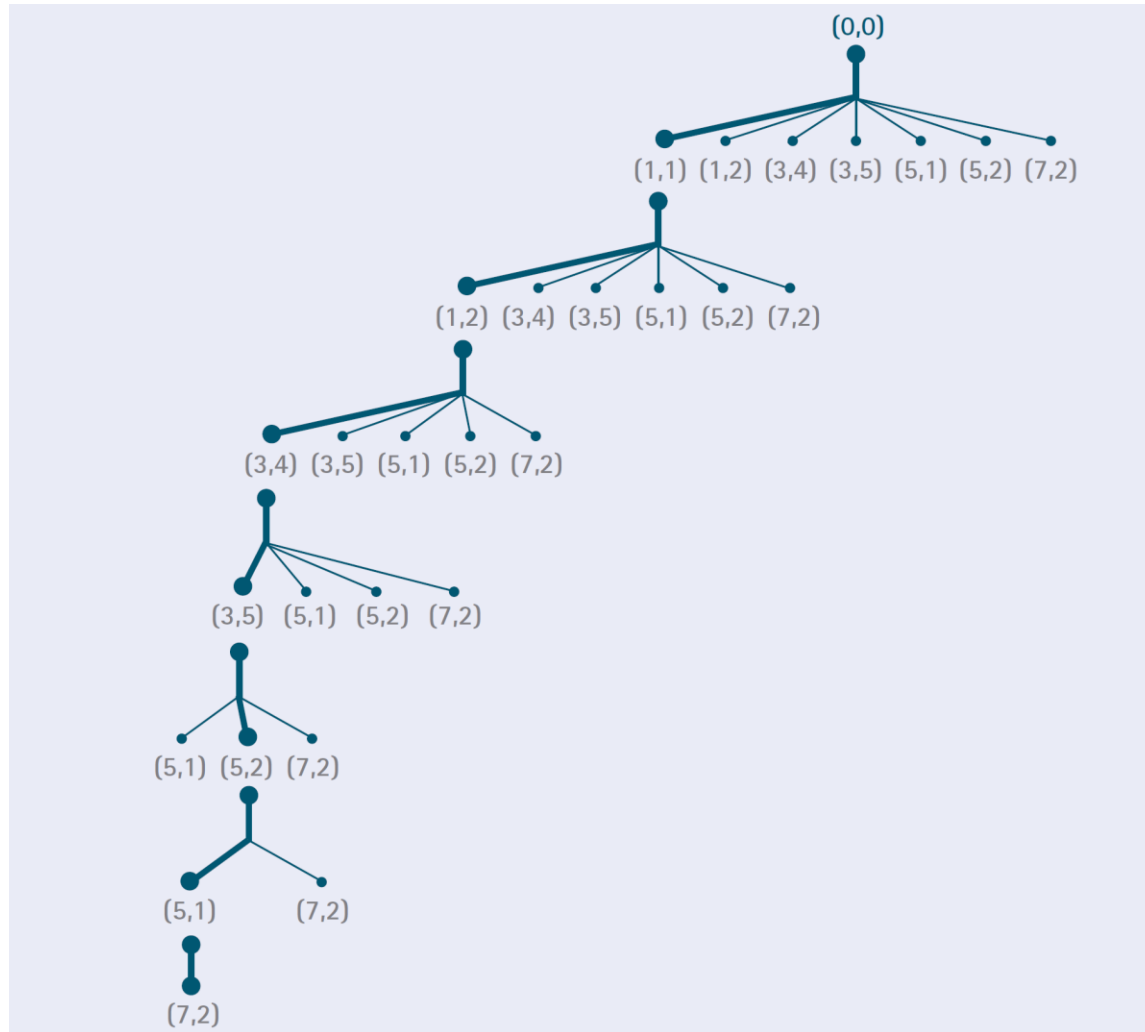
- Wegeoptimierung bei Lötrobotern

- automatisiert Lötstellen auf einer Lochrasterplatte herstellen
- Viele Platinen mit dem selben Lötmuster
- Reihenfolge, in welcher die Lötstellen abgearbeitet werden, hat Einfluss darauf, wie schnell eine Platine fertig gelötet ist
- Problem des Handlungsreisenden, Rundreiseproblem
- Ziel: kostenoptimale (Zeit) Rundreise: jeder Punkt genau einmal, zum Schluss zurück zum Ausgangspunkt

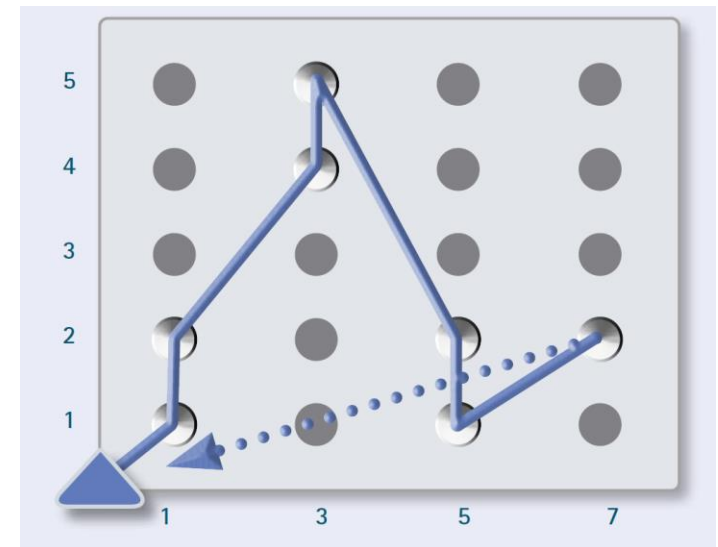


- Stellung $[0,0]$ zum Tausch der Platine
- Horizontale Abstände doppelt so groß wie vertikale
- Horizontale und vertikale Bewegung gleichzeitig

Modellieren und Lösen: Beispiel

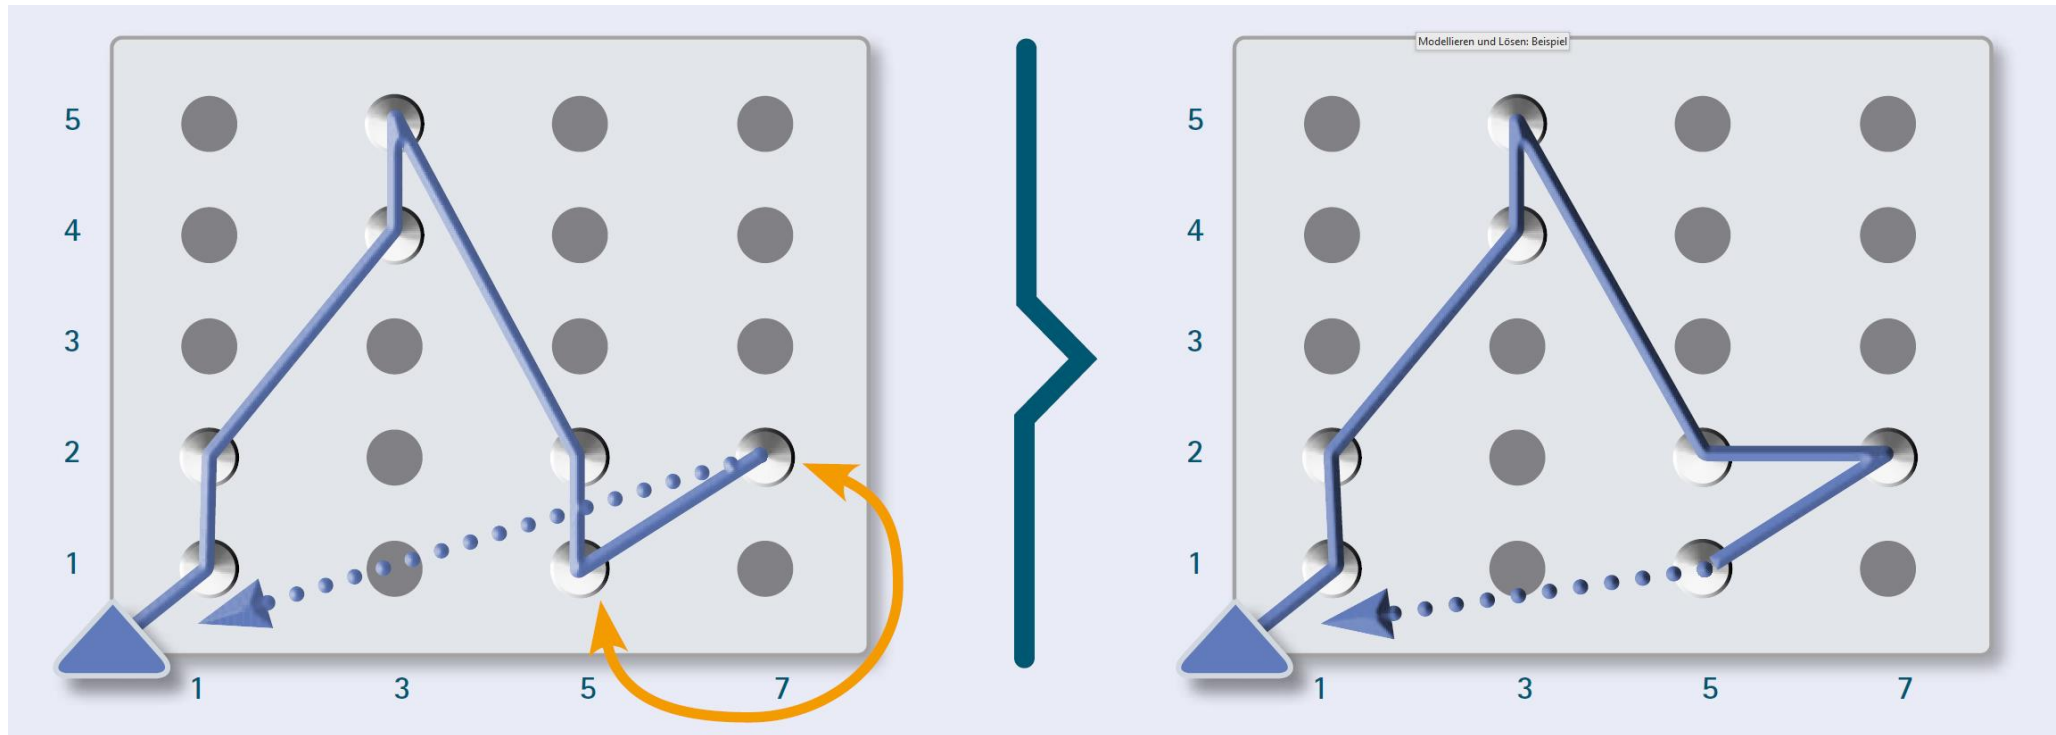


- Aufbau eines Suchbaums
- Reihenfolge, in welcher Knoten entwickelt werden abhängig von Algorithmus
- Gierige-Besten Suche (Greedy Best First Search)
 - Expandiere zuerst Knoten, welche laut einer Heuristik (Bewertungsfunktion) die besten sind
 - Beispielheuristik: geografisch nächste Löcher zuerst



Modellieren und Lösen: Beispiel

- Lokale Suche
 - Start mit Lösung
 - Verbessere schrittweise die Lösung



Überwachtes Maschinelles Lernen

- Lerne Funktion / Funktionsparameter
- Lerne wie Input mit Output zusammenhängt
- Lernen basiert auf Trainingsdaten
- Trainingsdaten beinhalten die richtigen Antworten

nicht-diskrete Antwort->Regression

diskrete Antwort->Klassifikation

ID	Feature 1	Feature 2	...	Feature n	Antwort
a	Wert _{a,1}	Wert _{a,2}	...	Wert _{a,n}	Antwort für a
b	Wert _{b,1}	Wert _{b,2}	...	Wert _{b,n}	Antwort für b
...
m	Wert _{m,1}	Wert _{m,2}	...	Wert _{m,n}	Antwort für c

Klassifikation: Beispiel

- Spam Erkennung

	„Black Jack“	„Casino“	„Gewinn“	„Bargeld“	„Cash“	„Kostenlos“	Spam
E-Mail 1	Ja	Ja	Ja	Nein	Ja	Nein	Ja
E-Mail 2	Ja	Ja	Nein	Ja	Nein	Nein	Ja
E-Mail 3	Nein	Ja	Ja	Ja	Nein	Nein	Ja
E-Mail 4	Nein	Nein	Ja	Ja	Ja	Nein	Ja
E-Mail 5	Nein	Nein	Nein	Nein	Nein	Nein	Nein
E-Mail 6	Nein	Nein	Nein	Nein	Nein	Ja	Nein
E-Mail 7	Nein	Nein	Nein	Nein	Ja	Nein	Nein
E-Mail 8	Nein	Nein	Nein	Ja	Nein	Nein	Nein

Klassifikation: Beispiel

- Spam Erkennung
- K-nearest neighbors Methode

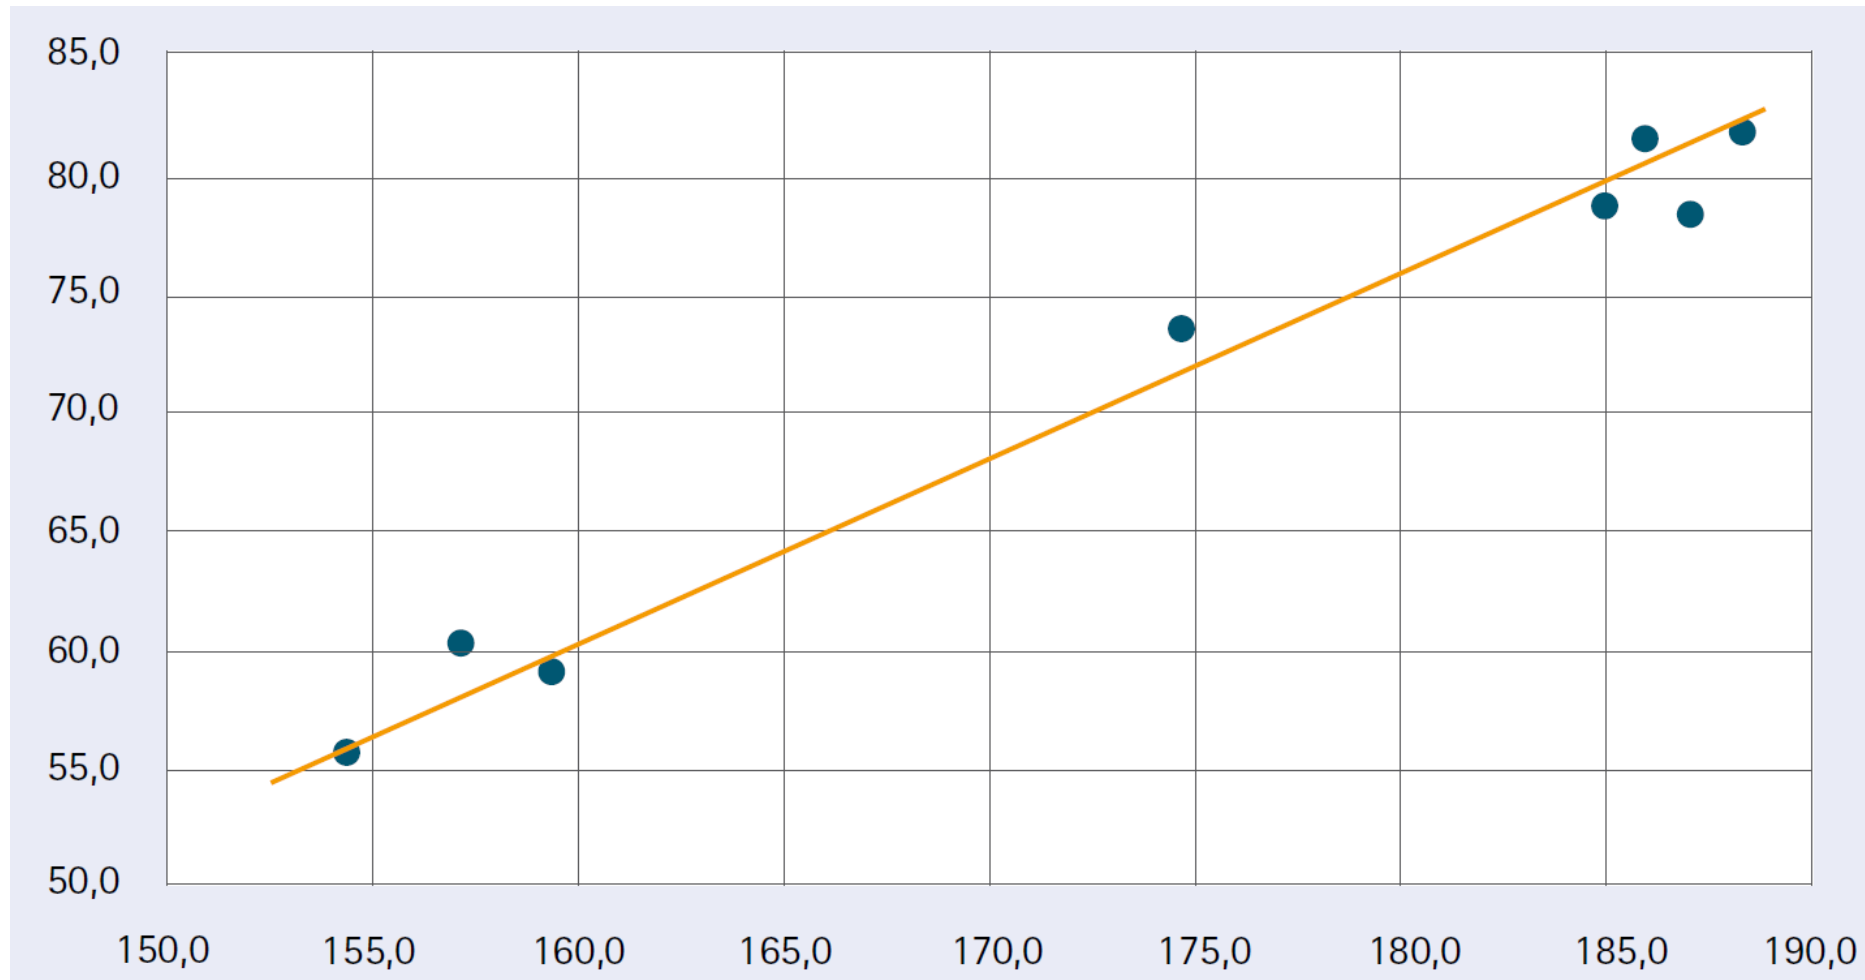
	„Black Jack“	„Casino“	„Gewinn“	„Bargeld“	„Cash“	„Kostenlos“	Spam	Gleiche Merkmale mit der neuen E-Mail
E-Mail 1	Ja	Ja	Ja	Nein	Ja	Nein	Ja	4
E-Mail 2	Ja	Ja	Ja	Ja	Nein	Nein	Ja	4
E-Mail 3	Nein	Ja	Ja	Ja	Nein	Nein	Ja	3
E-Mail 4	Nein	Nein	Ja	Ja	Ja	Nein	Ja	5
E-Mail 5	Nein	Nein	Nein	Nein	Nein	Nein	Nein	2
E-Mail 6	Nein	Nein	Nein	Nein	Nein	Ja	Nein	1
E-Mail 7	Nein	Nein	Nein	Nein	Ja	Nein	Nein	3
E-Mail 8	Nein	Nein	Nein	Ja	Nein	Nein	Nein	3
neue E-Mail	Ja	Nein	Ja	Ja	Ja	Nein	??? Ja	

Regression: Beispiel

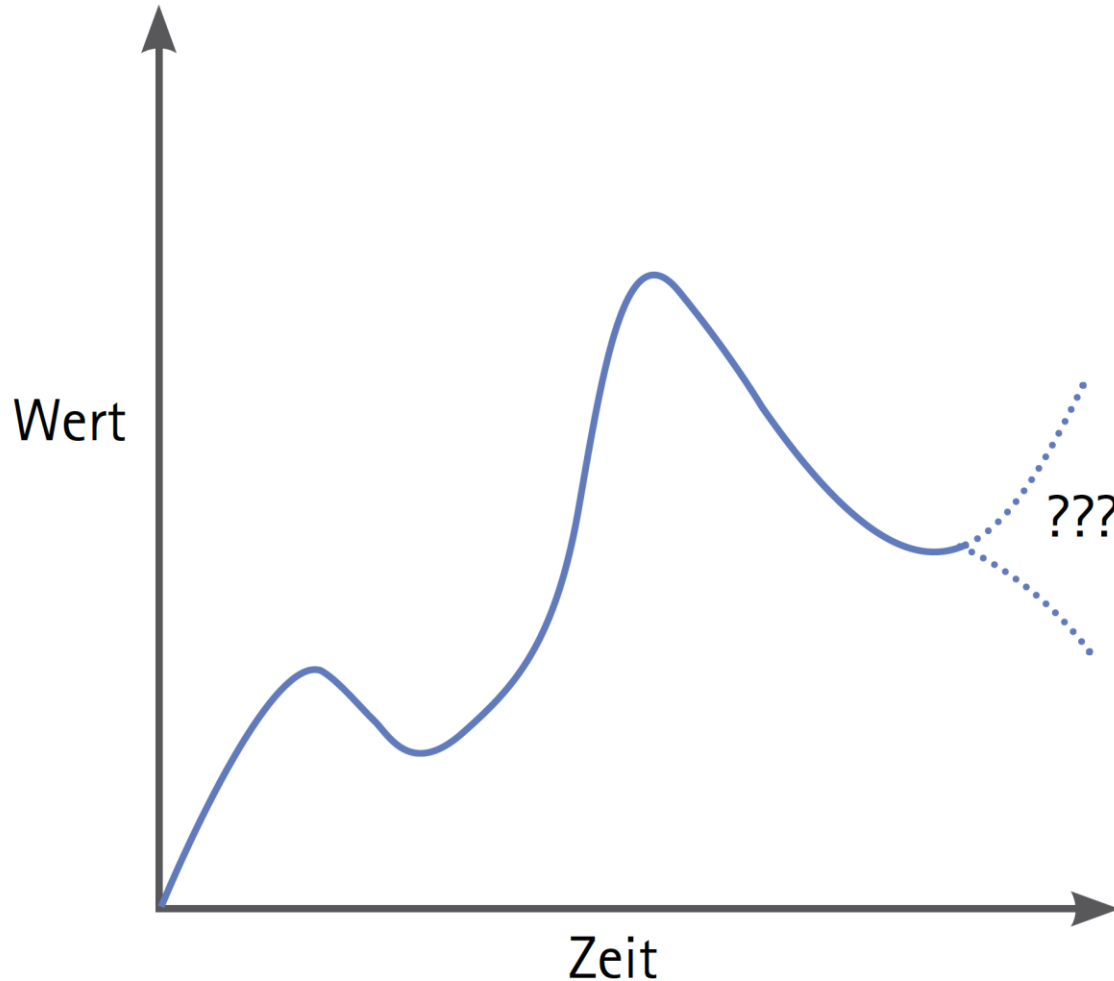
	Größe (cm)	Gewicht (kg)
Person 1	188,4	81,8
Person 2	187,0	78,6
Person 3	157,1	60,2
Person 4	174,6	73,6
Person 5	159,3	59,2
Person 6	185,9	81,6
Person 7	154,3	55,8
Person 8	185,0	78,8

- 3-nearest neighbors Methode
 - Durchschnitt statt Majorität
- Was ist das geschätzte Gewicht einer Person mit Größe 180cm?
 - Personen 4, 6, 8 am ähnlichsten
 - $(73,6+81,6+78,8)/3=78$

(Lineare) Regression: Beispiel



Zeitreihenanalyse: Autoregression



- Features sind die Werte der Vergangenheit
- Trainingsdatensatz kann leicht generiert werden
 - Jeder Datenpunkt ist eine Antwort
 - Vorangegangene Datenpunkte sind Features

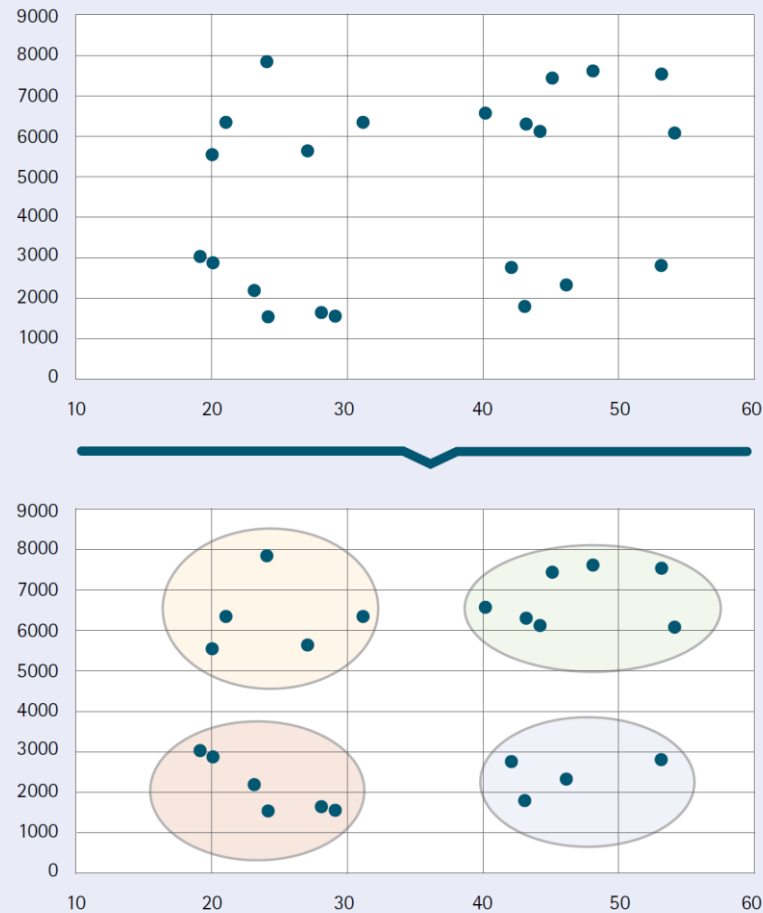
Unüberwachtes Maschinelles Lernen

- Datensatz hat keine Antworten
- Datensatz wird nicht zum Training verwendet
- Datensatz ist selbst ist, was zu analysieren ist und wo neue Informationen (versteckte Zusammenhänge) gesucht werden
 - Zusammenhänge zwischen Spalten
 - Z.B. Principal Component Analysis
 - Zusammenhänge zwischen Reihen
 - Z.B. Clusteranalyse
 - Zusammenhänge zwischen Reihen und Spalten
 - Z.B. Rule Mining

ID	Feature 1	Feature 2	...	Feature n
a	Wert _{a,1}	Wert _{a,2}	...	Wert _{a,n}
b	Wert _{b,1}	Wert _{b,2}	...	Wert _{b,n}
...
m	Wert _{m,1}	Wert _{m,2}	...	Wert _{m,n}

Clusteranalyse: Beispiel

Kunde	Alter	Umsatz
1	42	2716
2	40	6579
3	53	7533
4	23	2152
5	24	1506
6	29	1520
7	19	2993
8	43	6323
9	48	7622
10	46	2282
11	43	1756
12	53	2783
13	20	2842
14	28	1596
15	27	5642
16	45	7441
17	54	6079
18	44	6127
19	21	6329
20	24	7808
21	31	6336
22	20	5533



- Was gehört zusammen?
- Cluster sollen möglichst ähnliche Objekte beinhalten
- Verschiedene Cluster sollen maximal unterschiedlich sein

Rule Mining: Beispiel

Warenkorb	Produkt 1	Produkt 2	Produkt 3	Produkt 4	Produkt 5	Produkt 6	Produkt 7
1	1	0	0	1	0	1	0
2	1	1	1	0	0	0	0
3	0	0	1	1	1	0	0
4	1	0	0	1	0	1	0
5	0	1	0	0	1	0	1
6	1	0	0	1	0	1	0
7	1	0	0	0	1	0	0
8	0	1	0	1	0	0	0
9	1	0	1	1	0	0	1
10	0	0	0	0	1	1	1

- Warenkorbanalyse
- Welche Produkte werden oft zusammen gekauft?
- Produkt 1, 4, 6 in 30% der Fälle gemeinsam
- Mögliche Regel: Wenn Produkt 1 und 4 dann Produkt 6
 - Regel wäre in 75% der Anwendungsfälle korrekt

Ende Teil 1