

# Konzepte der AI: Maschinelles Lernen

Nysret Musliu, Wolfgang Slany  
Abteilung für Datenbanken und Artificial Intelligence  
Institut für Informationssysteme, TU-Wien

## Übersicht

- Was ist Lernen?
- Wozu maschinelles Lernen?
- Welche Arten maschinellen Lernen gibt es?
- Induktive Logische Programmierung (Verallgemeinern)
- Abduktion auf logischen Wissensbasen (Theorien erfinden)
- ID3 Algorithmus
- Clustering
- Computationales/Statistisches Lernen (PAC-Learning)
- Probabilistic reinforcement learning
- Literatur und Links

## Was ist Lernen?

- Sinnvolle Änderungen im Gehirn
- Meist aufgrund erlebter Erfahrungen
- Meist kann dadurch etwas besser gemacht werden
- Verknüpfen mit bestehendem Wissen

3

## Was ist Lernen?

- Jede Änderung an einem System, die es diesem erlaubt, bei Wiederholung derselben Aufgabe oder einer anderen Aufgabe aus der gleichen Population das zweite Mal ein bessere Leistung zu zeigen

*(Simon 1983)*

4

## Wozu maschinelles Lernen?

- Fortschritte in Algorithmen und Theorie
- Datenflut (Internet, ...)
- Rechenleistung mittlerweile vorhanden
- Bedarf an autonomer maschineller Intelligenz
- Manche Probleme lassen sich anders nicht lösen

5

## Drei beispielhafte Nischen für maschinelles Lernen:

- Datamining: historische Daten zur Verbesserung von Entscheidungen:
  - Krankengeschichten - medizinisches Wissen
- Anwendungen, die nicht 'von Hand' programmierbar sind:
  - Fahrerloses Auto
  - Spracherkennung
- Selbst-konfigurierende Anwendungen:
  - Aufzüge in Hochhäusern

6

## Welche Arten maschinellen Lernen gibt es?

- Neurale Netzwerke (cf. Gehirn)
- Genetische Algorithmen (cf. Evolution)
- Induktive Logische Programmierung (Verallgemeinern)
- Abduktion auf logischen Wissensbasen (Theorien erfinden)
- Decision tree learning (Bsp: Tiere Raten)
- Computationales/Statistisches Lernen (PAC-Learning)
- Probabilistic reinforcement learning

7

## Deduktion:

Poldi hat von dem Waschmittel getrunken. (Fall)  
Das Waschmittel ist giftig. (Regel)

Daher hat Poldi starke Bauchschmerzen. (Resultat)

8

## Induktion:

- Durch Austausch des Resultats mit der Regel in obiger Deduktion erhält man einen (deduktiv falschen) Syllogismus, der als **induktive Verallgemeinerung** betrachtet werden kann:

Poldi hat von dem Waschmittel getrunken. (Fall)

Poldi hat starke Bauchschmerzen. (Resultat)

Daher ist das Waschmittel giftig. (Regel)

9

## Abduktion:

- Alternativ entsteht durch Austausch des Resultats mit dem Fall ein (ebenfalls deduktiv falscher) Syllogismus, der als **abduktive Erklärung** betrachtet werden kann:

Poldi hat starke Bauchschmerzen. (Resultat)

Das Waschmittel ist giftig. (Regel)

---

Daher hat Poldi von dem Waschmittel getrunken. (Fall)

- Meistens wird Abduktion in folgender Situation angewandt:  
Ein überraschendes Resultat, B, wurde beobachtet;

Aber wenn A wahr wäre, dann würde B sofort daraus folgen.

Also hat man **guten Grund** anzunehmen, dass A wahr ist.

10

## Induktive Kalibrierung

- Suchräume, die sich beim Lernen ergeben, sind extrem gross
- Kalibrierung: Methode, mit der ein Lernprogramm den Raum möglicher Generalisierungen einschränkt

11

## ID3 Algorithmus [2]

- Repräsentiert Konzepte als Entscheidungsbäume
- Objekten werden klassifiziert, indem wir deren Eigenschaften auf bestimmte werte überprüfen
- Beispiel: Kreditrisiko Einschätzung
  - Eigenschaften: Kreditwürdigkeit, aktuelle Verschuldung, Sicherheiten, Einkommen

12

## ID3 Algorithmus

- Test daten: Beispiele für Personen mit einer bekannten Kreditrisiko
- Die Entscheidungsbaum repräsentiert die Klassifikation aus Tabelle insofern, als dass alle in der Tabelle enthaltenen Objekte durch diese Baum korrekt dargestellt werden

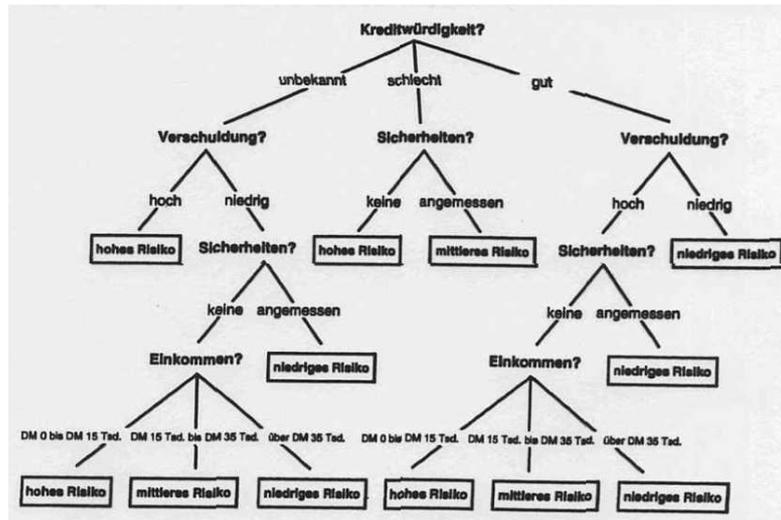
13

### Beispiele für Personen mit einer bekannten Kreditrisiko [2]

<b>Nr.</b>	<b>Risiko</b>	<b>Kreditwürdigkeit</b>	<b>Verschuldung</b>	<b>Sicherheiten</b>	<b>Einkommen</b>
1.	hoch	schlecht	hoch	keine	DM 0 bis DM 15 Tsd.
2.	hoch	unbekannt	hoch	keine	DM 15 Tsd. bis DM 35 Tsd.
3.	mittel	unbekannt	niedrig	keine	DM 15 Tsd. bis DM 35 Tsd.
4.	hoch	unbekannt	niedrig	keine	DM 0 bis DM 15 Tsd.
5.	niedrig	unbekannt	niedrig	keine	über DM 35 Tsd.
6.	niedrig	unbekannt	niedrig	angemessen	über DM 35 Tsd.
7.	hoch	schlecht	niedrig	keine	DM 0 bis DM 15 Tsd.
8.	mittel	schlecht	niedrig	angemessen	über DM 35 Tsd.
9.	niedrig	gut	niedrig	keine	über DM 35 Tsd.
10.	niedrig	gut	hoch	angemessen	über DM 35 Tsd.
11.	hoch	gut	hoch	keine	DM 0 bis DM 15 Tsd.
12.	mittel	gut	hoch	keine	DM 15 Tsd. bis DM 35 Tsd.
13.	niedrig	gut	hoch	keine	über DM 35 Tsd.
14.	hoch	schlecht	hoch	keine	DM 15 Tsd. bis DM 35 Tsd.

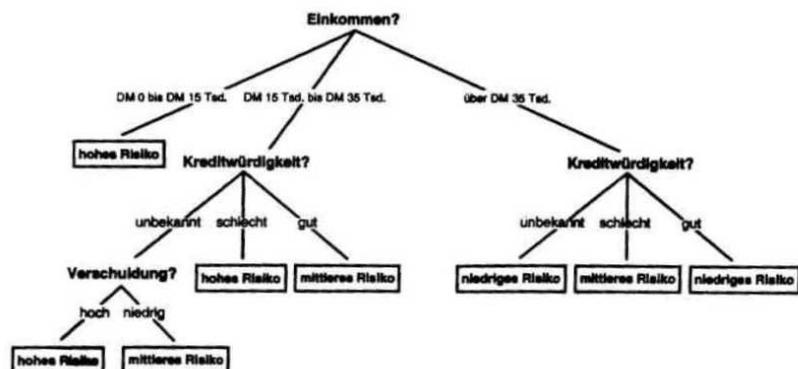
14

## Entscheidungsbaum für die Einschätzung des Kreditrisikos [2]



15

## Vereinfachter Entscheidungsbaum für die Einschätzung des Kreditrisikos [2]



16

## ID3 Algorithmus

- Welcher Baum mit der höchsten Warscheinlichkeit bislang unbekannte einschlägige Beispiele korrekt einstufen kann?
  - ID3: Einfachste Entscheidungbaum, der alle Trainingsbeispiele abdeckt
  - ID3 hat in Praxis gut bewährt

17

## (Un)Supervised lernen

- Supervised lernen
  - Trainingsdaten werden klassifiziert
  - Dem lernenden System wird mitgeteilt, ob ein Fall ein positives oder ein negatives Beispiel des Zielkonzepts darstellt
- Unsupervised lernen
  - Kategorienbildung ist das das grundproblem des unüberwachten Lernens
  - Wie kann ein Agent die Objekte in sinnvolle Kategorien einteilen, wenn eine Menge von Objekten gegeben ist, die unterschiedliche Eigenschaften aufweisen

18

## Unsupervised Lernen

- Lernende System bildet und bewertet die Konzepten selbständig
- z.B Naturwissenschaften:
  - Hypothese wird formuliert, um Beobachtungen zu erklären
  - Hypothesen werden bewertet anhand Kriterien wie Einfachheit, Allgemeingültigkeit,...
  - Hypothesen werden getestet durch selbst entworfene Experimente

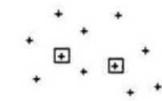
19

## Konzeptuelles Clustering

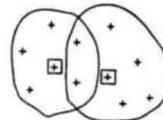
- Sammlung nicht klassifizierter Objekte
- Methode, um die Ähnlichkeiten von Objekten zu messen
- Das Ziel besteht darin, die Objekte in eine Hierarchie von Klassen einzuordnen, die einen bestimmten Qualitätsstandard genügen, wie z.B die Ähnlichkeiten von Objekten zu maximieren, die der Gleichen Klasse angehören

20

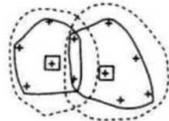
## Konzeptuelles Clustering [2]



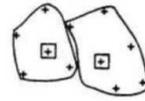
Nach der Auswahl von Basisobjekten (Schritt 1).



Nach der Erzeugung allgemeiner Beschreibungen (Schritt 2 und 3). Beachten Sie, dass sich die Kategorien überschneiden.



Nach der Spezialisierung der Konzeptbeschreibungen (Schritt 4). Es gibt noch immer Elemente, bei denen sich die Kategorien überschneiden.



Nach der Eliminierung redundanter Elemente (Schritt 5).

21

## Computational learning theory:

- PAC-learning: Jede eigentlich falsche Hypothese sollte mit hoher Wahrscheinlichkeit anhand einer kleinen Menge von Beobachtungen als solche erkennbar sein. Daher sollte jede Hypothese, die mit ausreichend vielen Beobachtungen im Einklang steht, wahrscheinlich ungefähr korrekt, also **probably approximately correct** sein.
- Wichtige Voraussetzung: Training und Test-Daten müssen gleiche Wahrscheinlichkeitsverteilung haben!  
-> Theorie

22

## Reinforcement-Lernen

- Ein Agent wird hier einer Umgebung ausgesetzt und empfängt in diesem Kontext Rückmeldungen
- Der Agent muss handeln und die Rückmeldungen zu diesen Handlungen interpretieren
- Es gibt kein Lehrer, der direkt auf jede Handlung reagiert
- Der Agent muss stattdessen selbst eine Strategie zur Interpretation der Rückmeldungen entwickeln
- z.B: Radfahren lernen

23

## Allgemeine Literatur zu maschinellem Lernen:

1. Mitchell, Machine Learning, McGraw-Hill, 1997,  
<http://www.cs.cmu.edu/~tom/mlbook.html>
2. G.F. Luger. *Künstliche Intelligenz: Strategien zur Lösung komplexer Probleme*. Pearson Studium, 2001.
3. Nilsson, Introduction to Machine Learning, online book draft 1996,  
<http://robotics.stanford.edu/people/nilsson/mlbook.htm>
4. Russell & Norvig, AI A Modern Approach, Prentice Hall 1995 (Part VI ``Learning").
5. Machine Learning Online Resources  
<http://www.aic.nrl.navy.mil/~aha/research/machine-learning.html>

24