



OTTO VON GUERICKE
UNIVERSITÄT
MAGDEBURG

INF

FAKULTÄT FÜR
INFORMATIK

Intelligente Systeme

Maschinelles Lernen

Prof. Dr. R. Kruse C. Braune C. Moewes

{kruse,cmoewes,russ}@iws.cs.uni-magdeburg.de

Institut für Wissens- und Sprachverarbeitung

Fakultät für Informatik

Otto-von-Guericke Universität Magdeburg

Übersicht

1. Maschinelles Lernen

Definitionen des Lernens

Klassifikation der Ansätze

Erlernen von Entscheidungsbäumen

Data Mining

Most people think computers will never be able to think.
Marvin Minsky, 1982

Definitionen des Lernens (1)

Learning denotes changes in the system that are adaptive in the sense that they enable the system to do the same task or tasks drawn from the same population more efficiently and more effectively the next time.[Simon, 1983]

umfasst allerdings auch Veränderungen, die nichts mit Lernen zu tun haben

Beispiel einer Lernleistung: Verwendung eines schneller getakteten Prozessors als schnellere Abarbeitung einer arithmetischen Berechnung

Definitionen des Lernens (2)

The study and computer modeling von learning processes in their multiple manifestations constitutes the subject matter von machine learning.[Michalski et al., 1986]

direkte Anspielung auf „Lernprozesse in ihren verschiedenen Erscheinungsformen“

Definitionen des Lernens (3)

Learning is constructing or modifying representations von what is being experienced. [Michalski, 1986]

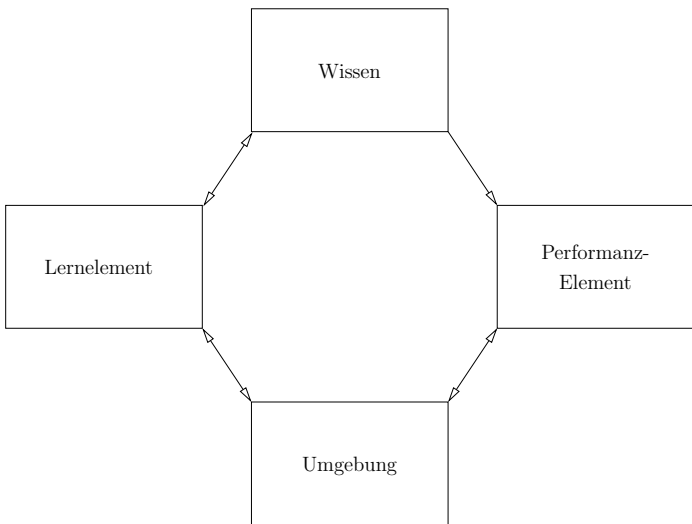
zentraler Aspekt: Konstruktion einer Repräsentation

Definitionen des Lernens (4)

Research in machine learning has been concerned with building computer programs able to construct new knowledge or to improve already possessed knowledge by using input information.[Michalski and Kodratoff, 1990]

Ziel des ML: Computerprogramme sollen durch Erfahrung ihr eigenes Handeln verbessern können

Schema eines allgemeinen Lernmodells



Lernmodell

Performanzelement: interagiert mit der Umgebung, wird durch vorhandenes Wissen gesteuert

Lernelement: nimmt Erfahrungen und Beobachtungen aus der Umgebung auf, erzeugt/modifiziert Wissen

Zusätzlich meist:

Kritikelement: teilt dem Lernelement mit, wie erfolgreich es ist

Problemgenerator: erzeugt Aufgaben, die zu neuen und informativen Erfahrungen führen sollen

Klassifikation der Ansätze

Klassifikation der Ansätze gemäß [Carbonell et al., 1984]:

Klassifikation gemäß der zugrundeliegenden *Lernstrategie*:

Unterscheidung wie viel Information bereits vorgegeben wird und in welchem Maße das Lernsystem eigene Inferenzen durchführt

Klassifikation gemäß der benutzten *Repräsentation von Wissen*, welches das System erlernt

Klassifikation gemäß dem *Anwendungsbereich* des Lernsystems

Klassifikation gemäß der benutzten Lernstrategie

direkte Eingabe neuen Wissens und Auswendiglernen:

keinerlei Inferenz oder andere Art der Wissenstransformation erforderlich

z.B. Speichern von Daten/Fakten, Lernen durch direkte Programmierung

Lernen durch Anweisungen:

aufbereitetes Wissen wird vorgegeben, was intern verarbeitet werden muss

Wissen soll effektiv verwendet werden

Anweisungen werden durch den Lehrenden aufgearbeitet, so dass Wissen des Lernenden schrittweise erweitert werden kann

Klassifikation gemäß der benutzten Lernstrategie

Lernen durch Deduktion:

leitet aus vorhandenem Wissen mittels deduktiver Schlussweisen neues Wissen ab

neues Wissen kann zur Effizienz- oder Effektivitätssteigerung verwendet werden

Lernen durch Analogie:

Erlernen neuer Fakten und Fähigkeiten durch Anpassung vorhandenen Wissens an neue Situationen

Klassifikation gemäß der benutzten Lernstrategie

Lernen aus Beispielen:

allgemeine Konzeptbeschreibung soll erstellt werden, die alle vorher gegebenen Beispiele umfasst und evtl. vorhandene Gegenbeispiele ausschließt

- *Beispiele vom Lehrenden*: Konzept ist dem Lehrer bekannt; Beispiele können entsprechend ausgewählt werden; schneller Lernerfolg möglich
- *Beispiele vom Lernenden*: Lernender hat Hypothese für das zu lernende Konzept und generiert Beispiele; von außerhalb kommt Feedback zu den Beispielen (positive oder negative Beispiele)
- *Beispiele aus der Umgebung*: Zufallsbeobachtungen; Notwendigkeit, dem Lernenden mitzuteilen, ob die Beobachtung ein positives oder ein Gegenbeispiel ist

Klassifikation gemäß der benutzten Lernstrategie

alternative Klassifizierung des „Lernens durch Beispiele“:

nur positive Beispiele verfügbar: keine Informationen darüber verfügbar, ob abgeleitetes Konzept zu allgemein ist; dem wird oft durch Minimalitätskriterien entgegenzuwirken versucht

positive und negative Beispiele verfügbar: üblichste Situation beim Lernen; positive Beispiele sorgen dafür, dass abgeleitetes Konzept allgemein genug ist; negative Beispiele verhindern, dass das Konzept zu allgemein wird

Klassifikation gemäß der benutzten Lernstrategie

weitere alternative Klassifizierung des „Lernens durch Beispiele“:

alle Beispiele gleichzeitig: alle Informationen stehen in jedem Fall am Anfang zur Verfügung; Hypothesen können sofort auf Richtigkeit überprüft werden

Beispiele sind inkrementell gegeben: Hypothese in Konsistenz mit den bisherigen Beispielen wird erstellt, die keines der Gegenbeispiele erfasst; anhand nachfolgender Beispiele wird Hypothese überprüft und ggf. verfeinert

Klassifikation gemäß der benutzten Lernstrategie

Lernen aus Beobachtungen und durch Entdeckungen: generelle Ausprägung des induktiven Lernens; keinerlei Steuerung durch Lehrenden; verschiedene Konzepte sind gleichzeitig zu erlernen

- *Passive Beobachtungen:* Konzepte, die aufgrund der Beobachtungen der Umgebung durch den Lernenden entwickelt werden;
- *Aktive Experimente:* Umgebung wird gezielt beeinflusst, um die Auswirkungen der Experimente beobachten zu können; Steuerung der Experimente per Zufall, nach allgemeinen Gesichtspunkten oder durch theoretische Überlegungen.

Klassifikation gemäß dem gelernten Typ von Wissen

Parameter in algebraischen Ausdrücken: gegeben ist ein algebraischer Ausdruck; numerische Parameter oder Koeffizienten sind so zu optimieren, dass ein gewünschtes Verhalten erreicht wird

Entscheidungs bäume: zur Unterscheidung zwischen Elementen einer Klasse; Knoten: Attribute der Objekte; Blätter: Menge der Objekte, die der gleichen Unterklasse zugeordnet werden

Formale Grammatiken: zur Beschreibung einer formalen Sprache; ausgehend von Beispielausdrücken wird eine formale Grammatik erlernt

Klassifikation gemäß dem gelernten Typ von Wissen

Regeln: **if C then A**; C ist Menge von Bedingungen, A ist eine Aussage

Vier Basisoperationen für Regeln:

Erzeugung: eine neue Regel wird generiert oder aus der Umgebung aufgenommen

Verallgemeinerung: Bedingungen aus dem Bedingungsteil werden entfernt, Regel wird allgemeiner

Spezialisierung: zusätzliche Bedingungen werden dem Bedingungsteil hinzugefügt, Regel ist nur noch auf speziellere Situationen anwendbar

Komposition: Regeln werden zusammengefasst; nicht mehr notwendige Bedingungen und Folgerungen werden eliminiert

Klassifikation gemäß dem gelernten Typ von Wissen

Ausdrücke basierend auf formaler Logik: für die Beschreibung einzelner Objekte als auch für die Bildung des zu erlernenden Konzepts; Aussagen, Prädikate, Variablen, logische Ausdrücke

Begriffshierarchien: Begriffe, die in Beziehung zueinander stehen, werden hierarchischen Begriffskategorien zugeordnet; Begriffshierarchien bzw. Taxonomien sind zu lernen

Entscheidungsbäume

Hier: vereinfachte Entscheidungsbäume, die nur ja/nein-Knoten beinhalten.

- Die Blätter sind mit dem Wahrheitswert markiert, der als Ergebnis der Funktion zurückgeliefert werden soll, wenn das Blatt erreicht wird.
- Die inneren Knoten sind mit einem Attribut markiert. Eine solche Markierung a repräsentiert eine Abfrage, welchen Wert das betrachtete Objekt für das Attribut a hat.
- Die von einem mit a markierten Knoten ausgehenden Kanten sind mit den zu a möglichen Attributwerten markiert.

Entscheidungsbäume: Beispiel

Beispiel: Kinobesuch, Definition der Attribute

Attraktivität des Films: hoch, mittel, gering

Preis: normal (n), mit Zuschlag (z)

Loge: noch verfügbar (ja), nicht verfügbar (nein)

Wetter: schön, mittel, schlecht

Warten: ja, nein

Besetzung: top, mittel

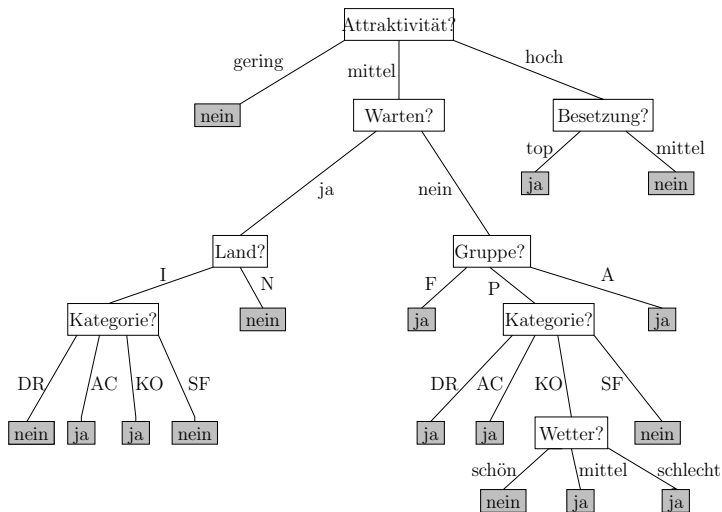
Kategorie: Action (AC), Komödie (KO), Drama (DR), Science Fiction (SF)

Reservierung: ja, nein

Land: national (N), international (I)

Gruppe: Freunde (F), Paar (P), allein (A)

Entscheidungsbäume: Beispiel



Entscheidungsbäume: Regeln

Aus Entscheidungsbäumen können sehr einfach Regeln abgelesen werden:

if Attraktivität = hoch **and** Besetzung = top **then** Kinobesuch = ja.

if Attraktivität = mittel **and** Warten = ja **and** Land = national **then** Kinobesuch = nein.

Ein Lernverfahren für Entscheidungsbäume generiert aus einer Menge von Beispielen (der *Trainingsmenge*) einen Entscheidungsbaum. Ein *Trainingsbeispiel* ist dabei eine Menge von Attribut/Wert-Paaren zusammen mit der Klassifikation.

Entscheidungsbäume: Generierung

Für jedes Beispiel steht am Ende genau ein Pfad im Baum von der Wurzel zum Blattknoten.

Diese Vorgehensweise liefert keine sinnvolle Generalisierung, der Baum passt nur auf die vorhandenen Trainingsdaten, aber nicht auf neue Daten.

Occam's Razor: Bevorzuge die einfachste Hypothese, die konsistent mit allen Beobachtungen ist.

Problem: Welches Attribut wird ausgewählt, um in einem Knoten die Beispieldaten aufzuteilen? Welches Attribut ist das *wichtigste*?

Beispiel: Induktion eines Entscheidungsbaums

Patienten-Datenbank

12 Beispielfälle

3 beschreibende Attribute

1 Klassenattribut

Bestimmung des Medikaments M

(ohne Patientenattribute)

immer Medikament A oder immer
Medikament B:

50% korrekt (in 6 v. 12 Fällen)

Nr	Geschl.	Alt.	Blutdr.	M.
1	männlich	20	normal	A
2	weiblich	73	normal	B
3	weiblich	37	hoch	A
4	männlich	33	niedrig	B
5	weiblich	48	hoch	A
6	männlich	29	normal	A
7	weiblich	52	normal	B
8	männlich	42	niedrig	B
9	männlich	61	normal	B
10	weiblich	30	normal	A
11	weiblich	26	niedrig	B
12	männlich	54	hoch	A

Beispiel: Induktion eines Entscheidungsbaums

Geschlecht eines Patienten

Teilung bzgl. männlich/weiblich

Bestimmung des Medikaments

männlich: 50% korrekt (in 3 von 6 Fällen)

weiblich: 50% korrekt (in 3 von 6 Fällen)

gesamt: **50% korrekt** (in 6 von 12 Fällen)

Nr	Geschl.	M.
1	männlich	A
6	männlich	A
12	männlich	A
4	männlich	B
8	männlich	B
9	männlich	B
3	weiblich	A
5	weiblich	A
10	weiblich	A
2	weiblich	B
7	weiblich	B
11	weiblich	B

Beispiel: Induktion eines Entscheidungsbaums

Alter des Patienten

Sortieren anhand des Alters

beste Teilung finden, hier: ca. 40 Jahre

Bestimmung des Medikaments

≤ 40 : A 67% korrekt (in 4 von 6 Fällen)

> 40 : B 67% korrekt (in 4 von 6 Fällen)

gesamt: **67% korrekt** (in 8 von 12 Fällen)

Nr	Alt.	M.
1	20	A
11	26	B
6	29	A
10	30	A
4	33	B
3	37	A
8	42	B
5	48	A
7	52	B
12	54	A
9	61	B
2	73	B

Beispiel: Induktion eines Entscheidungsbaums

Blutdruck des Patienten

Teilung bzgl. hoch/normal/niedrig

Bestimmung des Medikaments

hoch: A 100% korrekt (3 von 3)

normal: 50% korrekt (3 von 6)


niedrig: B 100% korrekt (3 von 3)

gesamt: **75% korrekt** (9 von 12)

Nr	Blutdr.	M.
3	hoch	A
5	hoch	A
12	hoch	A
1	normal	A
6	normal	A
10	normal	A
2	normal	B
7	normal	B
9	normal	B
4	niedrig	B
8	niedrig	B
11	niedrig	B

Beispiel: Induktion eines Entscheidungsbaums

Momentaner Entscheidungsbaum:



Beispiel: Induktion eines Entscheidungsbaums

Blutdruck und Geschlecht

nur Patienten mit normalem Blutdruck

Zerlegung bzgl. männlich/weiblich

Bestimmung des Medikaments

männlich: A 67% korrekt (2 von 3)

weiblich: B 67% korrekt (2 von 3)

gesamt: **67% korrekt** (4 von 6)

Nr	Blutdr.	Geschl.	M.
3	hoch		A
5	hoch		A
12	hoch		A
1	normal	männlich	A
6	normal	männlich	A
9	normal	männlich	B
2	normal	weiblich	B
7	normal	weiblich	B
10	normal	weiblich	A
4	niedrig		B
8	niedrig		B
11	niedrig		B

Beispiel: Induktion eines Entscheidungsbaums

Blutdruck und Alter

nur Patienten mit normalem Blutdruck

Sortieren anhand des Alters

beste Teilung finden, hier: ca. 40 Jahre

Bestimmung des Medikaments

≤ 40: A 100% korrekt (3 von 3)


> 40: B 100% korrekt (3 von 3)

gesamt: **100% korrekt** (6 von 6)

Nr.	Blutdr.	Alt.	M.
3	hoch		A
5	hoch		A
12	hoch		A
1	normal	20	A
6	normal	29	A
10	normal	30	A
7	normal	52	B
9	normal	61	B
2	normal	73	B
11	niedrig		B
4	niedrig		B
8	niedrig		B

Ergebnis nach Lernen des Entscheidungsbaums

Bestimmung eines Medikaments für einem Patienten:



Bewertungsmaße

im vorherigen Beispiel:

Rate der korrekt klassifizierten Beispielfälle

- Vorteil: leicht zu berechnen, einfach zu verstehen
- Nachteil: funktioniert nur gut für zwei Klassen

falls mehr als zwei Klassen: diese Rate ignoriert viele verfügbare Informationen

- nur Mehrheitsklasse— d.h. Klasse, die am meisten in (einer Teilmenge von) Beispielen vorkommt—wird wirklich berücksichtigt
- Verteilung der anderen Klassen hat keinen Einfluss
- aber: gute Wahl can hier wichtig sein für tiefere Ebenen des Entscheidungsbaums

darum: auch andere Bewertungsmaße betrachten, hier:

- **Informationsgewinn** und seine verschiedenen Normierungen,

Induktion eines Entscheidungsbaums: Notation

S	Menge von Fällen oder Objektbeschreibungen
C	Klassenattribut
$A^{(1)}, \dots, A^{(m)}$	beschreibende Attribute (ohne Indices im Folgenden)
$\text{dom}(C)$	$= \{c_1, \dots, c_{n_C}\}, \quad n_C: \text{Anzahl der Klassen}$
$\text{dom}(A)$	$= \{a_1, \dots, a_{n_A}\}, \quad n_A: \text{Anzahl der Attribute}$
$N_{..}$	Gesamtanzahl der Fälle, d.h. $N_{..} = S $
N_i	absolute Häufigkeit der Klasse c_i
$N_{.j}$	absolute Häufigkeit des Attributwerts a_j
N_{ij}	absolute Häufigkeit der Kombination aus c_i und a_j
	wobei $N_i = \sum_{j=1}^{n_A} N_{ij}$ und $N_{.j} = \sum_{i=1}^{n_C} N_{ij}$
p_i	relative Häufigkeit der Klasse c_i , $p_i = \frac{N_i}{N_{..}}$
$p_{.j}$	relative Häufigkeit des Attributwerts a_j , $p_{.j} = \frac{N_{.j}}{N_{..}}$
p_{ij}	relative Häufigkeit der Kombination aus c_i und a_j , $p_{ij} = \frac{N_{ij}}{N_{..}}$
$p_{i j}$	relative Häufigkeit von c_i für Fälle mit a_j , $p_{i j} = \frac{N_{ij}}{N_{.j}} = \frac{p_{ij}}{p_{.j}}$

Ein informationstheoretisches Bewertungsmaß

Informationsgewinn (Kullback und Leibler 1951, Quinlan 1986)
basiert auf Shannon-Entropie $H = -\sum_{i=1}^n p_i \log_2 p_i$ (Shannon 1948)

$$I_{\text{gain}}(C, A) = \underbrace{H(C)} - \underbrace{H(C | A)}$$

$$= -\sum_{i=1}^{n_C} p_i \cdot \log_2 p_i - \sum_{j=1}^{n_A} p_{\cdot j} \left(-\sum_{i=1}^{n_C} p_{i|j} \log_2 p_{i|j} \right)$$

$H(C)$

$H(C | A)$

$H(C) - H(C | A)$

Entropie von der Klassenverteilung (C : Klassenattribut)
erwartete Entropie von der Klassenverteilung falls
der Wert vom Attribut A bekannt ist
erwartete Entropie der Verminderung oder
des *Informationsgewinns*

Induktion des Entscheidungsbaums

Informationsgewinn von Medikament und Geschlecht:

$$H(\text{Medi.}) = - \left(\frac{1}{2} \log_2 \frac{1}{2} + \frac{1}{2} \log_2 \frac{1}{2} \right) = 1$$

$$H(\text{Medi.} \mid \text{Geschl.}) = \frac{1}{2} \underbrace{\left(-\frac{1}{2} \log_2 \frac{1}{2} - \frac{1}{2} \log_2 \frac{1}{2} \right)}_{H(\text{Medi.} \mid \text{Geschl.} = \text{männlich})} + \frac{1}{2} \underbrace{\left(-\frac{1}{2} \log_2 \frac{1}{2} - \frac{1}{2} \log_2 \frac{1}{2} \right)}_{H(\text{Medi.} \mid \text{Geschl.} = \text{weiblich})} = 1$$

$$I_{\text{gain}}(\text{Medi.}, \text{Geschl.}) = 1 - 1 = 0$$

überhaupt kein Informationsgewinn, weil ursprüngliche Gleichverteilung des Medikaments in zwei Gleichverteilungen geteilt wird

Induktion des Entscheidungsbaums

Informationsgewinn von Medikament und Alter:

$$H(\text{Medi.}) = - \left(\frac{1}{2} \log_2 \frac{1}{2} + \frac{1}{2} \log_2 \frac{1}{2} \right) = 1$$

$$H(\text{Medi.} \mid \text{Alt.}) = \frac{1}{2} \underbrace{\left(-\frac{2}{3} \log_2 \frac{2}{3} - \frac{1}{3} \log_2 \frac{1}{3} \right)}_{H(\text{Medi.} \mid \text{Alt.} \leq 40)} + \frac{1}{2} \underbrace{\left(-\frac{1}{3} \log_2 \frac{1}{3} - \frac{2}{3} \log_2 \frac{2}{3} \right)}_{H(\text{Medi.} \mid \text{Alt.} > 40)} \approx 0.9183$$

$$I_{\text{gain}}(\text{Medi.}, \text{Alt.}) = 1 - 0.9183 = 0.0817$$

Teilung bzgl. Alter kann gesamte Entropie reduzieren

Induktion des Entscheidungsbaums

Informationsgewinn von Medikament und Blutdruck:

$$H(\text{Medi.}) = - \left(\frac{1}{2} \log_2 \frac{1}{2} + \frac{1}{2} \log_2 \frac{1}{2} \right) = 1$$

$$H(\text{Medi.} \mid \text{Blutdr.}) = \frac{1}{4} \cdot 0 + \frac{1}{2} \underbrace{\left(-\frac{2}{3} \log_2 \frac{2}{3} - \frac{1}{3} \log_2 \frac{1}{3} \right)}_{H(\text{Medi.} \mid \text{Blutdr.}=\text{normal})} + \frac{1}{4} \cdot 0 = 0.5$$

$$I_{\text{gain}}(\text{Medi.}, \text{Blutdr.}) = 1 - 0.5 = 0.5$$

größter Informationsgewinn, also wird zuerst bzgl. Blutdruck aufgeteilt
(genauso wie im Beispiel mit Fehlklassifikationsrate)

Induktion des Entscheidungsbaums

nächste Ebene: Teilbaum „Blutdruck ist normal“

Informationsgewinn für Medikament und Geschlecht:

$$H(\text{Medi.}) = - \left(\frac{1}{2} \log_2 \frac{1}{2} + \frac{1}{2} \log_2 \frac{1}{2} \right) = 1$$

$$H(\text{Medi.} \mid \text{Geschl.}) = \frac{1}{2} \underbrace{\left(-\frac{2}{3} \log_2 \frac{2}{3} - \frac{1}{3} \log_2 \frac{1}{3} \right)}_{H(\text{Medi.} \mid \text{Geschl.} = \text{männlich})} + \frac{1}{2} \underbrace{\left(-\frac{1}{3} \log_2 \frac{1}{3} - \frac{2}{3} \log_2 \frac{2}{3} \right)}_{H(\text{Medi.} \mid \text{Geschl.} = \text{weiblich})} = 0.9183$$

$$I_{\text{gain}}(\text{Medi.}, \text{Geschl.}) = 0.0817$$

Entropie kann reduziert werden

Induktion des Entscheidungsbaums

nächste Ebene: Teilbaum „Blutdruck ist normal“

Informationsgewinn für Medikament und Alter:

$$H(\text{Medi.}) = - \left(\frac{1}{2} \log_2 \frac{1}{2} + \frac{1}{2} \log_2 \frac{1}{2} \right) = 1$$

$$H(\text{Medi.} \mid \text{Alt.}) = \frac{1}{2} \cdot 0 + \frac{1}{2} \cdot 0 = 0$$

$$I_{\text{gain}}(\text{Medi.}, \text{Alt.}) = 1$$

maximaler Informationsgewinn, d.h. perfekte Klassifikation

ID3: Induktion von Entscheidungsbäumen

ID3 ist mit dieser Heuristik, das Attribut mit dem höchsten Informationsgewinn als „Split-Attribut“ zu verwenden, sehr erfolgreich

Werte mit sehr vielen Attributen durch ID3 bevorzugt: Beispiel: bei einer Einkommensteuererklärung die jedem Bürger zugeordnete eindeutige Steuernummer.

- Genausoviele Ausprägungen, wie es Bürger (n) gibt
- Partitionierung der Beispielmenge E in n Teilmengen
- bedingte mittlere Information

$$I(E \mid \text{StNr bekannt}) = \sum_{i=1}^n \frac{1}{n} H(0; 1) = 0 \text{ bit}$$

- Informationsgewinn maximal, allerdings Attribut nutzlos.

C4.5: Induktion von Entscheidungsbäumen

Verbesserung: C4.5

Statt des absoluten Informationsgewinns wird ein normierter Informationsgewinn genutzt.

$$\textit{gain ratio}(a) = \frac{\textit{gain}(a)}{\textit{split info}(a)}$$

split info(*a*) ist hierbei die Entropie des Attributes *a*:

$$\textit{split info}(a) = H(a) = - \sum_{i=1}^k P(a = w_i) \log_2 P(a = w_i)$$

Beispiel Steuernummer: Induktion einer Gleichverteilung, Normierungsfaktor maximal; nächstes Attribut: dasjenige mit maximalem *gain ratio*

Data Mining und Wissensfindung in Daten

Oberbegriffe für die Automatisierung der Analyse von Daten,
Knowledge Discovery in Databases (KDD)

zentrales Forschungsthema in der Künstlichen Intelligenz

KDD: Prozess, neues, nützliches und interessantes Wissen aus Daten
herauszufiltern und in verständlicher Form zu präsentieren

KDD-Prozess

Hintergrundwissen und Zielsetzung: Relevantes, bereichsspezifisches Wissen wird zur Verfügung gestellt. Die Ziele des durchzuführenden KDD sollten definiert werden.

Datenauswahl: Eine Menge von Daten wird als Untersuchungsobjekt festgelegt. Darüberhinaus erfolgt gegebenenfalls eine Vorauswahl der betrachteten Variablen.

Datenbereinigung: Ausreißer müssen aus der Datenbasis entfernt, Rauscheffekte herausgefiltert werden. Datentypen werden festgelegt und die Behandlung fehlender Daten wird geklärt.

Datenreduktion und -projektion: Die vorbehandelte Datenmenge wird noch einmal komprimiert durch Reduktion oder Transformation der behandelten Variablen.

KDD-Prozess

Modellfunktionalität: Welchem Zweck dient das Data Mining? U.a. gibt es Klassifikation, Clustering, Regressionsanalyse.


Verfahrenswahl: Bestimmung eines Data-Mining-Verfahrens, das zu den untersuchten Daten und der Zielvorgabe des gesamten KDD-Prozesses passt.

Data Mining: der eigentliche Data-Mining-Prozess, bei dem das ausgewählte Verfahren auf die behandelte Datenmenge angewandt wird, um interessante Informationen z.B. in Form von Klassifikationsregeln oder Clustern zu extrahieren

Interpretation: Die im Data-Mining-Schritt gewonnene Information wird aufbereitet, indem z.B. redundante Information entfernt wird, und schließlich dem Benutzer in verständlicher Form (Visualisierung!) präsentiert.


CRoss Industry Standard Process for Data Mining

<ftp://ftp.software.ibm.com/software/analytics/spss/support/Modeler/Documentation/14/UserManual/CRISP-DM.pdf>



CRISP-DM im Detail

<http://exde.wordpress.com/2009/03/13/a-visual-guide-to-crisp-dm-methodology/>



Determine Business Objectives

Background
Business Objectives
Business Success Criteria
(Log and Report Process)

Assess Situation

*Inventory of Resources,
Requirements, Assumptions,
and Constraints*
Risks and Contingencies
Terminology
Costs and Benefits
(Log and Report Process)

Determine Data Mining Goals

Data Mining Goals
Data Mining Success Criteria
(Log and Report Process)

Produce Project Plan

Project Plan
Initial Assessment of Tools and
Techniques
(Log and Report Process)

Collect Initial Data

Initial Data Collection Report
(Log and Report Process)

Describe Data

Data Description Report
(Log and Report Process)

Explore Data

Data Exploration Report
(Log and Report Process)

Verify Data Quality

Data Quality Report
(Log and Report Process)

Data Set

Data Set Description
(Log and Report Process)

Select Data

*Rationale for Inclusion/
Exclusion*
(Log and Report Process)

Clean Data

Data Cleaning Report
(Log and Report Process)

Construct Data

*Derived Attributes
Generated Records*
(Log and Report Process)

Integrate Data

Merged Data
(Log and Report Process)

Format Data

Reformatted Data
(Log and Report Process)

Select Modeling Technique

Modeling Technique
Modeling Assumptions
(Log and Report Process)

Generate Test Design

Test Design
(Log and Report Process)

Build Model Parameter Settings

Models
Model Description
(Log and Report Process)

Assess Model

Model Assessment
Revised Parameter
(Log and Report Process)

Evaluate Results

*Align Assessment of Data
Mining Results with
Business Success Criteria*
(Log and Report Process)

Approved Models

Review Process
Review of Process
(Log and Report Process)

Determine Next Steps

List of Possible Actions
Decision
(Log and Report Process)

Plan Deployment

Deployment Plan
(Log and Report Process)

Plan Monitoring and Maintenance

*Monitoring and
Maintenance Plan*
(Log and Report Process)

Produce Final Report

Final Report
Final Presentation
(Log and Report Process)

Review Project

Experience
Documentation
(Log and Report Process)

Data Mining

Einsatzgebiete für Data Mining:

Klassifikation: Ein Objekt wird einer oder mehreren vordefinierten Kategorien zugeordnet

Clustering: Ein Objekt wird einer oder mehreren Klassen bzw. Clustern zugeordnet, wobei diese im Unterschied zur Klassifikation nicht vorgegeben sind, sondern erst bestimmt werden müssen. Natürliche Gruppierungen von Clustern sollen gefunden werden.

Modellierung von Abhängigkeiten: Lokale Abhängigkeiten zwischen Variablen werden etabliert. Die Stärke der Abhängigkeiten wird bei quantitativen Methoden numerisch angegeben.

Data Mining

Einsatzgebiete für Data Mining:

Sequenzanalyse: beschreibt Muster in sequentiellen Daten, um Regelmäßigkeiten und Trends transparent zu machen, beispielsweise in der Zeitreihenanalyse

Assoziationen: sind Zusammenhänge zwischen mehreren Merkmalen und werden meist durch *Assoziationsregeln* repräsentiert.

Im Folgenden werden Assoziationen in Form von Assoziationsregeln eingehender behandelt.

Assoziationsregeln

beschreiben gewisse Zusammenhänge und Regelmäßigkeiten zwischen verschiedenen Dingen wie z.B. den Artikeln eines Warenhauses oder sozio-ökonomischen Merkmalen

Zusammenhänge sind allgemeiner Art, nicht notwendigerweise kausaler Natur

Annahme: in diesen Assoziationen manifestieren sich implizite strukturelle Abhängigkeiten

Beispiel: Warenkorbanalyse

Label	Artikel	t_1	t_2	t_3	t_4	t_5	t_6	t_7	t_8	t_9	t_{10}	support
A	Seife	•				•		•		•		0,4
B	Shampoo	•	•	•	•		•		•	•	•	0,8
C	Haarspülung		•	•	•		•		•	•		0,6
D	Duschgel	•			•		•	•		•	•	0,6
E	Zahnpasta	•		•		•		•				0,4
F	Zahnbürste			•		•						0,2
G	Haarfärbung		•		•				•			0,3
H	Haargel		•									0,1
J	Deodorant			•	•	•	•	•	•			0,6
K	Parfüm						•		•			0,2
L	Kosmetikartikel		•		•		•		•		•	0,5

Einkaufstransaktionen in einem Drogeriemarkt

Assoziationsregeln, Formales

behandelte Dinge: *Items*, $\mathcal{I} = \{i_1, i_2, \dots\}$

$\mathcal{X} \subseteq \mathcal{I}$: Itemmenge

k-Itemmenge: Itemmenge mit k Elementen

Transaktion $t \subseteq \mathcal{I}$ ist eine Itemmenge

$\mathcal{D} = \{t_1, t_2, \dots\}$ Menge von Transaktionen als Datenbasis

Relativer Anteil aller Transaktionen, die X enthalten:

$$\text{support}(X) = \frac{|\{t \in \mathcal{D} \mid X \subseteq t\}|}{|\mathcal{D}|}$$

Assoziationsregeln, Formales

Assoziationsregel: $X \rightarrow Y$

- $X, Y \subseteq \mathcal{I}$
- $X \cap Y = \emptyset$

$support(X \rightarrow Y) = support(X \cup Y)$

Relativer Anteil derjenigen X enthaltenden Transaktionen, die auch Y enthalten:

$$confidence(X \rightarrow Y) = \frac{|\{t \in \mathcal{D} \mid (X \cup Y) \subseteq t\}|}{|\{t \in \mathcal{D} \mid X \subseteq t\}|} \quad (1)$$

$$= \frac{support(X \rightarrow Y)}{support(X)} \quad (2)$$

Assoziationsregeln, Algorithmus

Aufgabe: Finde alle Assoziationsregeln, die in der betrachteten Datenbasis mit einem Support von mindestens *minsupp* und einer Konfidenz von mindestens *minconf* gelten, wobei *minsupp* und *minconf* benutzerdefinierte Werte sind.

Teilaufgabe 1: Finde alle Itemmengen, deren Support über der *minsupp*-Schwelle liegt. Diese Mengen werden *häufige Itemmengen* (frequent itemsets) genannt.

Teilaufgabe 2: Finde in jeder häufigen Itemmenge I alle Assoziationsregeln $I' \rightarrow (I - I')$ mit $I' \subset I$, deren Konfidenz mindestens *minconf* beträgt.

Nützliche Tatsache für den folgenden *apriori*-Algorithmus: Alle Teilmengen einer häufigen Itemmenge sind ebenfalls häufig. Alle Obermengen einer nicht häufigen Itemmenge sind ebenfalls nicht häufig.

Apriori-Algorithmus

Algorithmus: Apriori

Eingabe: Datenbasis \mathcal{D}

Ausgabe: Menge häufiger Itemmengen

$L_1 := \{\text{häufige 1-Itemmengen}\}$

$k := 2$

while $L_{k-1} \neq \emptyset$ **do**

$C_k := \text{AprioriGen}(L_{k-1})$

for all Transaktionen $t \in \mathcal{D}$ **do**

$C_t := \{c \in C_k \mid c \subseteq t\}$

for all Kandidaten $c \in C_t$ **do**

$c.\text{count} := c.\text{count} + 1$

end for

end for

$L_k := \{c \in C_k \mid c.\text{count} \geq |\mathcal{D}| \cdot \text{minsupp}\}$

$k := k + 1$

end while

return $\bigcup_k L_k$

Apriori-Algorithmus

Algorithmus: $AprioriGen(L_{k-1})$

Eingabe: Menge häufiger $(k-1)$ -Itemmengen L_{k-1}

Ausgabe: Obermenge der Menge häufiger k -Itemmengen

$C_k := \emptyset$

for all $p, q \in L_{k-1}$ mit $p \neq q$ **do**

if p und q haben $k - 2$ gleiche Elemente

$p = \{e_1, \dots, e_{k-2}, e_p\}$

$q = \{e_1, \dots, e_{k-2}, e_q\}$

und $e_p < e_q$ **then**

$C_k := C_k \cup \{\{e_1, \dots, e_{k-2}, e_p, e_q\}\}$

end if

end for

for all $c \in C_k$ **do**

for all $(k - 1)$ -Teilmengen s von c **do**

if $s \notin L_{k-1}$ **then**

$C_k := C_k \setminus \{c\}$

end if

end for

end for

return C_k

Beispiel: Warenkorbanalyse

ideales Einsatzszenario für Assoziationsregeln

- Modellbildung ist nicht nötig
- Regeln können isoliert betrachtet werden
- Daten stehen in der Regel bereits zur Verfügung

Beispiel: Warenkorbanalyse

Label	Artikel	t_1	t_2	t_3	t_4	t_5	t_6	t_7	t_8	t_9	t_{10}	support
A	Seife	•				•		•		•		0,4
B	Shampoo	•	•	•	•		•		•	•	•	0,8
C	Haarspülung		•	•	•		•		•	•		0,6
D	Duschgel	•			•		•	•		•	•	0,6
E	Zahnpasta	•		•		•		•				0,4
F	Zahnbürste			•		•						0,2
G	Haarfärbung		•		•				•			0,3
H	Haargel		•									0,1
J	Deodorant			•	•	•	•	•	•			0,6
K	Parfüm						•		•			0,2
L	Kosmetikartikel		•		•		•		•		•	0,5

Einkaufstransaktionen in einem Drogeriemarkt

Beispiel: Warenkorbanalyse

gesucht: alle Assoziationsregeln mit:

- $\text{minsupp} = 0,4$
- $\text{minconf} = 0,7$

in realen Anwendung wird *minsupp* in der Regel sehr viel kleiner gewählt ($< 0,01$)

häufige 1-Itemmengen:

$$L_1 = \{\{A\}, \{B\}, \{C\}, \{D\}, \{E\}, \{J\}, \{L\}\}$$

Beispiel: Warenkorbanalyse

Berechnung der Menge C_2 : alle paarweisen Kombinationen von Mengen in L_1 bilden und deren Support bestimmen.

C_2 -Menge	Support	C_2 -Menge	Support	C_2 -Menge	Support
{A,B}	0,2	{B,D}	0,5	{C,L}	0,4
{A,C}	0,1	{B,E}	0,2	{D,E}	0,2
{A,D}	0,2	{B,J}	0,4	{D,J}	0,3
{A,E}	0,3	{B,L}	0,5	{D,L}	0,3
{A,J}	0,2	{C,D}	0,3	{E,J}	0,3
{A,L}	0,0	{C,E}	0,1	{E,L}	0,0
{B,C}	0,6	{C,J}	0,4	{J,L}	0,3

Beispiel: Warenkorbanalyse

häufigste 2-Itemmengen:

$$L_2 = \{\{B, C\}, \{B, D\}, \{B, J\}, \{B, L\}, \{C, J\}, \{C, L\}\}$$

Berechnung von C_3 :

C_3 vor Teilmengencheck	C_3 nach Teilmengencheck	Support
$\{B, C, D\}$	$\{B, C, J\}$	0,4
$\{B, C, J\}$	$\{B, C, L\}$	0,4
$\{B, C, L\}$		
$\{B, D, J\}$		
$\{B, D, L\}$		
$\{B, J, L\}$		
$\{C, J, L\}$		

Beispiel: Warenkorbanalyse

Damit ist

$$L_3 = \{\{B, C, J\}, \{B, C, L\}\}$$

einzig mögliche weitere Kombination: $\{B, C, J, L\}$

allerdings nicht häufig, daher ist $C_4 = L_4 = \emptyset$

Beispiel: Warenkorbanalyse

Bildung der Assoziationsregeln aus den häufigen Itemmengen:

Regel	Konfidenz	Regel	Konfidenz
$B \rightarrow C$	0,75	$C \rightarrow B$	1,00
$B \rightarrow D$	0,63	$D \rightarrow B$	0,83
$B \rightarrow J$	0,50	$J \rightarrow B$	0,67
$B \rightarrow L$	0,63	$L \rightarrow B$	1,00
$C \rightarrow J$	0,67	$J \rightarrow C$	0,67
$C \rightarrow L$	0,67	$L \rightarrow C$	0,80

fünf der Regeln erfüllen die Konfidenzbedingung ($\text{minconf} = 0,7$)

Beispiel: Warenkorbanalyse

l_3 enthält $l_{3.1} = \{B, C, J\}$ und $l_{3.2} = \{B, C, L\}$

$l_{3.1}$ (in l_3 die Konfidenz der Regel)

- $H_1 = \{B, C, J\}$
- Regeln: $BC \rightarrow J$ [0,67], $BJ \rightarrow C$ [1,00], $CJ \rightarrow B$ [1,00]
- $H_2 = \text{AprioriGen}(H_1) = \{B, C\}$
- Regel: $J \rightarrow BC$ [0,67]

$l_{3.2}$

- Regeln: $BC \rightarrow L$ [0,67], $BL \rightarrow C$ [0,8], $CL \rightarrow B$ [1,00]
- durch Erweiterung der Konklusion noch: $L \rightarrow BC$ [0,8]

Beispiel: Warenkorbanalyse

Regel		Support	Konfidenz
Shampoo	→	Haarspülung	0,6 0,75
Haarspülung	→	Shampoo	0,6 1,00
Duschgel	→	Shampoo	0,5 0,83
Kosmetik	→	Shampoo	0,5 1,00
Kosmetik	→	Haarspülung	0,4 0,80
Shampoo, Deodorant	→	Haarspülung	0,4 1,00
Haarspülung, Deodorant	→	Shampoo	0,4 1,00
Shampoo, Kosmetik	→	Haarspülung	0,4 0,80
Haarspülung, Kosmetik	→	Shampoo	0,4 1,00
Kosmetik	→	Shampoo, Haarspülung	0,4 0,80

FPM – Frequent Pattern Mining

Werbung in eigener Sache: während der prüfungsfreien Zeit wird die Blockveranstaltung „**Frequent Pattern Mining**“ stattfinden, die von PD Christian Borgelt gehalten wird. In dieser Veranstaltung geht es um das Finden häufiger Muster verschiedenster Formen in Daten, u.a. Assoziationsregeln. Verschiedene Algorithmen zum Thema werden vorgestellt und eingehend behandelt.

Weitere Informationen sind verfügbar unter:

<http://www.borgelt.net/teach/fpm>

IDA – Intelligent Data Analysis

Werbung in eigener Sache: im **Sommersemester** wird unsere reguläre Vorlesung „**Intelligent Data Analysis**“ stattfinden. Es geht dort unter anderem um klassische Statistik, Assoziationsregeln, Bayes'sche Klassifikation, Entscheidungs- und Regressionsbäume, Fuzzy-Datenanalyse und Clustering-Techniken.

Weitere Informationen werden bald verfügbar sein unter:


<http://fuzzy.cs.ovgu.de/wiki/pmwiki.php?n=Lehre.IDA2013>

Big Data

Massendaten, die mit Standard-Datenbanktools nicht effizient verarbeitet werden können

Verwendungsbeispiele:

- Internet-Statistiken für Online-Werbung
- Überwachung von Hochfrequenzhandel
- Smart Metering: intelligente Energieverbrauchssteuerung
- personalisierte Medizin
- (Teile-)Bedarfsplanung eines Konzerns





Chancen: Big Data Mining

Lösungen:

- parallele Verarbeitung
- Zerlegung in Teilprobleme
- In-Disk- vs. In-Memory-Datenbanken

Herausforderungen:

- Erweiterung klassischer Verfahren
- Datenqualität
- gleichzeitige Verfügbarkeit der Daten
- Verarbeitung extrem vieler Datensätze mit hoher Anzahl an Attributen
- schneller Import
- kurze Antwortzeiten, auch bei komplexen Anfragen



Risiken: Big Data Mining

“Machines don’t make the essential and important connections among data and they don’t create information. Humans do.”

Jim Stikeleather
(Dell Chief Innovation Officer)







“We’ve got lots of dirt–data. And there’s definitely gold in our data. But to refine it into information, you need people that have been doing this for years.”

Rob Lux (Freddie Mac Chief Information Officer)

“With any Big Data project, if you don’t spend time thinking about analysis, you’re wasting your money. You must have a structured idea of what you want to get out of unstructured data.”

Ron Gill (NetSuite CFO)

Weiterführende Literatur I

-  Bishop, C. M. (2006).
Pattern Recognition and Machine Learning.
Springer, 2. edition.
-  Carbonell, J. G., Michalski, R. S., and Mitchell, T. M. (1984).
An overview of machine learning.
In Michalski, R. S., Carbonell, J. G., and Mitchell, T. M., editors, *Machine Learning: An Artificial Intelligence Approach*, pages 3–23. Springer, Berlin, Heidelberg.
-  Hastie, T., Tibshirani, R., and Friedman, J. (2009).
The Elements of Statistical Learning: Data Mining, Inference, and Prediction.
Springer, 2. edition.
-  Michalski, R. S. (1986).
Understanding the nature of learning: Issues and research directions.
In Michalski, R. S., Carbonell, J. G., and Mitchell, T. M., editors, *Machine Learning: An Artificial Intelligence Approach (Volume 2)*, pages 3–26. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA.

Weiterführende Literatur II



Michalski, R. S. and Kodratoff, Y. (1990).

Research in machine learning: Recent progress, classification of methods, and future directions.

In Kodratoff, Y. and Michalski, R. S., editors, *Machine Learning*, pages 3–30. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA.



Michalski, S. R., Carbonell, G. J., and Mitchell, M. T., editors (1986).

Machine learning an artificial intelligence approach volume II.

Morgan Kaufmann Publishers Inc., San Francisco, CA, USA.



Mitchell, T. (1997).

Machine Learning.

McGraw Hill.



Simon, H. A. (1983).

Why should machines learn?

In *Machine Learning, An Artificial Intelligence Approach*. Tioga, Palo Alto, California.