

**Applied Analytical Data Science**  
Teil 7: Regression (forts.),  
Assoziationsregelverfahren

Dr. Jörg-Uwe Kietz,  
Vorlesung an der Univ. Zürich,  
Mittwoch, 14:00-15:45 Uhr Vorlesung,  
16:00-17:30 Uhr Übung

<http://www.kietz.ch/AADS/>

## Heutiges Programm

---



### Regression

- lineare Regression
- Regressions- & Modellbäume
- andere regressionstaugliche Verfahren

### • Assoziationsregeln

- Definition, Anwendungen, Beispiel
- Apriori-Verfahren
- Assoziationsregeln & Hierarchien
- Assoziationsregeln & Sequenzen

## Definition Klassifikation und Regression

---

Gegeben:

Eine Menge von Beispielen, beschrieben durch

- Eingabeattribute, und
- ein Zielattribut: nominal (Klassifikation)  
numerisch (Regression)

Gesucht:

Eine Funktion (Baum, Regeln, Funktion, Neuronales Netz ...):

- zur Berechnung/Vorhersage des Zielattributes, für jedes neue, nur durch die Eingabeattribute beschriebene Beispiel.


## Lineare Regression

---

- Bestimmung der besten Hyperebene, d.h. Bestimmung der Gewichte  $w_0, \dots, w_k$ , so dass der Zielwert  $x^{(i)}$  eines Beispiels  $i$  aus den Attributen  $a_1, \dots, a_k$  berechnet werden kann
$$x^{(i)} = w_0^{(i)} + w_1 a_1^{(i)} + \dots + w_k a_k^{(i)} = \sum_{j=0}^k w_j a_j^{(i)}$$
- Die Gewichte ergeben sich als Lösung des Optimierungsproblems zur Minimierung des quadratischen Fehlers über allen Trainingsbeispielen  
Minimierung von:  $\sum_{i=1}^n (x^{(i)} - \sum_{j=0}^k w_j a_j^{(i)})^2$


## Lineare Regression

---




## Lineare Modelle können zu einfach sein

---



## Lösung: Modellbäume

---



## Modell und Regressionsbäume

---

- Ein **Regressionsbaum** ist ein Entscheidungsbaum an dessen Blättern ein **konstanter Wert** für ein **skalares Zielattribut** vorhergesagt wird.
- Ein **Modellbaum** ist ein Entscheidungsbaum an dessen Blättern eine **lineare Regression** zur Berechnung des **skalaren Zielattributs** benutzt wird.
- Die Attributauswahl beim Bilden der Bäume basiert auf der **Fehlerminimierung** (oder vereinfacht Minimierung der Standard Abweichung) statt auf Informationgain durch Wahl des Attributes.



## Andere regressionstaugliche Verfahren

---

- Instance based learning (IBL):  
Vorhersage des Durchschnitts der k nächsten Nachbarn.
- Support vector machine (SVM):  
Minimierung des Fehlers statt Maximierung des Abstands, ergibt lineare Regression mit Kernfunktionen für nicht-lineare Aufgaben.
- Neuronale Netze:  
direkte Interpretation der Ausgabereinheit ergibt eine nicht-lineare Regression.

## Heutiges Programm

---

- Regression
  - lineare Regression
  - Regressions- & Modellbäume
  - andere regressionstaugliche Verfahren



### Assoziationsregeln

- Definition, Anwendungen, Beispiel
- Apriori-Verfahren
- Assoziationsregeln & Hierarchien
- Assoziationsregeln & Sequenzen

## Assoziationsregeln Definition

---

Gegeben:

- Eine Menge von Transaktionen
- Eine minimale Sicherheit (confidence)
- Eine minimale Unterstützung (support)

Gesucht:

- Alle maximalen Assoziationsregeln, mit
- höherer Sicherheit, und
- höherer Unterstützung

## Assoziationsregeln Aufgaben

---

Aufgaben:

- Warenkorbanalyse, oder
  - Was wird zusammen gekauft?
  - Cross-selling, Sonderangebotsplanung, ...

Im Allgemeinen:

- Finde häufige Muster, z.B.:
  - Produkt / Kunden Muster
  - Sequenzmuster in Zeitreihen, Texten, ...

## Beispiel Assoziationsregeln

---

Einige Transaktionen	Was wurde zusammen gekauft?		
1: cola, beer, juice	cola → juice	C:100%	S:40%
2: beer, wine	juice → beer	C:75%	S:60%
3: juice, beer	beer → juice	C:75%	S:60%
4: cola, juice, wine	wine → beer	C:66%	S:40%
5: juice, beer, wine	wine → juice	C:66%	S:40%
	cola, beer → juice	C:100%	S:20%
	cola, wine → juice	C:100%	S:20%
	...		

## Assoziationsregeln

---

- Gegeben ist eine Menge **D** von Transaktionen **t**. Jedes **t** besteht aus einer Menge von Items **I** (Atome: Binäres Attribute)  $t \subseteq I$
- Assoziationsregel:  $X \rightarrow Y$ , mit  $X \subseteq I$  und  $Y \subseteq I$
- Eine Transaktion **t** erfüllt eine Regel  $X \rightarrow Y$ , falls  $(X \cup Y) \subseteq t$
- **Support** ist der Anteil der Transaktionen, der die Regel erfüllt:

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

- **Confidence** misst die Korrektheit der Regel:

$$\text{confidence}(X \rightarrow Y) = \frac{|\{t \in D \mid (X \cup Y) \subseteq t\}|}{|\{t \in D \mid X \subseteq t\}|} = \frac{\text{support}(X \rightarrow Y)}{\text{support}(X)}$$


## Def: Assoziationsproblem

---

- Definition (**Assoziationsproblem**):
  - gegeben: Menge D von Transaktionen  
Wert für minimalen Support  $s_{\min}$   
Wert für minimale Konfidenz  $c_{\min}$
  - gesucht: Finde alle Assoziationsregeln  $X \rightarrow Y$  , so daß  
 $\text{support}(X \rightarrow Y) \geq s_{\min}$   
 $\text{confidence}(X \rightarrow Y) \geq c_{\min}$

## Heutiges Programm

---

- Regression
  - lineare Regression
  - Regressions- & Modellbäume
  - andere regressionstaugliche Verfahren
- Assoziationsregeln
  - Definition, Anwendungen, Beispiel
  -  – Apriori-Verfahren
  - Assoziationsregeln & Hierarchien
  - Assoziationsregeln & Sequenzen



# Apriori Algorithmus

---

## Idee:

Schritt 1: Bestimme Itemmengen mit vorgegebenem Mindestsupport

=> **häufige Itemmengen**

Schritt 2: Sei X häufige Itemmenge, dann gilt für  $X' \subseteq X$ :

$$\text{confidence}((X - X') \rightarrow X') = \frac{\text{support}(X)}{\text{support}(X - X')}$$

d.h. die Konfidenz läßt sich aus dem Support der häufigen Itemmengen berechnen.

Bilde alle **Assoziationsregeln** aus häufigen Itemmengen mit vorgegebener Mindestkonfidenz.

## Berechnung der häufigen Itemmengen

---

- für  $X' \subseteq X$  gilt:  $\text{support}(X') \geq \text{support}(X)$   
=> wenn  $X$  häufige Itemmenge ist, dann auch  $X'$ .
- berechne sukzessive die häufigen Itemmengen mit 1,2,3,... Elementen.
- fasse die häufigen Itemmengen mit  $i$  Elementen zur Menge  $I_i$  zusammen:  $I_i := \{X \mid X \text{ ist häufige Itemmenge, } |X| = i\}$
- für  $X \in I_{n+1}$  gilt: alle  $n$ -elementigen Teilmengen von  $X$  sind häufig.
- Berechnung von  $I_{n+1}$  aus  $I_n$ :
  - $n$ -elementige **häufige** Mengen werden um jeweils 1 Element erweitert.
  - prüfe, ob  $(n+1)$ -elementige Menge häufig ist:  
wenn ja, nehme  $(n+1)$ -elementige Menge in  $I_{n+1}$  auf.

## Beispiel Apriori

Einkaufs-Transaktionen	gekaufte Artikel (Items)
t <sub>1</sub>	Saft, Cola, Bier
t <sub>2</sub>	Saft, Cola, Wein
t <sub>3</sub>	Saft, Wasser
t <sub>4</sub>	Cola, Bier, Saft
t <sub>5</sub>	Saft, Cola, Bier, Wein
t <sub>6</sub>	Wasser



Artikel (Item)	Transaktionen, in denen der Artikel vorkommt	Support des Items
Saft	t <sub>1</sub> , t <sub>2</sub> , t <sub>3</sub> , t <sub>4</sub> , t <sub>5</sub>	5/6 = 83.3%
Cola	t <sub>1</sub> , t <sub>2</sub> , t <sub>4</sub> , t <sub>5</sub>	4/6 = 66.6%
Bier	t <sub>1</sub> , t <sub>4</sub> , t <sub>5</sub>	3/6 = 50 %
Wein	t <sub>2</sub> , t <sub>5</sub>	2/6 = 33.3%
Wasser	t <sub>3</sub> , t <sub>6</sub>	2/6 = 33.3%

## Beispiel Apriori: häufige Itemmengen

Artikel (Item)	Transaktionen, in denen der Artikel vorkommt	Support des Items
Soft	$t_1, t_2, t_3, t_4, t_5$	$5/6 = 83.3\%$
Cola	$t_1, t_2, t_4, t_5$	$4/6 = 66.6\%$
Bier	$t_1, t_4, t_5$	$3/6 = 50\%$
Wein	$t_2, t_5$	$2/6 = 33.3\%$
Wasser	$t_3, t_6$	$2/6 = 33.3\%$

↓

n	$H_n$	$I_n$
1	$\{\{\text{Soft}\}, \{\text{Cola}\}, \{\text{Bier}\}, \{\text{Wein}\}, \{\text{Wasser}\}\}$	$\{\{\text{Soft}\}, \{\text{Cola}\}, \{\text{Bier}\}\}$
2	$\{\{\text{Soft, Cola}\}, \{\text{Soft, Bier}\}, \{\text{Cola, Bier}\}\}$	$\{\{\text{Soft, Cola}\}, \{\text{Cola, Bier}\}, \{\text{Soft, Bier}\}\}$
3	$\{\{\text{Soft, Cola, Bier}\}\}$	$\{\{\text{Soft, Cola, Bier}\}\}$
4	$\{\}$	$\{\}$

## Beispiel Apriori: Von Itemmengen zu Regeln

---

zu Schritt 2:

- gegeben:  $c_{\min} = 75\%$
- wähle z.B.  $\{\text{Saft, Cola}\} \in I_2$

$$\text{confidence}(\text{Saft} \rightarrow \text{Cola}) = \frac{\text{support}(\{\text{Saft, Cola}\})}{\text{support}(\{\text{Saft}\})} = \frac{2/3}{5/6} = 80\%$$

$$\text{confidence}(\text{Cola} \rightarrow \text{Saft}) = \frac{\text{support}(\{\text{Saft, Cola}\})}{\text{support}(\{\text{Cola}\})} = \frac{2/3}{2/3} = 100\%$$

## Algorithmus für häufige Itemmengen

---

1. Initialisierung:

$s_{\min}$  = Wert für minimalen Support;

$n := 1$ ;

$I := \emptyset$ ;

$H_n := \{\{i\} \mid i \text{ ist ein Item}\}$ ;

2. gehe über die Datenbasis  $D$  und bestimme für alle  $H \in H_n$  den Support;

3.  $I_n := \{H \in H_n \mid \text{support}(H) \geq s_{\min}\}$ ;

$I := I \cup I_n$ ;

4. Falls  $I_n = \emptyset$ , gebe  $I$  als Ergebnis aus;

5.  $H_{n+1} := \{\{i_1, i_2, \dots, i_{n+1}\} \mid \forall j: 1 \leq j \leq n+1: (\{i_1, i_2, \dots, i_{n+1}\} - \{i_j\}) \in I_n\}$ ;

$n := n+1$ ;

6. gehe nach 2.

## Gefundene Assoziationsregeln

**Fortführung des Beispiels:** abgeleitete Assoziationsregeln zu den häufigen Itemmengen

Regeln mit Support $\geq 50\%$	erfüllende Transaktionen	Support	Konfidenz
Saft $\rightarrow$ Cola	$t_1, t_2, t_4, t_5$	66%	80%
Cola $\rightarrow$ Saft	$t_1, t_2, t_4, t_5$	66%	100%
Cola $\rightarrow$ Bier	$t_1, t_4, t_5$	50%	75%
Bier $\rightarrow$ Cola	$t_1, t_4, t_5$	50%	100%
Saft $\rightarrow$ Bier	$t_1, t_4, t_5$	50%	60%
Bier $\rightarrow$ Saft	$t_1, t_4, t_5$	50%	100%
Saft, Bier $\rightarrow$ Cola	$t_1, t_4, t_5$	50%	100%
Cola, Saft $\rightarrow$ Bier	$t_1, t_4, t_5$	50%	75%
Bier, Cola $\rightarrow$ Saft	$t_1, t_4, t_5$	50%	100%
Cola $\rightarrow$ Saft, Bier	$t_1, t_4, t_5$	50%	75%
Bier $\rightarrow$ Cola, Saft	$t_1, t_4, t_5$	50%	100%
Saft $\rightarrow$ Cola, Bier	$t_1, t_4, t_5$	50%	60%

## Zusammenfassung Apriori


---

- sofern häufige Itemmengen mit  $n$  Elementen existieren, benötigt der Algorithmus  $n$  Durchläufe
  - => 1 Megabyte Warenkorb-Daten im Sekundenbereich analysiert
- Algorithmus entdeckt Tausende von Regeln:
  - **Visualisierung, Browsing** notwendig
  - Regeln mit sehr hohen Support-/Konfidenzwerten schon bekannt
  - Regeln im "**Mittelfeld**" interessant
  - verwende zusätzlich statistische Maße für Bewertung von Regeln
- Regeln berücksichtigen viele **externe Einflußfaktoren** nicht, da diese in den Transaktionen nicht repräsentiert sind:
  - Käufergruppen (Alter, sozialer Status, ...)
  - Tageszeit, Wochentag
  - Werbekampagnen



## Heutiges Programm

---

- Regression
  - lineare Regression
  - Regressions- & Modellbäume
  - andere regressionstaugliche Verfahren
- Assoziationsregeln
  - Definition, Anwendungen, Beispiel
  - Apriori-Verfahren
  -  – Assoziationsregeln & Hierarchien
  - Assoziationsregeln & Sequenzen

## Assoziationsregeln & Hierarchien


---

- Regeln können durch Hintergrundwissen verallgemeinert werden
  - verwende **Taxonomien** über Items zur Bildung von Warengruppen,  
z.B. Bier *is-a* alkoholisches Getränk  
Chips *is-a* Salzgebäck
  - damit können abstraktere Regeln gebildet werden,  
z.B. (Salzgebäck → Bier)  
(Chips → alkoholisches Getränk)
- benötigtes Wissen kann durch **Ontologien** und **Domänenmodelle** bereitgestellt werden

## Beispiele für Hierarchien

---

**Example:** Taxonomy for Clothes and Footwear (Srikant/Agrawal 1995)



## Apriori-Erweiterung für Hierarchien

---

Basis-Idee zum Lernen von Assoziationen mit Hierarchien:

- (1) Erweiterung (saturierung) der Transaktionen: Transaktion mit **Jacket** => Transaktion mit **Outerwear** und **Clothes**
  - (2) Benutze Frequent-Itemsets (Apriori) auf den erweiterten Transaktionen.
  - (3) Benutze Generate-Rules (Apriori) um alle Regeln mit minimum Support und Confidence zu generieren.
- => nicht alle Regeln sind interessant!!!
- (4) Lösche alle uninteressanten (insb. die redundanten) Regeln

## Saturierung der Itemsets

---

- transaction **t supports** an itemset  $X$ , if for each item  $x \in X$   $t$  contains  $x$  or some sub-concepts of  $x$ :
  - check becomes simpler if we first add to  $t$  all (direct/indirect) super-concepts of  $x$ ; we call the resulting transaction  $t'$  an **extended** transaction.
  - **t supports X** iff<sup>1</sup>
    - $t'$  is a superset of  $X$ .

## Itemsets und Hierarchien

**Example:** (Srikant/Agrawal 1995)

- given database D:

Transaction	Items Bought
100	Shirt
200	Jacket, Hiking Boots
300	Ski Pants, Hiking Boots
400	Shoes
500	Shoes
600	Jacket

- assume: minimum support = 30%, minimum confidence = 60%

Itemset	Support
{ Jacket }	2
{ Outerwear }	3
{ Clothes }	4
{ Shoes }	2
{ Hiking Boots }	2
{ Footwear }	4
{ Outerwear, Hiking Boots }	2
{ Clothes, Hiking Boots }	2
{ Outerwear, Footwear }	2
{ Clothes, Footwear }	2

Rule	Support	Conf.
Outerwear $\Rightarrow$ Hiking Boots	33%	66.6%
Outerwear $\Rightarrow$ Footwear	33%	66.6%
Hiking Boots $\Rightarrow$ Outerwear	33%	100%
Hiking Boots $\Rightarrow$ Clothes	33%	100%

## Beobachtungen zu hierarchischen Regeln (1)

---

- rules 'Ski Pants => Hiking Boots',  
'Jackets => Hiking Boots'  
do **not** have minimum support.
  - generalized rule 'Outerwear => Hiking Boots'  
may have minimum support.
- let  $\hat{x}$  denote the (direct/indirect) super-concept of  $x$ :
  - if ' $x \Rightarrow y$ ' has **minimum support**, so do  
' $x \Rightarrow \hat{y}$ ', ' $\hat{x} \Rightarrow y$ ' and ' $\hat{x} \Rightarrow \hat{y}$ '.

## Beobachtungen zu hierarchischen Regeln (2)

---

- rule 'Outerwear => Hiking Boots' has minimum confidence
  - generalized rule may **not** have minimum confidence:  
'Clothes => Hiking Boots' has only confidence of 50%
  
- if 'x => y' has **minimum confidence**, so does 'x =>  $\hat{y}$ '.  
rules 'x => y' and 'x =>  $\hat{y}$ ' may not have minimum confidence.



## Beobachtungen zu hierarchischen Regeln (3)

---

- support for an item x is **not** equal to the sum of the supports of its sub-concepts:
  - several sub-concepts may be present in a **single** transaction

## Pruning von redundanten Regeln

---

- assume 'Outerwear => Hiking Boots' with support 8%, confidence 70%
- assume that 25% of 'Outerwear'-transactions are 'Ski Pants'-transactions
- we therefore **expect** a rule  
    'Ski Pants => Hiking Boots'  
with support 2% and confidence 70%.
- if such a rule is generated, the more special rule is **redundant** when compared to the more general rule.

## Interessante Regeln

---

- let  $R$  be a user-specified minimum interest
- for a rule ' $X \Rightarrow Y$ ', we call the rules ' $X \Rightarrow \hat{Y}$ ', ' $\hat{X} \Rightarrow Y$ ', ' $\hat{X} \Rightarrow \hat{Y}$ ' its ancestors
- for a rule ' $X \Rightarrow Y$ ', we call the rule ' $\hat{X} \Rightarrow \hat{Y}$ ' its **close ancestor**, if there is no rule ' $X^* \Rightarrow Y^*$ ', such that
  - ' $X^* \Rightarrow Y^*$ ' is an ancestor of ' $X \Rightarrow Y$ ' and
  - ' $\hat{X} \Rightarrow \hat{Y}$ ' is an ancestor of ' $X^* \Rightarrow Y^*$ '.
- A rule ' $X \Rightarrow Y$ ' is **interesting** if
  - it has no ancestors or
  - it is  $R$ -interesting with respect to its close ancestors

## Beispiele für interessante Regeln

Example: (Srikant/Agrawal 1995)

Rule #	Rule	Support	Item	Support
1	"Clothes $\Rightarrow$ Footwear"	10	Clothes	5
2	"Outerwear $\Rightarrow$ Footwear"	8	Outerwear	2
3	"Jackets $\Rightarrow$ Footwear"	4	Jackets	1

- assume  $R=2$
- rule 1 is **interesting**, since it has **no ancestors**.
- rule 2 is **interesting**, since its support is twice (**R times**) the expected support based on rule 1:

(i) 
$$\frac{\text{support(Outerwear)}}{\text{support(Clothes)}} = \frac{2}{5}$$

(ii) expected support('Outerwear  $\Rightarrow$  Footwear') =  
$$\text{support('Clothes } \Rightarrow \text{ Footwear')} \cdot \frac{2}{5} = 10 \cdot \frac{2}{5} = 4$$
  
however: support('Outerwear  $\Rightarrow$  Footwear') = 8 =  $R \cdot 4$

## Beispiele für uninteressante Regeln

---

- rule 3 is **not interesting**, since its support is **equal** to the expected support based on rule 2:

$$(i) \frac{\text{support}(\text{Jackets})}{\text{support}(\text{Outerwear})} = \frac{1}{2}$$

$$(ii) \text{expected support}(\text{'Jackets' } \Rightarrow \text{'Footwear'}) = \frac{\text{support}(\text{'Outerwear' } \Rightarrow \text{'Footwear'})}{2} = 8 \cdot \frac{1}{2} = 4$$

Remark:

measure of interest is able to prune between 40% and 60% of all generated rules.

## Fazit zu Hierarchien und Assoziationen

---

- basic algorithm can be made **more efficient** by applying several optimization steps,
  - e.g. pre-compute all super-concepts of all available items
- taxonomy provides means for
  - generating **more useful** rules
  - **pruning uninteresting** rules

## Heutiges Programm

---

- Regression
  - lineare Regression
  - Regressions- & Modellbäume
  - andere regressionstaugliche Verfahren
- Assoziationsregeln
  - Definition, Anwendungen, Beispiel
  - Apriori-Verfahren
  - Assoziationsregeln & Hierarchien
  - Assoziationsregeln & Sequenzen



## Assoziationsregeln & Sequenzen

---

- Definition: Eine Sequenz-abhängige Assoziationsregel  $A \Rightarrow^T B$  ist eine Assoziation über einer diskreten Sequenz, mit der Bedeutung: „Wenn A vorkommt, kommt B innerhalb von T Elementen vor.“
- Der **Supportset(A,T)** einer Sequenz A ist die Menge aller Fenster der Grösse T, in denen die Elemente der Sequenz  $A = A_1, \dots, A_n$  in dieser Reihenfolge, aber nicht notwendigerweise aufeinanderfolgend, vorkommen.
- **Support( $A \Rightarrow^T B$ ) = | Supportset((A,B),T) |**
- Die **Konfidenz( $A \Rightarrow^T B$ ) = | Supportset((A,B),T) | / | Supportset(A,T) |**



## Mining von Assoziationen über Sequenzen

---

- Das Apriori-Verfahren ( $\Rightarrow$  Teil 4) kann fast unverändert zum Finden von sequenz abhängigen Assoziationsregeln benutzt werden, da Item-Mengen als sortierte Item-Listen implementiert werden.
- $\Rightarrow$  Die Berücksichtigung der Sequenz (vs. Menge, insb. das Weglassen der Sortierung) macht Apriori zu Apriori-Sequenz.
- Aber: Apriori ist exponentiell in der Anzahl der verschiedenen Items, d.h. der Aufwand von Apriori ist  $O(2^{|\text{Items}|})$
- Apriori-Sequenz ist exponentiell in der Anzahl der möglichen Item-Sequenzen der Länge  $T$ , davon gibt es:  $|\text{Items}|^T$
- $\Rightarrow$  Der Aufwand von Apriori-Sequenz ist  $O(2^{|\text{Items}|^T})$

## Fazit

---

- Regression ist die Data Mining Methode zur Vorhersage von skalaren (kontinuierlichen) Werten.
  - Basis ist lineare Regression => Erweiterung zu Modellbäumen.
  - Auch IBL, SVM und Neuronale Netze können benutzt werden.
- Assoziations-Regel entdecken häufige Muster von zusammen auftretenden Elementen in Transaktionen
  - Apriori ist der Basis Algorithmus dieses Effizient zu tun
  - Erweiterung zu Hierarchien über Elementen (Produktgruppen)
  - Erweiterung zu Sequenzen von Elementen (Zeit, Text, ...)

## Literatur

---

### Data Mining Methoden für Regression und Assoziationsregeln:

- Witten, I.; Frank, E.: Practical Machine Learning Tools and Techniques with Java implementations, Morgan Kaufmann, 2000.
- K. Morik; S. Wrobel; T. Joachims: "Maschinelles Lernen und Data Mining" Beitrag zum »Handbuch KI«, G. Görz, J. Schneeberger und C.-R. Rollinger (Hrsg.), Oldenbourg Verlag, im erscheinen.  
PDF download: [http://www-ai.informatik.uni-dortmund.de/LEHRE/VORLESUNGEN/MLRN/SKRIPT/handbuch\\_ki-ml.pdf](http://www-ai.informatik.uni-dortmund.de/LEHRE/VORLESUNGEN/MLRN/SKRIPT/handbuch_ki-ml.pdf)
- R. Studer, S. Staab, A. Hotho, A. Mädche: Folien zur Vorlesung „Knowledge Discovery, WS 1999/2000“, AIFB, Univ. Karlsruhe,  
[http://www.aifb.uni-karlsruhe.de/WBS/Lehrveranstaltungen/kdd99\\_00/](http://www.aifb.uni-karlsruhe.de/WBS/Lehrveranstaltungen/kdd99_00/)