

Data Mining in Datenbanken

Alexander Hinneburg

hinneburg@informatik.uni-halle.de

www.informatik.uni-halle.de/~hinneburg

Vorlesungsplan

- 17.10. Einleitung
- 24.10. Ein- und Ausgabe
- 31.10. Reformationstag
- 7.11. Einfache Regeln, Naïve Bayes
- 14.11. Entscheidungsbäume, und Regeln
- 21.11. Assoziationsregeln
- 28.11. Lineare Modelle
- 5.12. Instanzbasiertes Lernen, Clustering
- 12.12. Evaluation I
- 19.12. Evaluation II
- 9.1. Entscheidungsbäume, Klassifikationsregeln
- 16.1. Lineare Modelle, Numerische Vorhersage
- 23.1. Clustering
- 30.1. Attribut-Selektion, Diskretisierung, Transformationen
- 6.2. Kombination von Modellen, Lernen von nicht-klassifizierten Beispielen

Veranstaltungsmodalitäten

- Vorlesung
 - Mischung aus Folien und Tafel
 - Ian Witten, Eibe Frank: Data Mining, 2. Aufl., Morgan Kaufmann, 2005
- Übung
 - Theorieaufgaben
 - Praktische Aufgaben,  EKA Data Mining Suite (<http://www.cs.waikato.ac.nz/~ml/weka/>), Oracle
 - Präsentation der Ergebnisse, 3-5 Folien
- Schein
 - 50% der Übungspunkte
 - Klausur Ende des Semesters
 - Wirtschaftsinformatiker: 2+2 Vorlesung, 6 Leistungspunkte
- Blockseminar
 - 2-3 Tage, Anfang April 2006 (vor Vorlesungsbeginn)

Einleitung

- Daten versus Wissen
- Data Mining und Machine Learning
- Strukturierte Beschreibungen
 - Regeln: Klassifikation und Assoziation
 - Entscheidungsbäume
- Daten
 - Wetter, Kontaktlinsen, CPU Performanz, Gewerkschaftsverhandlungen, Sojabohnen Klassifikation
- Echte Anwendungen
 - Kreditanwendungen, Satellitenaufnahmen, Lastvorhersage, Maschinenfehlerdiagnose, Warenkorbanalyse
- Verallgemeinerung als Suche
- Data Mining und Ethik

Daten versus Wissen

- Gesellschaft erzeugt riesige Datenmengen
 - Quellen: Wirtschaft, Wissenschaft, Medizin, Geo-Anwendungen, Sport, Umwelt, ...
- Potentiell wertvolle Ressource
- Rohdaten sind nutzlos: Methoden um Informationen automatisch daraus zu gewinnen
 - Daten: gespeicherte Fakten
 - Informationen: in den Daten inhärente Muster

Data Mining Aufgabe

- Extrahiere
 - implizite,
 - vorher unbekannte,
 - potentiell nützliche

Informationen aus Daten

- Bedarf: Programme, die Muster und Regelmäßigkeiten in Daten detektieren
- Interessante Muster \Rightarrow gute Vorhersagen
 - Problem 1: meisten Muster nicht interessant
 - Problem 2: Muster sind unscharf, unecht
 - Problem 3: Daten fehlen, sind fehlerbehaftet

Data Mining Methoden

- *Algorithmen zum Gewinnen (Lernen) struktureller Beschreibungen aus Beispielen*
- strukturelle Beschreibungen repräsentieren Muster explizit
 - Vorhersage in neuen Situationen möglich
 - Zum Verstehen und Erklären wie Vorhersage entstand (*meist wichtiger*)
- Methoden stammen aus Künstlicher Intelligenz, Statistik, Datenbanken, Visualisierung, Theoretische Informatik

Kontaktlinsen Daten

Age	Spectacle prescription	Astigmatism	Tear production rate	Recommended lenses
Young	Myope	No	Reduced	None
Young	Myope	No	Normal	Soft
Young	Myope	Yes	Reduced	None
Young	Myope	Yes	Normal	Hard
Young	Hypermetrope	No	Reduced	None
Young	Hypermetrope	No	Normal	Soft
Young	Hypermetrope	Yes	Reduced	None
Young	Hypermetrope	Yes	Normal	hard
Pre-presbyopic	Myope	No	Reduced	None
Pre-presbyopic	Myope	No	Normal	Soft
Pre-presbyopic	Myope	Yes	Reduced	None
Pre-presbyopic	Myope	Yes	Normal	Hard
Pre-presbyopic	Hypermetrope	No	Reduced	None
Pre-presbyopic	Hypermetrope	No	Normal	Soft
Pre-presbyopic	Hypermetrope	Yes	Reduced	None
Pre-presbyopic	Hypermetrope	Yes	Normal	None
Presbyopic	Myope	No	Reduced	None
Presbyopic	Myope	No	Normal	None
Presbyopic	Myope	Yes	Reduced	None
Presbyopic	Myope	Yes	Normal	Hard
Presbyopic	Hypermetrope	No	Reduced	None
Presbyopic	Hypermetrope	No	Normal	Soft
Presbyopic	Hypermetrope	Yes	Reduced	None
Presbyopic	Hypermetrope	Yes	Normal	None

Können Maschinen wirklich lernen?

- Definitionen für “lernen” aus dem Lexikon:

**Wissenserwerb durch Studium, Erfahrung
oder Belehrung** }

**Kenntnis erlangen durch sich informieren
oder durch Beobachtung** }

Auswendig lernen }

Informiert sein, etwas ermitteln, Instruktionen erhalten,

- Operationale Definition:

**Etwas lernt, wenn es sein Verhalten oder
Eigenschaften so ändert, dass es in
Zukunft besser funktioniert.** }

- Impliziert Lernen eine Intention?



Das Wetter Problem

- Umstände um Tennis zu spielen

Outlook	Temperature	Humidity	Windy	Play
Sunny	Hot	High	False	No
Sunny	Hot	High	True	No
Overcast	Hot	High	False	Yes
Rainy	Mild	Normal	False	Yes
Rainy	Cool	Normal	True	No
...

```
If outlook = sunny and humidity = high then play = no
If outlook = rainy and windy = true then play = no
If outlook = overcast then play = yes
If humidity = normal then play = yes
If none of the above then play = yes
```

Wetterdaten mit gemischten Attributen

- Einige Attribute haben numerische Werte

Outlook	Temperature	Humidity	Windy	Play
Sunny	85	85	False	No
Sunny	80	90	True	No
Overcast	83	86	False	Yes
Rainy	75	80	False	Yes
...

```
If outlook = sunny and humidity > 83 then play = no
If outlook = rainy and windy = true then play = no
If outlook = overcast then play = yes
If humidity < 85 then play = yes
If none of the above then play = yes
```

Ross Quinlan



- Machine learning Forscher seit 1970
 - University of Sydney, Australia
- 1986 “Induction of decision trees” *ML Journal*
- 1993 *C4.5: Programs for machine learning.*
Morgan Kaufmann
- 199? Started



**RULEQUEST
RESEARCH**
data mining tools

Klassifikations & Assoziationsregeln

- **Klassifikationsregel:**

Vorhersage für den Wert eines gegebenen Attributes

```
If outlook = sunny and humidity = high  
then play = no
```

- **Assoziationsregel:**

Vorhersage des Wertes eines beliebigen Attributes o. Kombination

```
If temperature = cool then humidity = normal  
If humidity = normal and windy = false  
then play = yes  
If outlook = sunny and play = no  
then humidity = high  
If windy = false and play = no  
then outlook = sunny and humidity = high
```

Wetterdaten (komplett)

- sunny hot high FALSE no
- sunny hot high TRUE no
- overcast hot high FALSE yes
- rainy mild high FALSE yes
- rainy cool normal FALSE yes
- rainy cool normal TRUE no
- overcast cool normal TRUE yes
- sunny mild high FALSE no
- sunny cool normal FALSE yes
- rainy mild normal FALSE yes
- sunny mild normal TRUE yes
- overcast mild high TRUE yes
- overcast hot normal FALSE yes
- rainy mild high TRUE no


Kontaktlinsen Daten

Age	Spectacle prescription	Astigmatism	Tear production rate	Recommended lenses
Young	Myope	No	Reduced	None
Young	Myope	No	Normal	Soft
Young	Myope	Yes	Reduced	None
Young	Myope	Yes	Normal	Hard
Young	Hypermetrope	No	Reduced	None
Young	Hypermetrope	No	Normal	Soft
Young	Hypermetrope	Yes	Reduced	None
Young	Hypermetrope	Yes	Normal	hard
Pre-presbyopic	Myope	No	Reduced	None
Pre-presbyopic	Myope	No	Normal	Soft
Pre-presbyopic	Myope	Yes	Reduced	None
Pre-presbyopic	Myope	Yes	Normal	Hard
Pre-presbyopic	Hypermetrope	No	Reduced	None
Pre-presbyopic	Hypermetrope	No	Normal	Soft
Pre-presbyopic	Hypermetrope	Yes	Reduced	None
Pre-presbyopic	Hypermetrope	Yes	Normal	None
Presbyopic	Myope	No	Reduced	None
Presbyopic	Myope	No	Normal	None
Presbyopic	Myope	Yes	Reduced	None
Presbyopic	Myope	Yes	Normal	Hard
Presbyopic	Hypermetrope	No	Reduced	None
Presbyopic	Hypermetrope	No	Normal	Soft
Presbyopic	Hypermetrope	Yes	Reduced	None
Presbyopic	Hypermetrope	Yes	Normal	None

Komplete und korrekte Regelmenge

```
If tear production rate = reduced then recommendation = none
If age = young and astigmatic = no
  and tear production rate = normal then recommendation = soft
If age = pre-presbyopic and astigmatic = no
  and tear production rate = normal then recommendation = soft
If age = presbyopic and spectacle prescription = myope
  and astigmatic = no then recommendation = none
If spectacle prescription = hypermetrope and astigmatic = no
  and tear production rate = normal then recommendation = soft
If spectacle prescription = myope and astigmatic = yes
  and tear production rate = normal then recommendation = hard
If age young and astigmatic = yes
  and tear production rate = normal then recommendation = hard
If age = pre-presbyopic
  and spectacle prescription = hypermetrope
  and astigmatic = yes then recommendation = none
If age = presbyopic and spectacle prescription = hypermetrope
  and astigmatic = yes then recommendation = none
```

Entscheidungsbaum für dieses Problem



Klassifizierung von Iris-Blumen



	Sepal length	Sepal width	Petal length	Petal width	Type
1	5.1	3.5	1.4	0.2	Iris setosa
2	4.9	3.0	1.4	0.2	Iris setosa
...					
51	7.0	3.2	4.7	1.4	Iris versicolor
52	6.4	3.2	4.5	1.5	Iris versicolor
...					
101	6.3	3.3	6.0	2.5	Iris virginica
102	5.8	2.7	5.1	1.9	Iris virginica
...					

```
If petal length < 2.45 then Iris setosa
If sepal width < 2.10 then Iris versicolor
...
```

Vorhersage CPU Performanz

- Beispiel: 209 verschiedene Computer Konfig.

	Cycle time (ns)	Main memory (Kb)		Cache (Kb)	Channels		Performanc e
	MYCT	MMIN	MMAX	CACH	CHMIN	CHMAX	PRP
1	125	256	6000	256	16	128	198
2	29	8000	32000	32	8	32	269
...							
208	480	512	8000	32	0	0	67
209	480	1000	4000	0	0	0	45



- Lineare Regression Funktion

$$\text{PRP} = -55.9 + 0.0489 \text{ MYCT} + 0.0153 \text{ MMIN} + 0.0056 \text{ MMAX} \\ + 0.6410 \text{ CACH} - 0.2700 \text{ CHMIN} + 1.480 \text{ CHMAX}$$

Gewerkschaftsverhandlungen

Attribute	Type	1	2	3	...	40
Duration	(Number of years)	1	2	3		2
Wage increase first year	Percentage	2%	4%	4.3%		4.5
Wage increase second year	Percentage	?	5%	4.4%		4.0
Wage increase third year	Percentage	?	?	?		?
Cost of living adjustment	{none,tcf,tc}	none	tcf	?		none
Working hours per week	(Number of hours)	28	35	38		40
Pension	{none,ret-allw, empl-cntr}	none	?	?		?
Standby pay	Percentage	?	13%	?		?
Shift-work supplement	Percentage	?	5%	4%		4
Education allowance	{yes,no}	yes	?	?		?
Statutory holidays	(Number of days)	11	15	12		12
Vacation	{below-avg,avg,gen}	avg	gen	gen		avg
Long-term disability assistance	{yes,no}	no	?	?		yes
Dental plan contribution	{none,half,full}	none	?	full		full
Bereavement assistance	{yes,no}	no	?	?		yes
Health plan contribution	{none,half,full}	none	?	full		half
Acceptability of contract	{good,bad}	bad	good	good		good

Entscheidungsbäume für Gewerkschaftsdaten



Sojabohnen Klassifikation



	Attribute	Number of values	Sample value
<i>Environment</i>	Time of occurrence	7	July
	Precipitation	3	Above normal
...			
<i>Seed</i>	Condition	2	Normal
	Mold growth	2	Absent
...			
<i>Fruit</i>	Condition of fruit pods	4	Normal
	Fruit spots	5	?
<i>Leaves</i>	Condition	2	Abnormal
	Leaf spot size	3	?
...			
<i>Stem</i>	Condition	2	Abnormal
	Stem lodging	2	Yes
...			
<i>Roots</i>	Condition	3	Normal
<i>Diagnosis</i>		19	Diaporthe stem canker

Bedeutung von Hintergrundwissen

```
If leaf condition is normal
and stem condition is abnormal
and stem cankers is below soil line
and canker lesion color is brown
then
diagnosis is rhizoctonia root rot
```

```
If leaf malformation is absent
and stem condition is abnormal
and stem cankers is below soil line
and canker lesion color is brown
then
diagnosis is rhizoctonia root rot
```

Aber hier, “leaf condition is normal” impliziert
“leaf malformation is absent”!



Echte Anwendungen

- Das Ergebnis des Data Mining
—oder die DM Methode selbst—
wird in praktischen Anwendungen eingesetzt
 - Bearbeiten von Kreditanträgen
 - Durchsuchen von Satellitenbildern nach Ölteppichen
 - Stromverbrauchsvorhersage
 - Diagnose von Maschinenfehlern
 - Marketing und Verkauf
 - Automatische Klassifikation von Himmelsobjekten
 - Automatische Ergänzung von Formularen
 - Text Retrieval und Mining

Kreditanträge (American Express)





- Gegeben: Fragebogen mit finanziellen und persönliche Informationen
- Frage: soll der Antrag bewilligt werden?
- Einfache statist. Methode für 90% der Fälle
- Grenzfälle an Sachbearbeiter weitergereicht
- Aber: 50% der akzeptierten Grenzfälle konnten nicht zurückzahlen!
- Lösung: alle Grenzfälle zurückweisen?
 - Nein! Grenzfälle sind die aktivsten Kunden

Data Mining Einstieg

- 1000 Trainingsbeispiele von Grenzfällen
- 20 Attribute:
 - Alter
 - Jahre beim derzeitigen Arbeitgeber
 - Jahre bei derzeitiger Adresse
 - Jahre bei der Bank
 - andere Kredit Karten besessen ,...
- Gelernte Regeln: korrekt in 70% der Fälle
 - Sachbearbeiter nur 50%
- Regeln konnten genutzt werden, um die Entscheidung dem Kunden zu erklären

Satellitenbilder

- Gegeben: Radar Satellitenbilder von Küstengewässern
- Problem: finde Ölteppiche in den Bildern
- Ölteppiche tauchen als dunkle Region mit sich ändernder Größe und Form auf
- Schwierigkeiten: ähnliche dunkle Regionen können durch Wetterphänomene verursacht werden (z.B. Höhenwinde)
- Teure Bearbeitung erfordert spezialisiertes Personal



Data Mining Einstieg

- Extrahiere dunkle Regionen aus normalisierten Bildern
- Attribute:
 - Größe der Region
 - Form und Fläche
 - Intensität
 - Schärfe und Zerklüftung der Grenzen
 - Nähe zu anderen Regionen
 - Infos über Hintergrund
- Bedingungen:
 - Wenig Trainingsbeispiele—Ölteppiche sind selten!
 - Ungleich verteilte Daten: meisten dunklen Regionen sind keine Ölteppiche
 - Anforderung: einstellbare Rate der Fehlalarme

Stromverbrauchs- vorhersage



- Stromanbieter müssen den Verbrauch vorhersagen und bestellen
- Vorhersage von Min/Max Last für jede Stunde
⇒ signifikante Einsparungen
- Gegeben: manuell konstruiertes Lastmodell mit Annahmen über “normale” klimatische Bedingungen
- Problem: anpassen der Wetterbedingungen
- Statisches Modell besteht aus:
 - Basislast des Jahres
 - periodische Lastveränderungen übers Jahr
 - Effekt der Ferien

Data Mining Einstieg

- Vorhersage korrigiert mittels der “ähnlichsten” Tage
- Attribute:
 - Temperatur
 - Luftfeuchtigkeit
 - Windgeschwindigkeit
 - Wolkenbedeckung
 - plus Unterschied zwischen aktueller Last und vorhergesagter Last
- Durchschnittsunterschied der drei “ähnlichsten” Tage zum Modell hinzugefügt
- Lineare Regressionskoeffizienten bilden Attributgewichte in der Ähnlichkeitsfunktion

Diagnose von Maschinenfehlern

- Diagnose: klassische Domäne von Expertensystemen
- Gegeben: Fourier Analyse von Vibrationen gemessen an verschiedenen Haltepunkten
- Frage: welcher Fehler ist gegeben?
- Preventive Wartung von elektromechanischen Motoren und Generatoren
- Information ist sehr verrauscht
- Bisher: Diagnose durch Expertenregeln



Data Mining Einstieg

- Verfügbar: 600 Fehler mit Expertendiagnose
- ~300 nichtbefriedigend, Rest genutzt zum Trainieren
- Attribute erweitert durch Zwischenkonzepte, die kausales Hintergrundwissen enthalten
- Experte nicht zufrieden mit initialen Regeln, weil sie sich nicht in Beziehung zum Hintergrundwissen setzen ließen
- Weiteres Hintergrundwissen ergab komplexere Regeln, die besser waren
- Gelernte Regeln waren besser als Expertenregeln

Marketing und Verkauf I

- Firmen speichern detaillierte Daten über Verkauf und Marketing
- Anwendungen:
 - Kunden Loyalität:
finde Kunden, die wechseln wollen durch Analyse ihres bisherigen Verhaltens
(e.g. Banken/Telekommunikationsfirmen)
 - Sonderangebote:
finde profitabele Kunden
(z.B. zuverlässige Kreditkartenkunden, die in den Ferien mehr Geld brauchen)

Marketing und Verkauf II

- Warenkorbanalyse
 - Assoziationsmethoden finden Produktgruppen, die oft zusammen gekauft werden (verwendet um Kassendaten zu untersuchen)
- Zeitliche Analyse von Kaufverhalten
- Identifiziere interessierte Kunden
 - Fokussiere Einführungswerbesendungen (Gezielte Aktionen sind billiger als das Gießkannenprinzip)



Data Mining, Maschinelles Lernen und Statistik

- Geschichtliche Unterschiede (stark vereinfacht)
 - Statistik: testen von Hypothesen, kleine Datenmengen
 - Machine learning: finde die richtigen Hypothesen, meist Klassifikation
 - Data Mining: Anwendungsgetrieben, große Datenbanken
- Aber: viele Gemeinsamkeiten
 - Entscheidungsbäume (C4.5 und CART)
 - Nächste Nachbar Methoden
 - Associationsregeln und formale Begriffsanalyse
- Heute: Perspektiven konvergieren
 - Die meisten ML Algorithmen verwenden statistische Techniken
 - Verschiedene „Communities“, verschiedene Begriffe, gemeinsame Probleme

Statistiker

Sir Ronald Aylmer Fisher

* 17 Feb 1890 London, England

+ 29 July 1962 Adelaide, Australia

Numerous distinguished contributions to developing the theory and application of statistics for making quantitative a vast field of biology



- Leo Breiman
- Entwickelte Entscheidungsbäume
- *1984 Classification and Regression Trees. Wadsworth.*

Problemverallgemeinerung als Suche

- Induktives Lernen: finde eine Konzept-Beschreibung, die auf die Daten paßt
- Beispiel: Regeln als Beschreibungssprache
 - Riesiger, aber endlicher Suchraum
- Einfache Lösung:
 - durchsuche den ganzen Konzeptraum
 - verwirfe Beschreibungen, die nicht auf die Beispiele passen
 - übrigbleibende Beschreibungen enthalten das Zielkonzept

Durchsuchen des Konzepttraumes

- Suchraum für das Wetterproblem
 - $4 \times 4 \times 3 \times 3 \times 2 = 288$ mögliche Kombinationen
 - mit 14 Regeln $\Rightarrow 2.7 \times 10^{34}$ mögliche Regelmengen
- Lösung: Kandidaten-Eliminations Algorithmus
- Andere praktische Probleme:
 - Mehr als eine Beschreibung bleibt übrig
 - Keine Beschreibung bleibt übrig
 - Sprache kann Zielkonzept nicht ausdrücken
 - *oder* Daten enthalten Rauschen

Der Versionsraum

- Raum der konsistenten Konzeptbeschreibungen
- Komplet durch zwei Mengen bestimmt
 - L : spezifischste Beschreibungen, die alle pos. und keine neg. Beispiele bestimmen
 - G : allgemeinsten Beschreibungen, die keine neg. und alle pos. Beispiele bestimmen
- Nur L und G müssen aktualisiert werden
- Nachteile
 - immer noch sehr berechnung intensiv
 - löst nicht die anderen prakt. Probleme

Versionsraum Beispiel

- Gegeben: rot oder grün, Kühe oder Hühner

$$L = \{\}$$

$$G = \{ \langle *, * \rangle \}$$

$\langle \text{grün}, \text{Kuh} \rangle$: positiv

$$L = \{ \langle \text{grün}, \text{Kuh} \rangle \}$$

$$G = \{ \langle *, * \rangle \}$$

$\langle \text{rot}, \text{Huhn} \rangle$: negativ

$$L = \{ \langle \text{grün}, \text{Kuh} \rangle \}$$

$$G = \{ \langle \text{grün}, * \rangle, \langle *, \text{Kuh} \rangle \}$$

$\langle \text{grün}, \text{Huhn} \rangle$: positiv

$$L = \{ \langle \text{grün}, * \rangle \}$$

$$G = \{ \langle \text{grün}, * \rangle \}$$

Candidate-elimination algorithm

```
Initialize  $L$  and  $G$ 
```

```
For each example  $e$ :
```

```
  If  $e$  is positive:
```

```
    Delete all elements from  $G$  that do not cover  $e$ 
```

```
    For each element  $r$  in  $L$  that does not cover  $e$ :
```

```
      Replace  $r$  by all of its most specific generalizations  
      that 1. cover  $e$  and
```

```
         2. are more specific than some element in  $G$ 
```

```
    Remove elements from  $L$  that
```

```
      are more general than some other element in  $L$ 
```

```
  If  $e$  is negative:
```

```
    Delete all elements from  $L$  that cover  $e$ 
```

```
    For each element  $r$  in  $G$  that covers  $e$ :
```

```
      Replace  $r$  by all of its most general specializations  
      that 1. do not cover  $e$  and
```

```
         2. are more general than some element in  $L$ 
```

```
    Remove elements from  $G$  that
```

```
      are more specific than some other element in  $G$ 
```

Bias (Befangenheit)

- Wichtige Entscheidungen in Lernsystemen:
 - Konzeptbeschreibungssprache
 - Reihenfolge in der der Suchraum durchmustert wird
 - Methoden um overfitting (auswendiglernen) der Trainingsdaten zu vermeiden
- Diese Entsch. bestimmen den “Bias” der Suche:
 - Sprach Bias
 - Such Bias
 - Overfitting-Vermeidungs Bias

Sprach Bias

- Wichtige Frage:
 - ist die Sprache universal
oder beschränkt sie was gelernt werden kann?
- Universale Sprache kann beliebige Teilmengen der Beispiele beschreiben
- Falls Sprache logisches *oder* (“Disjunktion”) enthält, ist sie universal
- Beispiel: Regelmengen
- Hintergrundwissen kann genutzt werden, um Teile des Suchraums von vornherein auszuschließen

Such Bias

- Suchheuristik
 - “Greedy” Suche: macht immer den aktuell bestmöglichen Schritt
 - “Beam search”: hält immer ein paar Alternativen vor
 - ...
- Richtung der Suche
 - *Allgemein-hinzu-Spezifisch*
 - z.B. spezialisieren einer Regel durch Hinzufügen von Bedingungen
 - *Spezifisch-hinzu-Allgemein*
 - z.B. Verallgemeinern eines Beispiels zu einer Regel

Overfitting-Vermeidungs Bias

- Kann als Art Such Bias verstanden werden
- Verändertes Evaluationskriterium
 - z.B. balanciert Einfachheit und Anzahl der Fehler
- Veränderte Suchstrategie
 - z.B. pruning (Vereinfachen einer Beschreibung)
 - Pre-pruning: hält bei einer einfachen Beschreibung an, bevor die Suche mit einer komplexen B. fortgesetzt wird
 - Post-pruning: erzeugt zuerst komplexe Beschreibungen, die dann vereinfacht werden

Data mining und Ethik I



- Ethische Fragestellungen tauchen in praktischen Anwendungen auf
- Data mining oft benutzt zum Unterscheiden
 - z.B. Kreditanträge: Verwendung von Informationen (z.B. Geschlecht, Religion, Herkunft) ist unethisch
- Ethische Situation hängt von der Anwendung ab
 - z.B. dieselbe Information ist ok in medizinischen Anwendungen
- Attribute können problematische Informationen enthalten
 - z.B. Postleitzahl kann mit Herkunft korrelieren

Data mining und Ethik II

- Wichtige Fragen:
 - Wer hat Zugang zu den Daten?
 - Für welchen Zweck werden die Daten gesammelt?
 - Welche Schlußfolgerung dürfen daraus gezogen werden?
- Ergebnisse müssen Vorteile enthalten, für wen?
- Rein statistische Argumente sind niemals ausreichend!
- Werden die Ergebnisse sinnvoll und gut verwendet?