Überblick

Klassifikationsproblem

Gegeben:

- eine Menge $O \subseteq D$ von Objekten $o = (o_1, \ldots, o_d) \in O$ mit *Attributen* A_i, $1 \leq i \leq d$
- eine Menge von Klassen $C = \{c_1, \ldots, c_k\}$
- Klassenzuordnung $T : O \rightarrow C$

Gesucht:

- die Klassenzugehörigkeit für Objekte aus $D \setminus O$
- ein *Klassifikator* $K : D \rightarrow C$

Abgrenzung zum Clustering

- Klassifikation: Klassen a priori bekannt
- Clustering: Klassen werden erst gesucht

Verwandtes Problem: *Regression*

- gesucht ist der Wert für ein numerisches Attribut

Beispiel

ID	Alter	Autotyp	Risiko
1	23	Familie	hoch
2	17	Sport	hoch
3	43	Sport	hoch
4	68	Familie	niedrig
5	32	LKW	niedrig

Einfacher Klassifikator

```
if Alter > 50 then Risikoklasse = Niedrig;
if Alter ≤ 50 and Autotyp=LKW then
Risikoklasse=Niedrig;
if Alter ≤ 50 and Autotyp ≠ LKW
                then Risikoklasse = Hoch.
```

Klassifikations-Prozess

Konstruktion des Modells

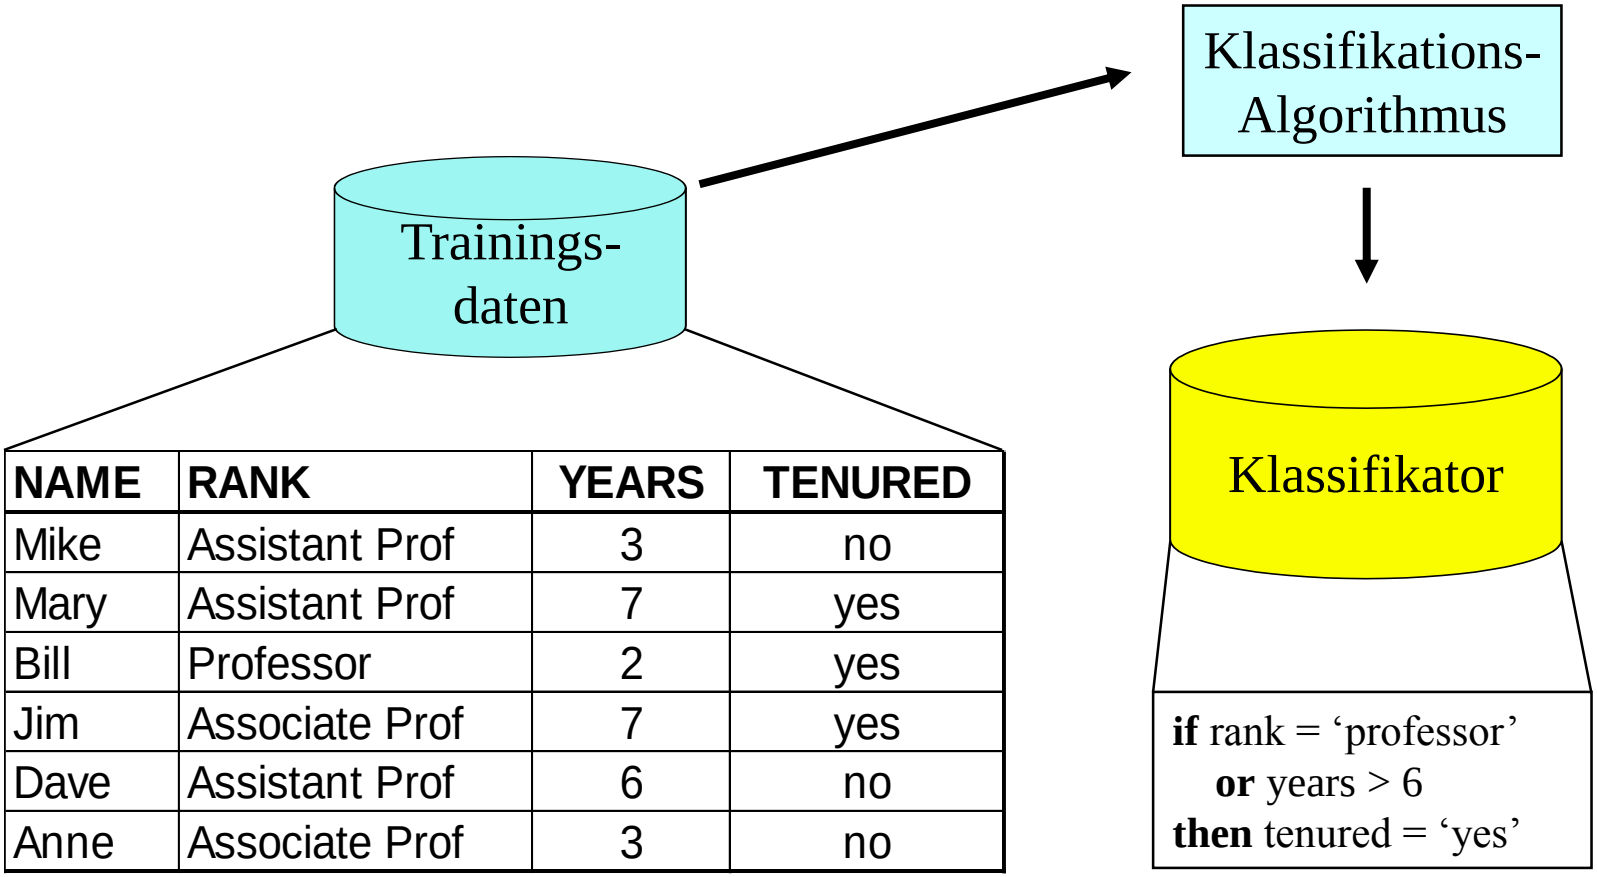

NAME	RANK	YEARS	TENURED
Mike	Assistant Prof	3	no
Mary	Assistant Prof	7	yes
Bill	Professor	2	yes
Jim	Associate Prof	7	yes
Dave	Assistant Prof	6	no
Anne	Associate Prof	3	no

Klassifikations-Prozess

Anwendung des Modells

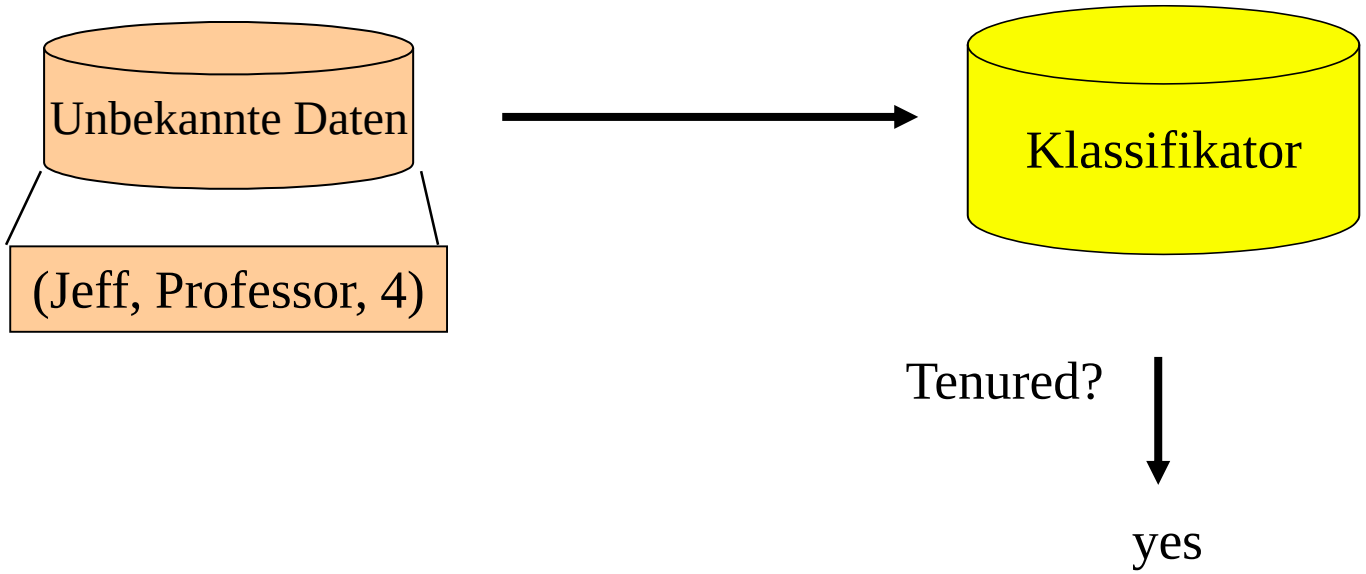

manchmal: keine Klassifikation unbekannter Daten
sondern „nur“ besseres Verständnis der Daten

Bewertung von Klassifikatoren

Grundbegriffe

- Sei K ein Klassifikator und sei $TR \subseteq O$ die Trainingsmenge. $O \subseteq D$ ist die Menge der Objekte, bei denen die Klassenzugehörigkeit bereits bekannt ist .

- **Problem der Bewertung:**
  - gewünscht ist gute Performanz auf ganz D.
  - Klassifikator ist für TR optimiert.
  - Test auf TR erzeugt in der Regel viel bessere Ergebnisse, als auf $D \backslash TR$.

    Daher kein realistisches Bild der Performanz auf D.

    $\Rightarrow$ *Overfitting*

Bewertung von Klassifikatoren

- Abschätzung der Vorhersagequalität auf unbekannten Daten: k-fache Kreuzvalidierung (k-fold cross-validation)
  - Teile Trainingsmenge $TR \subseteq O$ in k Partitionen $TR_1,\ldots,TR_k$ ein.
  - für $i = 1\ldots k$:
    - trainiere einen Klassifikator K_i auf $TR \backslash TR_i$
    - teste K_i auf TR_i
  - Mittle die k beobachteten Fehlerraten

Bewertung von Klassifikatoren

Ablauf 3-fache Überkreuzvalidierung (3-fold Cross Validation)

Sei n = 3 : Menge aller Daten mit Klasseninformation die zur Verfügung stehen

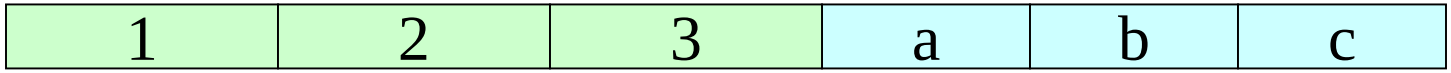

1 fold:

Trainingsmenge

Testmenge

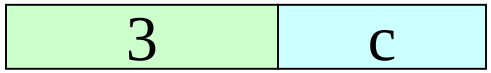

Klassifikator

Klassifikations-ergebnisse

2 fold:

Trainingsmenge

Testmenge

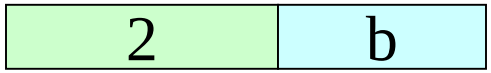

Klassifikator

Klassifikations-ergebnisse

3 fold:

Trainingsmenge

Testmenge

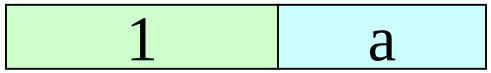

Klassifikator

Klassifikations-ergebnisse

gesamtes Klassifikations-ergebnis

Bewertung von Klassifikatoren

Ergebnis des Tests : Konfusionsmatrix (confusion matrix)

klassifiziert als ...

tatsächliche Klasse ...	Klasse1	Klasse 2	Klasse 3	Klasse 4	other
Klasse 1	35	1	1	1	4
Klasse 2	0	31	1	1	5
Klasse 3	3	1	50	1	2
Klasse 4	1	0	1	10	2
other	3	1	9	15	13

korrekt klassifizierte Objekte

Aus der Konfusionsmatrix lassen sich diverse Kennzahlen berechnen, z.B. Accuracy, Classification Error, Precision und Recall.

Bewertung von Klassifikatoren

• *Gütemaße für Klassifikatoren*

• Sei K ein Klassifikator, $TR \subseteq O$ die Trainingsmenge, $TE \subseteq O$ die Testmenge. Bezeichne $T(o)$ die tatsächliche Klasse eines Objekts o.

- *Klassifikationsgenauigkeit* (classification accuracy) von K auf TE:

$$G_{TE}(K) = \frac{|\{o \in TE : K(o) = T(o)\}|}{|TE|}$$

- *Tatsächlicher Klassifikationsfehler* (true classification error)

$$F_{TE}(K) = \frac{|\{o \in TE : K(o) \neq T(o)\}|}{|TE|}$$

- *Beobachteter Klassifikationsfehler* (apparent classification error)

$$F_{TR}(K) = \frac{|\{o \in TR : K(o) \neq T(o)\}|}{|TR|}$$

Bewertung von Klassifikatoren

Recall:

Anteil der Testobjekte einer Klasse *i*, die richtig erkannt wurden.

Sei $C_i = \{o \in TE : T(o) = i\}$, dann ist

$$\text{Recall}_{TE}(K, i) = \frac{|\{o \in C_i : K(o) = T(o)\}|}{|C_i|}$$

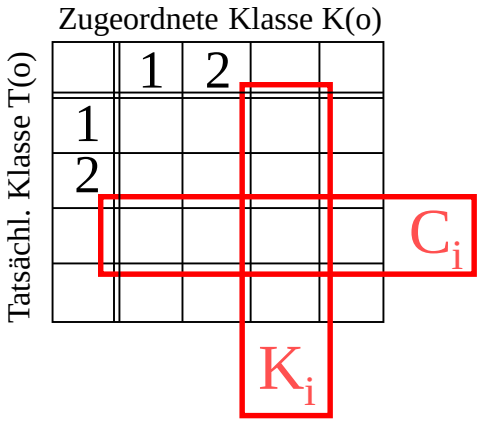

Precision:

Anteil der zu einer Klasse i zugeordneten Testobjekte, die richtig erkannt wurden.

Sei $K_i = \{o \in TE : K(o) = i\}$, dann ist

$$\text{Precision}_{TE}(K, i) = \frac{|\{o \in K_i : K(o) = T(o)\}|}{|K_i|}$$

Nächste-Nachbarn-Klassifikatoren

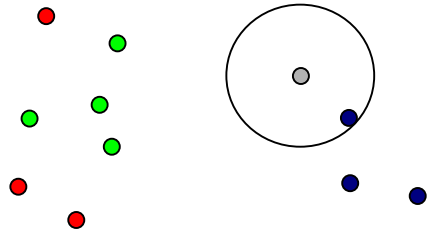

- Schrauben
- Nägel
- Klammern

} Trainings-daten

- Neues Objekt => Schraube

- Instanzbasiertes Lernen (*instance based learning*)
- Einfachster Nächste-Nachbar-Klassifikator: Zuordnung zu der Klasse des nächsten Nachbarpunkts
- Im Beispiel: Nächster Nachbar ist eine Schraube

Nächste-Nachbarn-Klassifikatoren

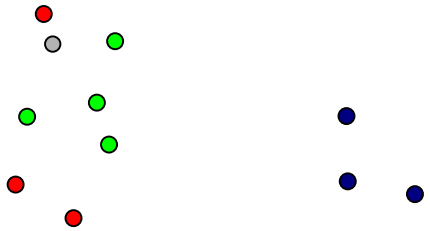

- Problem: Punkt links oben wahrscheinlich nur Ausreißer
  => neues Objekt vermutlich grün statt rot
- Besser: Betrachte mehr als nur einen Nachbarn
  → *k*-Nächste-Nachbarn-Klassifikator
- *Entscheidungsmenge*
  die Menge der zur Klassifikation betrachteten *k*-nächsten Nachbarn
- *Entscheidungsregel*
  wie bestimmt man aus den Klassen der Entscheidungsmenge die Klasse des zu klassifizierenden Objekts?
  - Interpretiere Häufigkeit einer Klasse in der Entscheidungsmenge als Wahrscheinlichkeit der Klassenzugehörigkeit
  - Maximum-Likelihood-Prinzip: Mehrheitsentscheidung
  - Ggf. Gewichtung

Nächste-Nachbarn-Klassifikatoren

Wahl des Parameters k

- „zu kleines“ *k*: hohe Sensitivität gegenüber Ausreißern
- „zu großes“ *k*: viele Objekte aus anderen Clustern (Klassen) in der Entscheidungsmenge.
- mittleres *k*: höchste Klassifikationsgüte, oft $1 << k < 10$

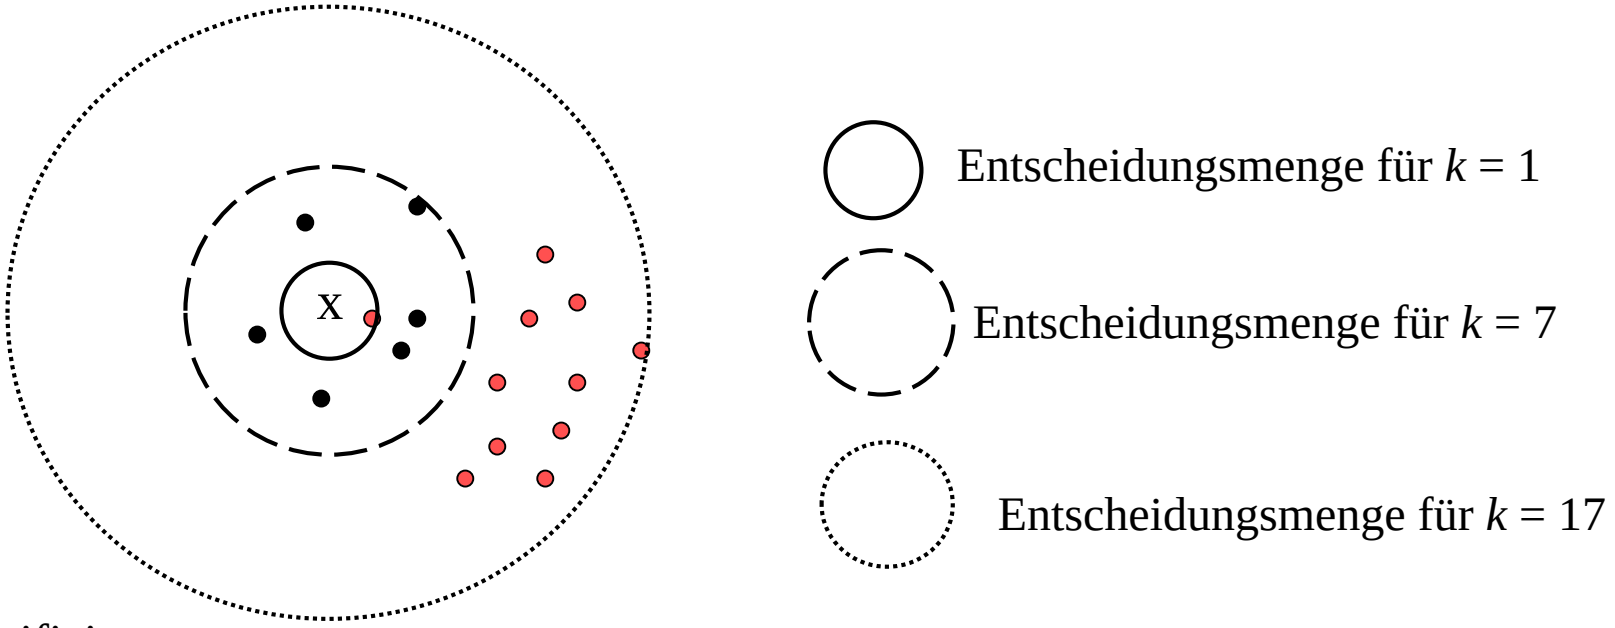

x: zu klassifizieren

Nächste-Nachbarn-Klassifikatoren

Entscheidungsregel

- Standardregel
  - wähle die Mehrheitsklasse der Entscheidungsmenge
- Gewichtete Entscheidungsregel

  gewichte die Klassen der Entscheidungsmenge
  - nach Distanz, meist invers quadriert: $weight(dist) = 1/dist^2$
  - nach Verteilung der Klassen (oft sehr ungleich!)

    Problem: Klasse mit zu wenig Instanzen ($< k/2$) in der Trainingsmenge bekommt keine Chance, ausgewählt zu werden, selbst bei optimaler Distanzfunktion
    - Klasse A: 95 %, Klasse B 5 %
    - Entscheidungsmenge = {A, A, A, A, B, B, B}
    - Standardregel $\Rightarrow$ A, gewichtete Regel $\Rightarrow$ B

Ausblick

Data Mining und andere Wissenschaften

- Data Mining lebt von der Anwendung und muss für viele Anwendungsszenarien und Probleme zugeschnitten werden.

- Data Mining kann im Anwendungsgebiet (z.B. einer anderen Wissenschaft – Geographie, BWL, Kunst, Sprachwissenschaft, Physik, Biologie,…) zu neuen Erkenntnissen führen.

- Umgekehrt bietet ein konkretes Anwendungsszenario oft interessante Herausforderungen für die Forschung im Bereich Data Mining.