

# Einführung in die Methoden der Künstlichen Intelligenz

## Maschinelles Lernen

PD Dr. David Sabel

SoSe 2014

# Einführung

- Direkte Programmierung eines **intelligenten Agenten** nicht möglich (bisher)
- Daher benötigt: **Maschinelles Lernen**
- Viele Ansichten / Begriffe, was maschinelles Lernen ist
- Erfolgreichste Ansätze verwenden statistische / stochastische Methoden
- Basieren auf Adaption von Werten / Gewichten

# Lernen und Agenten

Lernen soll Performanz des Agenten verbessern:

- Verbesserung der internen Repräsentation
- Optimierung bzw. Beschleunigung der Erledigung von Aufgaben.
- Erweiterung des Spektrums oder der Qualität der Aufgaben, die erledigt werden können.

# Beispiele

- Anpassung / Erweiterung des Lexikons eines computerlinguistischen Systems  
Inhalt wird angepasst, aber auch gleichzeitig die Semantik
- Bewertungsfunktion im Zweipersonenspiel (Adaption der Gewichte), war für Dame und Backgammon erfolgreich
- Lernen einer Klassifikation durch Trainingsbeispiele

# Struktur eines lernenden Systems

- **Agent:** (ausführende Einheit, performance element). Soll verbessert werden anhand von Erfahrung
- **Lerneinheit: (learning element)** Steuerung des Lernvorgangs. Vorgaben was schlecht ist. Bewertungseinheit (critic) und Problemgenerator
- **Umwelt:** Umwelt in der agiert wird (künstlich oder real)

# Lernmethoden

- **Überwachtes Lernen (supervised learning)**
  - Es gibt einen „allwissenden Lehrer“
  - Er sagt dem Agent, nach seiner Aktion, ob diese richtig / falsch wahr
  - unmittelbares Feedback
  - Alternative: Gebe positiv/negative Beispiele am Anfang vor

# Lernmethoden

- **Überwachtes Lernen (supervised learning)**
  - Es gibt einen „allwissenden Lehrer“
  - Er sagt dem Agent, nach seiner Aktion, ob diese richtig / falsch wahr
  - unmittelbares Feedback
  - Alternative: Gebe positiv/negative Beispiele am Anfang vor
- **Unüberwachtes Lernen (unsupervised learning)**
  - Agent, weiß nicht, was richtig ist
  - Bewertung der Güte der Aktion
  - z.B. Agent misst den Effekt selbst

# Lernmethoden

- **Überwachtes Lernen (supervised learning)**
  - Es gibt einen „allwissenden Lehrer“
  - Er sagt dem Agent, nach seiner Aktion, ob diese richtig / falsch wahr
  - unmittelbares Feedback
  - Alternative: Gebe positiv/negative Beispiele am Anfang vor
- **Unüberwachtes Lernen (unsupervised learning)**
  - Agent, weiß nicht, was richtig ist
  - Bewertung der Güte der Aktion
  - z.B. Agent misst den Effekt selbst
- **Lernen durch Belohnung/Bestrafung (reinforcement learning)**
  - Lernverfahren belohnen gute Aktion, bestrafen schlechte
  - D.h. Aktion ist bewertbar, aber man kennt den richtigen Parameter nicht



# Lernmethoden (2)

Mögliche Vorgehensweisen:

- inkrementell,
- alle Beispiele auf einmal.

Mögliche Rahmenbedingungen:

- Beispielwerte: exakt / ungefähr (fehlerhaft)
- nur positive bzw. positive und negative Beispiele

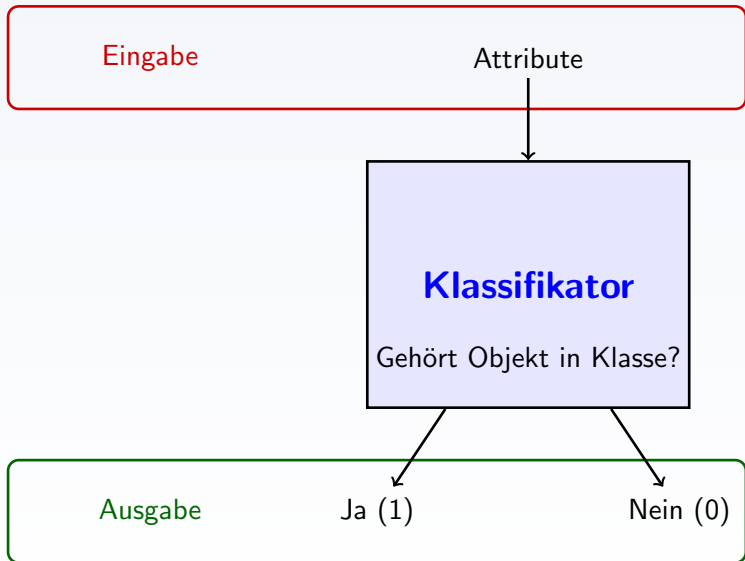
# Klassifikationsverfahren

## **Klassifikation** anhand von Eigenschaften (Attributen)

Beispiele:

- **Vogel**: kann-fliegen, hat-Federn, Farbe,...
- **Vorhersage, ob ein Auto im kommenden Jahr einen Defekt hat**: Alter, Kilometerstand, letzte Reparatur, Marke, ...
- **Medizinischer Test auf Krankheit**: Symptome, Blutwerte, ...
- **Kreditwürdigkeit e. Bankkunden**: Einkommen, Alter, Eigentumsverhältnisse, Adresse

# Klassifikator



# Abstrakte Situation

- Menge  $M$  von Objekten (mit innerer Struktur)
- Programm  $P : M \rightarrow \{0, 1\}$
- Wahre Klassifikation  $K : M \rightarrow \{0, 1\}$

# Abstrakte Situation

- Menge  $M$  von Objekten (mit innerer Struktur)
- Programm  $P : M \rightarrow \{0, 1\}$
- Wahre Klassifikation  $K : M \rightarrow \{0, 1\}$

Eingabe: Objekt  $x$

- Wenn  $K(x) = P(x)$ , dann liegt das Programm richtig
  - **richtig-positiv**: Wenn  $P(x) = 1$  und  $K(x) = 1$
  - **richtig-negativ**: Wenn  $P(x) = 0$  und  $K(x) = 0$
- Wenn  $K(x) \neq P(x)$ , dann liegt das Programm falsch:
  - **falsch-positiv**: Wenn  $P(x) = 1$ , aber  $K(x) = 0$
  - **falsch-negativ**: Wenn  $P(x) = 0$ , aber  $K(x) = 1$

# Beispiel: Schwangerschaftstest

Beispieldaten: 200 durchgeführte Tests

Test ergab ...	positiv	negativ
Schwangere Frauen	59	1
Nichtschwangere Frauen	15	125

# Beispiel: Schwangerschaftstest

Beispieldaten: 200 durchgeführte Tests

Test ergab ...	positiv	negativ
Schwangere Frauen	59	1
Nichtschwangere Frauen	15	125

- Richtig positiv: Frau schwanger, Test sagt schwanger

# Beispiel: Schwangerschaftstest

Beispieldaten: 200 durchgeführte Tests

Test ergab ...	positiv	negativ
Schwangere Frauen	59	1
Nichtschwangere Frauen	15	125

- Richtig positiv: Frau schwanger, Test sagt schwanger
- Falsch negativ: Frau schwanger, Test sagt nicht schwanger



# Beispiel: Schwangerschaftstest

Beispieldaten: 200 durchgeführte Tests

Test ergab ...	positiv	negativ
Schwangere Frauen	59	1
Nichtschwangere Frauen	15	125

- Richtig positiv: Frau schwanger, Test sagt schwanger
- Falsch negativ: Frau schwanger, Test sagt nicht schwanger
- Falsch positiv: Frau nicht schwanger, Test sagt schwanger

# Beispiel: Schwangerschaftstest

Beispieldaten: 200 durchgeführte Tests

Test ergab ...	positiv	negativ
Schwangere Frauen	59	1
Nichtschwangere Frauen	15	125

- Richtig positiv: Frau schwanger, Test sagt schwanger
- Falsch negativ: Frau schwanger, Test sagt nicht schwanger
- Falsch positiv: Frau nicht schwanger, Test sagt schwanger
- **Richtig negativ: Frau nicht schwanger, Test sagt nicht schwanger**

# Beispiel: Schwangerschaftstest

Beispieldaten: 200 durchgeführte Tests

Test ergab ...	positiv	negativ
Schwangere Frauen	59	1
Nichtschwangere Frauen	15	125

- Richtig positiv: Frau schwanger, Test sagt schwanger
- Falsch negativ: Frau schwanger, Test sagt nicht schwanger
- Falsch positiv: Frau nicht schwanger, Test sagt schwanger
- Richtig negativ: Frau nicht schwanger, Test sagt nicht schwanger

Wie gut ist der Test?

$M$  Gesamtmenge aller zu untersuchenden Objekte:

**Recall** (Richtig-Positiv-Rate, hit rate)

$$\frac{|\{x \in M \mid P(x) = 1 \wedge K(x) = 1\}|}{|\{x \in M \mid K(x) = 1\}|}$$

D.h. Anteil **richtig** klassifizierter, **positiver** Objekte

# Maßzahlen

$M$  Gesamtmenge aller zu untersuchenden Objekte:

**Recall** (Richtig-Positiv-Rate, hit rate)

$$\frac{|\{x \in M \mid P(x) = 1 \wedge K(x) = 1\}|}{|\{x \in M \mid K(x) = 1\}|}$$

D.h. Anteil **richtig** klassifizierter, **positiver** Objekte

Beispiel (60 Schwangere, 59 mal positiv)

$$\frac{59}{60} \approx 98,3\%$$

# Maßzahlen (2)

## Richtig-Negativ-Rate, correct rejection rate

$$\frac{|\{x \in M \mid P(x) = 0 \wedge K(x) = 0\}|}{|\{x \in M \mid K(x) = 0\}|}$$

D.h. Anteil **richtig** klassifizierter, **negativer** Objekte

# Maßzahlen (2)

## Richtig-Negativ-Rate, correct rejection rate

$$\frac{|\{x \in M \mid P(x) = 0 \wedge K(x) = 0\}|}{|\{x \in M \mid K(x) = 0\}|}$$

D.h. Anteil **richtig** klassifizierter, **negativer** Objekte

Beispiel (140 Nicht-Schwangere, 125 mal negativ)

$$\frac{125}{140} \approx 89,3\%$$

# Maßzahlen (3)

**Precision** (Präzision, positiver Vorhersagewert)

$$\frac{|\{x \in M \mid P(x) = 1 \wedge K(x) = 1\}|}{|\{x \in M \mid P(x) = 1\}|}$$

D.h. Anteil der **richtigen** unten den als **scheinbar richtig** erkannten



# Maßzahlen (3)

**Precision** (Präzision, positiver Vorhersagewert)

$$\frac{|\{x \in M \mid P(x) = 1 \wedge K(x) = 1\}|}{|\{x \in M \mid P(x) = 1\}|}$$

D.h. Anteil der **richtigen** unten den als **scheinbar richtig** erkannten

Beispiel (59 Schwangere richtig erkannt, Test positiv: 59 + 15 = 74)

$$\frac{59}{74} \approx 79,8\%$$

# Maßzahlen (4)

## Negative-Vorhersage Rate

$$\frac{|\{x \in M \mid P(x) = 0 \wedge K(x) = 0\}|}{|\{x \in M \mid P(x) = 0\}|}$$

D.h. Anteil der **richtig als falsch** klassifizierten unter **allen als falsch** klassifizierten

# Maßzahlen (4)

## Negative-Vorhersage Rate

$$\frac{|\{x \in M \mid P(x) = 0 \wedge K(x) = 0\}|}{|\{x \in M \mid P(x) = 0\}|}$$

D.h. Anteil der **richtig als falsch** klassifizierten unter **allen als falsch** klassifizierten

Beispiel (125 Nicht-Schwangere richtig erkannt, Test negativ: 125 + 1 = 126)

$$\frac{125}{126} \approx 99,2\%$$

# Maßzahlen (5)

***F*-Maß**: Harmonisches Mittel aus Precision und Recall:

$$F = 2 \cdot \frac{(\text{precision} \cdot \text{recall})}{(\text{precision} + \text{recall})}$$

# Maßzahlen (5)

**F-Maß:** Harmonisches Mittel aus Precision und Recall:

$$F = 2 \cdot \frac{(\text{precision} \cdot \text{recall})}{(\text{precision} + \text{recall})}$$

Beispiel (Precision = 79,8 % und Recall = 98,3 %)

$$F = 2 \cdot \frac{0,798 \cdot 0,983}{0,798 + 0,983} \approx 2 \cdot \frac{0,784}{1,781} \approx 0,88$$

# Weitere Beispiele

Bei seltenen Krankheiten möglich:

- Guter Recall (Anteil der Kranken, die erkannt wurden),
- aber schlechte Präzision (viele false-positives)

Bsp: Klassifikator: Körpertemperatur über 38,5 C  $\implies$  Gelbfieber.

- In Deutschland haben 10.000 Menschen Fieber mit 38,5 C  
aber nur 1 Mensch davon hat Gelbfieber
- Recall =  $\frac{1}{1} = 1$
- Precision =  $\frac{1}{10.000} = 0,0001$
- $F$ -Wert  $\approx 0$

Fazit: Man muss immer beide Maße betrachten!

# Weiteres Vorgehen

Ziel: Finde effizientes Klassifikatorprogramm

Vorher: Kurzer Exkurs zu Wahrscheinlichkeiten und zur Entropie

# Exkurs: Wahrscheinlichkeiten, Entropie

Sei  $X$  ein Orakel ( $n$ -wertige Zufallsvariable)

- $X$  liefert Wert  $a_i$  aus  $\{a_1, \dots, a_n\}$
- $p_i =$  Wahrscheinlichkeit, dass  $X$  den Wert  $a_i$  liefert
- Folge von Orakelausgaben:  $b_1, \dots, b_m$   
Je länger die Folge: Anteil der  $a_i$  in der Folge nähert sich  $p_i$
- $\{p_1, \dots, p_n\}$  nennt man auch  
**diskrete Wahrscheinlichkeitsverteilung**  
der Menge  $\{a_1, \dots, a_n\}$  bzw. des Orakels  $X$
- Es gilt stets  $\sum_i p_i = 1$
- Sind  $a_i$  Zahlen, dann ist der  
**Erwartungswert**  $E(X) = \sum_i p_i \cdot a_i$



# Exkurs: Wahrscheinlichkeiten, Entropie (2)

## Urnenmodell:

$X$  benutzt einen Eimer mit Kugeln beschriftet mit  $a_1, \dots, a_n$  und zieht bei jeder Anfrage zufällig eine Kugel (und legt sie zurück)

Dann gilt:

$$\begin{aligned} p_i &= \text{relative Häufigkeit von } a_i\text{-Kugeln in der Urne} \\ &= \frac{\text{\textit{a}_i\text{-Kugeln in der Urne}}}{\text{Anzahl alle Kugeln in der Urne}} \end{aligned}$$

# Exkurs: Wahrscheinlichkeiten, Entropie (3)

Gegeben: Wahrscheinlichkeitsverteilung  $p_i, i = 1, \dots, n$

## Informationsgehalt des Zeichens $a_k$

$$I(a_k) = \log_2\left(\frac{1}{p_k}\right) = -\log_2(p_k) \geq 0$$

Interpretation:

- „Grad der Überraschung beim Ziehen des Symbols  $a_i$ “, oder auch:
- „Wie oft muss man das Orakel im Mittel fragen, um  $a_i$  zu erhalten“

D.h.

- Selten auftretenden Zeichen: haben hohe Überraschung
- Bei nur einem Zeichen:  $p_1 = 1, I(p_1) = 0$

# Exkurs: Wahrscheinlichkeiten, Entropie (4)

## Entropie (Mittlerer Informationsgehalt)

$$I(X) = \sum_{i=1}^n p_i * I(a_i) = \sum_{i=1}^n p_i * \log_2\left(\frac{1}{p_i}\right) = - \sum_{i=1}^n p_i * \log_2(p_i) \geq 0$$

entspricht in etwa, der „mittleren Überraschung“

# Beispiele

8 Objekte mit gleicher Wahrscheinlichkeit ( $p_i = \frac{1}{8}$ )

- Informationsgehalt jedes  $a_i$ :  $\log_2\left(\frac{1}{\frac{1}{8}}\right) = \log_2 8 = 3$

- Entropie  $\sum_{i=1}^8 p_i * 3 = \sum_{i=1}^8 \frac{1}{8} * 3 = 3$

# Beispiele

8 Objekte mit gleicher Wahrscheinlichkeit ( $p_i = \frac{1}{8}$ )

- Informationsgehalt jedes  $a_i$ :  $\log_2\left(\frac{1}{8}\right) = \log_2 8 = 3$

- Entropie  $\sum_{i=1}^8 p_i * 3 = \sum_{i=1}^8 \frac{1}{8} * 3 = 3$

1000 Objekte mit gleicher Wahrscheinlichkeit ( $p_i = \frac{1}{1000}$ )

- Informationsgehalt jedes  $a_i$ :  $-\log_2(1/1000) = 9.966$
- Entropie = 9.966

# Beispiele

8 Objekte mit gleicher Wahrscheinlichkeit ( $p_i = \frac{1}{8}$ )

- Informationsgehalt jedes  $a_i$ :  $\log_2\left(\frac{1}{8}\right) = \log_2 8 = 3$

- Entropie  $\sum_{i=1}^8 p_i * 3 = \sum_{i=1}^8 \frac{1}{8} * 3 = 3$

1000 Objekte mit gleicher Wahrscheinlichkeit ( $p_i = \frac{1}{1000}$ )


- Informationsgehalt jedes  $a_i$ :  $-\log_2(1/1000) = 9.966$
- Entropie = 9.966

8 Objekte:  $p_1 = 0.4994, p_2 = 0.4994, p_i = 0.001$  für  $i = 3, \dots, 8$

- Informationsgehalt  $a_1, a_2$ :  $-\log_2(0.4994) \approx 1.002$   
 $a_i$ :  $-\log_2(0.001) \approx 9.966$
- Entropie:  $2 * 0.4994 * 1.002 + 6 * 0.001 * 9.966 \approx 1.061$

# Beispiele

Bernoulli-Experiment:  $p_{Kopf}$  und  $p_{Zahl} = 1 - p_{Kopf}$



# Entscheidungsbaumlernen



# Lernen von Entscheidungsbäumen (1)

## Objekt mit Attributen

- Es gibt eine endliche Menge  $A$  von Attributen.
- zu jedem Attribut  $a \in A$ : Menge von möglichen Werten  $W_a$ . Wertebereich endlich, oder  $\mathbb{R}$ .
- Ein **Objekt** wird beschrieben durch eine Funktion  $A \rightarrow \prod_{a \in A} W_a$ .  
Alternativ: Tupel mit  $|A|$  Einträgen
- Ein **Konzept**  $K$  ist repräsentiert durch ein Prädikat  $P_K$  auf der Menge der Objekte.  $P_K \subseteq$  Alle Objekte

Beispiel:

- Alle Objekte: Bücher
- Attribute: (Autor, Titel, Seitenzahl, Preis, Erscheinungsjahr).
- Konzepte „billiges Buch“ (Preis  $\leq 10$ ); „umfangreiches Buch“ (Seitenzahl  $\geq 500$ ), „altes Buch“ (Erscheinungsjahr  $< 1950$ )

# Entscheidungsbaum

**Entscheidungsbaum** zu einem Konzept  $K$ :

- endlicher Baum
- innere Knoten: Abfragen eines Attributwerts
  - Bei reellwertigen Attributen  $a \leq v$  für  $v \in \mathbb{R}$ . 2 Kinder: Für Ja und Nein
  - Bei diskreten Attributen  $a$  mit Werten  $w_1, \dots, w_n$ :  $n$  Kinder: Für jeden Wert eines
- Blätter: Markiert mit „Ja“ oder „Nein“ (manchmal auch mit „Ja oder Nein“)
- Pro Pfad: Jedes Attribut (außer rellwertige) nur einmal

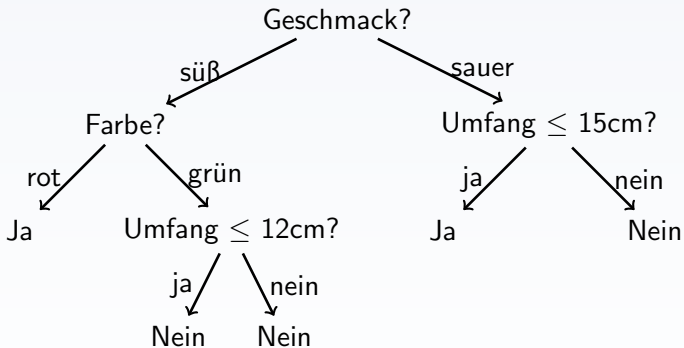
Der Entscheidungsbaum gibt gerade an, ob ein Objekt zum Konzept gehört.

# Beispiel

Objekte: Äpfel mit Attributen:

Geschmack (süß/sauer), Farbe (rot/grün), Umfang (in cm)

Konzept: „guter Apfel“




Ist der Baum „optimal“?

# Beispiel

Objekte: Äpfel mit Attributen:

Geschmack (süß/sauer), Farbe (rot/grün), Umfang (in cm)

Konzept: „guter Apfel“



Ist der Baum „optimal“? **Nein**

# Entscheidungsbäume (2)

Wofür werden sie benutzt?

→ als Klassifikator für Konzepte

Woher kommt der Baum?

→ Durch **Lernen** einer Trainingsmenge

Was ist zu beachten?

→ Der Baum sollte möglichst **kurze Pfade** haben

→ Trainingsmenge **muss** positive **und** negative Beispiele beinhalten

# Gute Entscheidungsäume

Ein **guter Entscheidungsbaum** ist ein möglichst kleiner, d.h. der eine **möglichst kleine mittlere Anzahl** von Anfragen bis zur Entscheidung benötigt.

Wir betrachten: Algorithmen zur Konstruktion von guten Entscheidungsäumen

Ansatz: Verwende die Entropie  
(verwandt zur Konstruktion von Huffman-Bäumen)

# Vorgehen: Auswahl des nächsten Attributs

Menge  $M$  von Objekten mit Attributen geteilt in **positive** und **negative** Beispiele. Annahme: Objekte sind gleichverteilt und spiegeln die Wirklichkeit wider.

Sei

- $p$  = Anzahl positiver Beispiele in  $M$
- $n$  = Anzahl negativer Beispiele in  $M$

Entropie der Menge  $M$ :

$$I(M) = \frac{p}{p+n} * \log_2\left(\frac{p+n}{p}\right) + \frac{n}{p+n} * \log_2\left(\frac{p+n}{n}\right)$$

## Vorgehen: Auswahl des nächsten Attributs (2)

Wie verändert sie die Entropie nach Wahl von Attribut  $a$ ?

- Sei  $m(a)$  der Wert des Attributs  $a$  des Objekts  $m \in M$ .
- Sei  $a$  ein Attribut mit Werten  $w_1, \dots, w_k$
- Dann zerlegt das Attribut  $a$  die Menge  $M$  in Mengen

$$M_i := \{m \in M \mid m(a) = w_i\}$$

- Seien  $p_i, n_i$  die Anzahl positiver/negativer Beispiele in  $M_i$ .
- Gewichtete Mittelwert des entstandenen Informationsgehalt nach Auswahl des Attributs  $a$

$$I(M|a) = \sum_{i=1}^k P(a = w_i) * I(M_i)$$



# Vorgehen: Auswahl des nächsten Attributs (2)

Wie verändert sie die Entropie nach Wahl von Attribut  $a$ ?

- Sei  $m(a)$  der Wert des Attributs  $a$  des Objekts  $m \in M$ .
- Sei  $a$  ein Attribut mit Werten  $w_1, \dots, w_k$
- Dann zerlegt das Attribut  $a$  die Menge  $M$  in Mengen

$$M_i := \{m \in M \mid m(a) = w_i\}$$

- Seien  $p_i, n_i$  die Anzahl positiver/negativer Beispiele in  $M_i$ .
- Gewichtete Mittelwert des entstandenen Informationsgehalt nach Auswahl des Attributs  $a$

$$I(M|a) = \sum_{i=1}^k \underbrace{P(a = w_i)}_{\frac{p_i + n_i}{p+n}} * \underbrace{I(M_i)}_{\frac{p_i}{p_i + n_i} * \log_2\left(\frac{p_i + n_i}{p_i}\right) + \frac{n_i}{p_i + n_i} * \log_2\left(\frac{p_i + n_i}{n_i}\right)}$$

# Vorgehen: Auswahl des nächsten Attributs (3)

$$I(M|a) = \sum_{i=1}^k \frac{p_i + n_i}{p + n} * \left( \frac{p_i}{p_i + n_i} * \log_2 \left( \frac{p_i + n_i}{p_i} \right) + \frac{n_i}{p_i + n_i} * \log_2 \left( \frac{p_i + n_i}{n_i} \right) \right)$$

Wähle das Attribut  $a$  mit bestem **Informationsgewinn**:

$$I(M) - I(M|a)$$

Zur Wohldefiniertheit, setzen wir:  $\frac{0}{a} * \log_2 \left( \frac{a}{0} \right) := 0$

# Das Verfahren ID3 (Iterative Dichotomiser 3)

## Algorithmus ID3-Verfahren

**Eingabe:** Menge  $M$  von Objekten mit Attributen

**Algorithmus:**

Erzeuge Wurzel als **offenen Knoten** mit Menge  $M$

**while** es gibt offene Knoten **do**

    wähle offenen Knoten  $K$  mit Menge  $M$

**if**  $M$  enthält nur positive Beispiele **then**

            schließe  $K$  mit Markierung „Ja“

**else-if**  $M$  enthält nur negative Beispiele **then**

            schließe  $K$  mit Markierung „Nein“

**else-if**  $M = \emptyset$  **then**

            schließe  $K$  mit Markierung „Ja“ oder „Nein“

**else**

            finde Attribut  $a$  mit maximalem Informationsgewinn:  $I(M) - I(M|a)$

            markiere  $K$  mit  $a$  und schließe  $K$

            erzeuge Kinder von  $K$ :

                Ein Kind pro Attributausprägung  $w_i$  von  $a$  mit Menge  $M_i$

                Füge Kinder zu den offenen Knoten hinzu

**end-if**

**end-while**

# Bemerkungen

- Praktische Verbesserung: Stoppe auch, wenn der Informationsgewinn zu klein
- Jedes diskrete Attribut wird nur einmal pro Pfad abgefragt, da beim zweiten Mal der Informationsgewinn 0 ist
- Wenn man eine Beispielmenge hat, die den ganzen Tupelraum abdeckt, dann wird genau das Konzept gelernt.
- Reellwertige Attribute: Leichte Anpassung möglich.

# Beispiel

Äpfel: Geschmack  $\in \{\text{süß, sauer}\}$  und Farbe  $\in \{\text{rot, grün}\}$ .

Menge  $M = \{(\text{süß, rot}), (\text{süß, grün}), (\text{sauer, rot}), (\text{sauer, grün})\}$ .

Konzept: „guter Apfel“

Positiv:  $\{(\text{süß, rot}), (\text{süß, grün})\}$

Negativ:  $\{(\text{sauer, rot}), (\text{sauer, grün})\}$

$$p = 2, n = 2 \Rightarrow I(M) = 0.5 \log_2 2 + 0.5 \log_2 2 = 1$$

# Beispiel (Forts)

Attribut Geschmack:

- $p_{\text{süß}} = 2, n_{\text{süß}} = 0$
- $p_{\text{sauer}} = 0, n_{\text{sauer}} = 2$
- $I(M|\text{Geschmack}) = \frac{2}{4} * (\frac{2}{2} \log \frac{2}{2} + \frac{0}{2} \log \frac{2}{0}) + \frac{2}{4} * (\frac{0}{2} \log \frac{2}{0} + \frac{2}{2} \log \frac{2}{2}) = 0$
- $I(M) - I(M|\text{Geschmack}) = 1$

Attribut Farbe:

- $p_{\text{rot}} = 1, n_{\text{rot}} = 1$
- $p_{\text{grün}} = 1, n_{\text{grün}} = 1$
- $I(M|\text{Farbe}) = \frac{2}{4} * (\frac{1}{2} \log \frac{2}{1} + \frac{1}{2} \log \frac{2}{1}) + \frac{2}{4} * (\frac{1}{2} \log \frac{2}{1} + \frac{1}{2} \log \frac{2}{1}) = 1$
- $I(M) - I(M|\text{Farbe}) = 0$

# Beispiel

süß,rot	süß,grün	sauer,rot	sauer,grün
10	20	4	6

Ergibt:

- $I(M) = 0.8112$
- $I(M|\text{Geschmack}) = 0$
- $I(M) - I(M|\text{Geschmack}) = 0.8112$

Attribut Farbe:

- $I(M|\text{Farbe}) = 0.8086$
- $I(M) - I(M|\text{Farbe}) = 0.0026$

Grund: Die Farben sind in positiv / negativ nicht relativ gleich

# Beispiel

süß,rot	süß,grün	sauer,rot	sauer,grün
10	20	3	6

- $I(M) = 0.7793$
- $I(M|\text{Geschmack}) = 0$
- $I(M) - I(M|\text{Geschmack}) = 0.7793$

Attribut Farbe:

- $I(M|\text{Farbe}) = 0.7793$
- $I(M) - I(M|\text{Farbe}) = 0$



# Beispiel

Äpfel: Geschmack  $\in \{\text{süß, sauer}\}$  und Farbe  $\in \{\text{rot, grün}\}$ , Nr  $\in \{1, \dots, 4\}$

Menge  $M = \{(\text{süß, rot, 1}), (\text{süß, grün, 2}), (\text{sauer, rot, 3}), (\text{sauer, grün, 4})\}$ .

Dann:

- $I(M) = 1$
- $I(M|\text{Geschmack}) = 0$ , Informationsgewinn:  
 $I(M) - I(M|\text{Geschmack}) = 1$
- $I(M|\text{Farbe}) = 1$ , Informationsgewinn:  $I(M) - I(M|\text{Farbe}) = 0$
- $I(M|\text{Nr}) = 0$ , Informationsgewinn:  $I(M) - I(M|\text{Nr}) = 1$

Unfair: Apfelnr ist eindeutig, und stellt implizit mehr Ja/Nein Fragen dar.

Abhilfe: Weglassen der Apfelnr

Allgemein: ID3 bevorzugt Attribute mit vielen Werten

Daher: C4.5 als Anpassung von ID3

# Beispiel: Konzept Apfel schmeckt wie er aussieht

Äpfel: Geschmack  $\in \{\text{süß, sauer}\}$  und Farbe  $\in \{\text{rot, grün, gelb}\}$

Menge  $M$  = einmal jede Kombination

positiv: (rot,süß), (grün,sauer), (gelb,süß), (gelb,sauer)

- $I(M) = 0.9183$
- $I(M|\text{Farbe}) = 0.6666$  und  $I(M) - I(M|\text{Farbe}) = 0.2516$
- $I(M|\text{Geschmack}) = 0.9183$  und  $I(M) - I(M|\text{Geschmack}) = 0$

Wähle Farbe und dann Geschmack.

# Die Variante C4.5

- ID3 bevorzugt Attribute mit vielen Ausprägungen
- C4.5 ändert dies, und normiert daher den Informationsgewinn
- Algorithmus wie ID3 mit einem Unterschied:

$$\text{normierter Informationsgewinn} = \\ (I(M) - I(M|a)) * \text{Normierungsfaktor}$$

Normierungsfaktor für Attribut  $a$  Werten  $w_i, i = 1, \dots, k$ :

$$\frac{1}{\sum_{i=1}^k P(a = w_i) * \log_2\left(\frac{1}{P(a = w_i)}\right)}$$

# Beispiel

Äpfel: Geschmack  $\in \{\text{süß, sauer}\}$  und Farbe  $\in \{\text{rot, grün}\}$ , Nr  $\in \{1, \dots, 4\}$

Menge  $M = \{(\text{süß, rot, 1}), (\text{süß, grün, 2}), (\text{sauer, rot, 3}), (\text{sauer, grün, 4})\}$ .

Dann:

- $I(M) = 1$
- $I(M|\text{Geschmack}) = 0$ , Informationsgewinn = 1, normiert =  $1 * 1 = 1$
- $I(M|\text{Farbe}) = 1$ , Informationsgewinn = 0, normiert =  $0 * 1 = 0$
- $I(M|\text{Nr}) = 0$ , Informationsgewinn = 1, normiert =  $1 * \frac{1}{2} = \frac{1}{2}$

Normierungsfaktoren:

- Geschmack:  $\frac{1}{2/4 * \log_2(4/2) + 2/4 * \log_2(4/2)} = \frac{1}{1} = 1$
- Farbe:  $\frac{1}{2/4 * \log_2(4/2) + 2/4 * \log_2(4/2)} = \frac{1}{1} = 1$
- Nr:  $\frac{1}{1/4 * \log_2(4/1) + 1/4 * \log_2(4/1) + 1/4 * \log_2(4/1) + 1/4 * \log_2(4/1)} = \frac{1}{2}$

# Übergeneralisierung

- **Effekt:** Beispiele werden eingeordnet, aber der Entscheidungsbaum unterscheidet zu fein
- **Grund:** Beispiele nicht repräsentativ bzw. ausreichend.

Beispiel: Krankheitsdiagnose: Alle positiven Beispiele sind jünger als 25 oder älter als 30

Übergeneralisierung: Alter zwischen 25 und 30  $\implies$  nicht krank.

# Übergeneralisierung (2)

Lösung: **Pruning** des Entscheidungsbaums

- Stoppe Aufbau des Baums ab einer gewissen Schranke, da alle weiteren Attribute vermutlich irrelevant.
- Blatt-Markierung: Jenachdem welche Beispiele signifikant sind bisher
- Stoppen kann durch statistische Tests gesteuert werden

Verrauschte Daten: Gleiches Verfahren, d.h. Pruning

# Versionenraum-Lernverfahren

# Objekte

Was wird gelernt?

- Objekte habe **mehrwertige** Attributsausprägungen (nur **diskrete** Attribute)
- Schreibweise als Tupel  $(w_1, \dots, w_n)$  wobei  $w_i =$  Attributsausprägung des Attributs  $A_i$
- Ziel: Lerne Konzept

Beispiel: Äpfel

Attribut	Attributsausprägungen
Geschmack	süß, sauer
Farbe	rot, grün, gelb
Herkunft	Italien, Spanien, Deutschland
Größe	S, M, L

Roter, süßer Apfel aus Deutschland mittlerer Größe wird dargestellt als:  
(süß,rot,Deutschland,M)



# Konzepte - Konzeptsprache

- Konzepte (und Hypothesen) entsprechen **Mengen von Objekten**
- **Syntaktische** Darstellung von Konzepten und Hypothesen
- $\langle w_1, \dots, w_n \rangle$  entspricht der einelementigen Menge  $\{(w_1, \dots, w_n)\}$
- statt  $w_i$  auch erlaubt: ? oder  $\emptyset$
- **Semantik von  $\emptyset$** : Unabhängig von der Ausprägung: Objekt gehört nicht zum Konzept, d.h.  $\langle w_1, \dots, \emptyset, \dots, w_n \rangle$  entspricht der **leeren Menge**
- **Semantik von ?**: Jede Attributsausprägung ist erlaubt.

Beispiele:

- Süße Äpfel:  $\langle \text{süß}, ?, ?, ? \rangle$
- Rote, süße Äpfel aus Italien:  $\langle \text{süß}, \text{rot}, \text{Italien}, ? \rangle$

# Enthaltensein und Subsumtion

- $e \in k$ : Objekt  $e$  ist im Konzept  $k$  **enthalten**  
Beispiel:  $(\text{süß, rot, Italien, M}) \in \langle \text{süß, rot, Italien, ?} \rangle$
- Es gibt eine (partielle) **Ordnung** auf Konzepten  
 $k_1 \leq k_2$ : wenn die zugehörigen Mengen die Teilmengenbeziehung erfüllen („ $k_1 \subseteq k_2$ “)  
Beispiel:  $\langle \text{süß, rot, Italien, ?} \rangle \leq \langle \text{süß, ?, ?, ?} \rangle$
- $k_1$  **ist spezieller als**  $k_2$  bzw.  $k_2$  **ist allgemeiner als**  $k_1$
- $<$  ist der strikte Anteil (echt spezieller / allgemeiner)

# Konsistenz

Sei  $B$  eine Menge von Beispielen und  $h$  eine Hypothese.

$h$  ist **konsistent für**  $B$  gdw. für alle  $e \in B$ :

- Wenn  $e$  ein positives Beispiel, dann gilt  $e \in h$ .
- Wenn  $e$  ein negatives Beispiel, dann gilt  $e \notin h$ .

Z.B.  $B = \{(\text{süß, rot, Italien, M})^+, (\text{sauer, rot, Deutschland, L})^-\}$

- $h_1 = \langle \text{süß, ?, ?, ?} \rangle$  konsistent für  $B$
- $h_2 = \langle ?, ?, ?, M \rangle$  konsistent für  $B$
- $h_3 = \langle ?, \text{rot}, ?, ? \rangle$  nicht konsistent für  $B$
- $h_4 = \langle ?, ?, ?, ? \rangle$  nicht konsistent für  $B$ .

# Versionsraum-Lernverfahren

## Ideen:

- **Inkrementelles** Lernverfahren:  
Beispiele werden nach und nach abgearbeitet
- Verwalte die folgende Menge (= **Versionsraum**):

**Maximale** Menge aller Hypothesen, die **konsistent** bezüglich aller **bisher verarbeiteten** Beispiele ist.

- Beispiele selbst können nach ihrer Arbeitung vergessen werden.
- Alte Beispiele werden nicht nochmals gelesen.

# Versionenraum-Lernverfahren

## Ideen:

- **Inkrementelles** Lernverfahren:  
Beispiele werden nach und nach abgearbeitet
- Verwalte die folgende Menge (= **Versionenraum**):


**Maximale** Menge aller Hypothesen, die **konsistent** bezüglich aller **bisher verarbeiteten** Beispiele ist.

- Beispiele selbst können nach ihrer Arbeitung vergessen werden.
- Alte Beispiele werden nicht nochmals gelesen.

## Probleme / Fragen

- Wie wird die Menge aller konsistenter Hypothesen dargestellt?
- Wie wird die Menge angepasst beim nächsten Beispiel?

# Versionenraum



- + bisher verarbeitete positive Beispiele
- bisher verarbeitete negative Beispiele

# Darstellung des Versionenraums

Speichere zwei Grenzmengen  $S$  und  $G$ :

- $S =$  **untere Grenze** des Versionenraums

(die **speziellsten** Hypothesen):

Für jede Hypothese  $h \in S$  gilt:

- $h$  ist konsistent für die Menge der bisher gesehenen Beispiele
- es gibt kein  $h'$  mit  $h' < h$ , das konsistent für die Menge der bisher gesehenen Beispiele ist.

- $G =$  **obere Grenze** des Versionenraums


(die **allgemeinsten** Hypothesen):

Für jede Hypothese  $h \in G$  gilt:

- $h$  ist konsistent für die Menge der bisher gesehenen Beispiele
- es gibt kein  $h'$  mit  $h' > h$ , das konsistent für die Menge der bisher gesehenen Beispiele ist.

$$\text{Versionenraum} = \{h \mid \exists s \in S, g \in G : s \leq h \leq g\}$$

# Grenzen im Bild





# Iteratives Versionenraum-Lernen

Start des Algorithmus:

- Wähle die speziellsten Hypothesen für  $S$
- Wähle die allgemeinsten Hypothesen für  $G$
- Versionenraum: Enthält alle Hypothesen

Daher starte mit:

$$S = \{\langle \emptyset, \dots, \emptyset \rangle\}$$

$$G = \{\langle ?, \dots, ? \rangle\}$$

Beachte: Für jede Hypothese  $h$  gilt  $\langle \emptyset, \dots, \emptyset \rangle \leq h \leq \langle ?, \dots, ? \rangle$

# Grundgerüst des Algorithmus

Solange  $G \neq \emptyset$  und  $S \neq \emptyset$  und es noch Beispiele gibt:  
Für neues Beispiel  $e$ :

- Passe Menge  $S$  an.
- Passe Menge  $G$  an.

Iteriere weiter.

Beachte: Wenn eine der Mengen  $S$  oder  $G$  leer wird, dann ist der Versionenraum zusammengefallen und es gibt keine konsistente Hypothese zu den Beispielen passt.

# Anpassungen bei neuen Beispielen

Einfache Fälle:

- $e$  ist **positives** Beispiel und  $e \in h \in (G \cup S)$ :  
keine Anpassung für  $h$  erforderlich!
- $e$  ist **negatives** Beispiel und  $e \notin h \in (G \cup S)$ :  
keine Anpassung erforderlich!

# Anpassungen bei neuen Beispielen (2)

Wenn  $e$  ein **positives** Beispiel ist:

- Die Hypothesen  $h \in S \cup G$  mit  $e \in h$  müssen nicht verändert werden.
- Für jedes  $h \in G$  mit  $e \notin h$ :  $h$  **ist zu speziell** aber  $h$  kann nicht verallgemeinert werden (da  $h \in G$ ). Daher: **Lösche**  $h$  aus  $G$ .
- Für jedes  $h \in S$  mit  $e \notin h$ :  $h$  ist **zu speziell** und **muss verallgemeinert** werden. Ersetze  $h$  durch alle  $h'$  wobei
  - $h'$  ist eine minimale Verallgemeinerung von  $h$  bzgl.  $e$ , d.h.  $h' > h$ ,  $e \in h'$  und es gibt keine Verallgemeinerung  $h''$  von  $h$  bzgl.  $e$  mit  $h' > h''$ .
  - Zudem werden nur solche  $h'$  eingefügt, die nicht zu allgemein sind, d.h. es muss eine Hypothese  $g \in G$  geben mit  $g \geq h'$ .

Schließlich (**um  $S$  kompakt zu halten**): Entferne alle Hypothesen aus  $S$ , die echte allgemeiner sind als andere Hypothesen aus  $S$

# Anpassungen bei neuen Beispielen (3)

Wenn  $e$  ein **negatives** Beispiel ist:

- Die Hypothesen  $h \in S \cup G$  mit  $e \notin h$  müssen nicht verändert werden.
- Für jedes  $h \in S$  mit  $e \in h$ :  $h$  **ist zu allgemein** aber  $h$  kann nicht spezialisiert werden (da  $h \in S$ ). Daher: **Lösche**  $h$  aus  $S$ .
- Für jedes  $h \in G$  mit  $e \in h$ :  $h$  ist **zu allgemein** und **muss spezialisiert** werden. Ersetze  $h$  durch alle  $h'$  wobei
  - $h'$  ist eine minimale Spezialisierung von  $h$  bzgl.  $e$ , d.h.  $h' < h$ ,  $e \notin h'$  und es gibt keine Spezialisierung  $h''$  von  $h$  bzgl.  $e$  mit  $h'' > h'$ .
  - Zudem werden nur solche  $h'$  eingefügt, die nicht zu speziell sind, d.h. es muss eine Hypothese  $s \in S$  geben mit  $s \leq h'$ .

Schließlich (**um  $G$  kompakt zu halten**): Entferne alle Hypothesen aus  $G$ , die echt spezieller sind als andere Hypothesen aus  $G$

# Resultat des Algorithmus

Verschiedene Möglichkeiten:

- Wenn  $S = G = \{h\}$ , dann ist  $h$  das gelernte Konzept.
- Wenn  $S = \emptyset$  oder  $G = \emptyset$ : Versionenraum ist kollabiert, es gibt **keine konsistente Hypothese** für die vorgegebenen Trainingsbeispiele.
- $S$  und  $G$  sind nicht leer aber auch nicht einelementig und gleich: Der aufgespannte Versionenraum enthält das Konzept aber dieses ist nicht eindeutig identifizierbar. D.h. **alle Hypothesen im Versionenraum sind konsistent** für die Beispiele.

# Beispiel

Beispielmenge:

(süß,rot,Italien,L)<sup>+</sup>

(süß,gelb,Spanien,S)<sup>-</sup>

(süß,gelb,Spanien,L)<sup>+</sup>

(sauer,rot,Deutschland,L)<sup>-</sup>

Starte mit

$S = \{\langle \emptyset, \emptyset, \emptyset, \emptyset \rangle\}$

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

## Beispiel (2)

$$S = \{\langle \emptyset, \emptyset, \emptyset, \emptyset \rangle\}$$

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

Aktuelles Beispiel: (süß,rot,Italien,L)<sup>+</sup>



## Beispiel (2)

$$S = \{\langle \emptyset, \emptyset, \emptyset, \emptyset \rangle\}$$

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

Aktuelles Beispiel: (süß,rot,Italien,L)<sup>+</sup>

- Da (süß,rot,Italien,L)  $\in \langle ?, ?, ?, ? \rangle$ , wird  $G$  nicht verändert.

## Beispiel (2)

$$S = \{\langle \emptyset, \emptyset, \emptyset, \emptyset \rangle\}$$

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

Aktuelles Beispiel: (süß,rot,Italien,L)<sup>+</sup>

- Da (süß,rot,Italien,L)  $\in \langle ?, ?, ?, ? \rangle$ , wird  $G$  nicht verändert.
- Da (süß,rot,Italien,L)  $\notin \langle \emptyset, \emptyset, \emptyset, \emptyset \rangle$  muss diese Hypothese verallgemeinert werden:

## Beispiel (2)

$$S = \{\langle \emptyset, \emptyset, \emptyset, \emptyset \rangle\}$$

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

Aktuelles Beispiel:  $(\text{süß, rot, Italien, L})^+$

- Da  $(\text{süß, rot, Italien, L}) \in \langle ?, ?, ?, ? \rangle$ , wird  $G$  nicht verändert.
- Da  $(\text{süß, rot, Italien, L}) \notin \langle \emptyset, \emptyset, \emptyset, \emptyset \rangle$  muss diese Hypothese verallgemeinert werden:

Minimale Verallgemeinerung  $\langle \text{süß, rot, Italien, L} \rangle$ .

D.h.  $S = \{\langle \text{süß, rot, Italien, L} \rangle\}$ .

## Beispiel (3)

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

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

Aktuelles Beispiel:  $(\text{süß, gelb, Spanien, S})^-$

## Beispiel (3)

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

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

Aktuelles Beispiel:  $(\text{süß, gelb, Spanien, S})^-$

- Da  $(\text{süß, gelb, Spanien, S}) \notin \langle \text{süß, rot, Italien, L} \rangle$ , wird  $S$  nicht verändert.

# Beispiel (3)

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

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

Aktuelles Beispiel:  $(\text{süß, gelb, Spanien, S})^-$

- Da  $(\text{süß, gelb, Spanien, S}) \notin \langle \text{süß, rot, Italien, L} \rangle$ , wird  $S$  nicht verändert.
- Da  $(\text{süß, gelb, Spanien, S}) \in \langle ?, ?, ?, ? \rangle$ , muss diese Hypothese spezialisiert werden.

Minimale Spezialisierungen:

$$\begin{array}{llll}
 \langle \text{sauer, ?, ?, ?} \rangle & \langle ?, \text{rot, ?, ?} \rangle & \langle ?, \text{gruen, ?, ?} \rangle & \langle ?, ?, \text{Italien, ?} \rangle \\
 \langle ?, ?, \text{Deutschland, ?} \rangle & \langle ?, ?, ?, \text{L} \rangle & \langle ?, ?, ?, \text{M} \rangle & 
 \end{array}$$

## Beispiel (3)

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

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

Aktuelles Beispiel:  $(\text{süß, gelb, Spanien, S})^-$

- Da  $(\text{süß, gelb, Spanien, S}) \notin \langle \text{süß, rot, Italien, L} \rangle$ , wird  $S$  nicht verändert.
- Da  $(\text{süß, gelb, Spanien, S}) \in \langle ?, ?, ?, ? \rangle$ , muss diese Hypothese spezialisiert werden.

Minimale Spezialisierungen:

$$\begin{array}{llll} \langle \text{sauer, ?, ?, ?} \rangle & \langle ?, \text{rot, ?, ?} \rangle & \langle ?, \text{gruen, ?, ?} \rangle & \langle ?, ?, \text{Italien, ?} \rangle \\ \langle ?, ?, \text{Deutschland, ?} \rangle & \langle ?, ?, ?, \text{L} \rangle & \langle ?, ?, ?, \text{M} \rangle & \end{array}$$

Kompaktifizierung:

Nehme nur solche  $h$  mit: Es gibt  $h' \in S$  und  $h \geq h'$ :

Das erfüllen nur  $\langle ?, \text{rot, ?, ?} \rangle$   $\langle ?, ?, \text{Italien, ?} \rangle$   $\langle ?, ?, ?, \text{L} \rangle$

Daher:  $G = \{\langle ?, \text{rot, ?, ?} \rangle, \langle ?, ?, \text{Italien, ?} \rangle, \langle ?, ?, ?, \text{L} \rangle\}$ .

## Beispiel (4)

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

$$G = \{\langle ?, \text{rot}, ?, ? \rangle, \langle ?, ?, \text{Italien}, ? \rangle, \langle ?, ?, ?, \text{L} \rangle\}.$$

Aktuelles Beispiel:  $(\text{süß, gelb, Spanien, L})^+$



## Beispiel (4)

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

$$G = \{\langle ?, \text{rot}, ?, ? \rangle, \langle ?, ?, \text{Italien}, ? \rangle, \langle ?, ?, ?, \text{L} \rangle\}.$$

Aktuelles Beispiel:  $(\text{süß, gelb, Spanien, L})^+$

- Da  $(\text{süß, gelb, Spanien, L}) \notin \langle ?, \text{rot}, ?, ? \rangle \in G$  muss die Hypothese gelöscht werden (da  $G$  die allgemeinsten Hypothesen enthält, darf nicht verallgemeinert werden).

## Beispiel (4)

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

$$G = \{\langle ?, \text{rot}, ?, ? \rangle, \langle ?, ?, \text{Italien}, ? \rangle, \langle ?, ?, ?, \text{L} \rangle\}.$$

Aktuelles Beispiel:  $(\text{süß, gelb, Spanien, L})^+$

- Da  $(\text{süß, gelb, Spanien, L}) \notin \langle ?, \text{rot}, ?, ? \rangle \in G$  muss die Hypothese gelöscht werden (da  $G$  die allgemeinsten Hypothesen enthält, darf nicht verallgemeinert werden).
- Da  $(\text{süß, gelb, Spanien, L}) \notin \langle ?, ?, \text{Italien}, ? \rangle \in G$  muss die Hypothese gelöscht werden

# Beispiel (4)

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

$$G = \{\langle \text{?, rot, ?, ?} \rangle, \langle \text{?, ?, Italien, ?} \rangle, \langle \text{?, ?, ?, L} \rangle\}.$$

Aktuelles Beispiel:  $(\text{süß, gelb, Spanien, L})^+$

- Da  $(\text{süß, gelb, Spanien, L}) \notin \langle \text{?, rot, ?, ?} \rangle \in G$  muss die Hypothese gelöscht werden (da  $G$  die allgemeinsten Hypothesen enthält, darf nicht verallgemeinert werden).
- Da  $(\text{süß, gelb, Spanien, L}) \notin \langle \text{?, ?, Italien, ?} \rangle \in G$  muss die Hypothese gelöscht werden
- Da  $(\text{süß, gelb, Spanien, L}) \in \langle \text{?, ?, ?, L} \rangle \in G$  bleibt Hypothese in  $G$ .

## Beispiel (4)

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

$$G = \{\langle ?, \text{rot}, ?, ? \rangle, \langle ?, ?, \text{Italien}, ? \rangle, \langle ?, ?, ?, \text{L} \rangle\}.$$

Aktuelles Beispiel:  $(\text{süß, gelb, Spanien, L})^+$

- Da  $(\text{süß, gelb, Spanien, L}) \notin \langle ?, \text{rot}, ?, ? \rangle \in G$  muss die Hypothese gelöscht werden (da  $G$  die allgemeinsten Hypothesen enthält, darf nicht verallgemeinert werden).
- Da  $(\text{süß, gelb, Spanien, L}) \notin \langle ?, ?, \text{Italien}, ? \rangle \in G$  muss die Hypothese gelöscht werden
- Da  $(\text{süß, gelb, Spanien, L}) \in \langle ?, ?, ?, \text{L} \rangle \in G$  bleibt Hypothese in  $G$ .
- Ergibt  $G = \{\langle ?, ?, ?, \text{L} \rangle\}$

## Beispiel (4)

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

$$G = \{\langle ?, \text{rot}, ?, ? \rangle, \langle ?, ?, \text{Italien}, ? \rangle, \langle ?, ?, ?, \text{L} \rangle\}.$$

Aktuelles Beispiel:  $(\text{süß, gelb, Spanien, L})^+$

- Da  $(\text{süß, gelb, Spanien, L}) \notin \langle ?, \text{rot}, ?, ? \rangle \in G$  muss die Hypothese gelöscht werden (da  $G$  die allgemeinsten Hypothesen enthält, darf nicht verallgemeinert werden).
- Da  $(\text{süß, gelb, Spanien, L}) \notin \langle ?, ?, \text{Italien}, ? \rangle \in G$  muss die Hypothese gelöscht werden
- Da  $(\text{süß, gelb, Spanien, L}) \in \langle ?, ?, ?, \text{L} \rangle \in G$  bleibt Hypothese in  $G$ .
- Ergibt  $G = \{\langle ?, ?, ?, \text{L} \rangle\}$
- Da  $(\text{süß, gelb, Spanien, L}) \notin \langle \text{süß, rot, Italien, L} \rangle \in S$  muss die Hypothese verallgemeinert werden.

# Beispiel (4)

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

$$G = \{\langle ?, \text{rot}, ?, ? \rangle, \langle ?, ?, \text{Italien}, ? \rangle, \langle ?, ?, ?, \text{L} \rangle\}.$$

Aktuelles Beispiel:  $(\text{süß, gelb, Spanien, L})^+$

- Da  $(\text{süß, gelb, Spanien, L}) \notin \langle ?, \text{rot}, ?, ? \rangle \in G$  muss die Hypothese gelöscht werden (da  $G$  die allgemeinsten Hypothesen enthält, darf nicht verallgemeinert werden).
- Da  $(\text{süß, gelb, Spanien, L}) \notin \langle ?, ?, \text{Italien}, ? \rangle \in G$  muss die Hypothese gelöscht werden
- Da  $(\text{süß, gelb, Spanien, L}) \in \langle ?, ?, ?, \text{L} \rangle \in G$  bleibt Hypothese in  $G$ .
- Ergibt  $G = \{\langle ?, ?, ?, \text{L} \rangle\}$
- Da  $(\text{süß, gelb, Spanien, L}) \notin \langle \text{süß, rot, Italien, L} \rangle \in S$  muss die Hypothese verallgemeinert werden.  
 Minimale Verallgemeinerung:  $\langle \text{süß}, ?, ?, \text{L} \rangle$ .  
 Kompaktifizierung ändert nichts. Daher  $S = \{\langle \text{süß}, ?, ?, \text{L} \rangle\}$

# Beispiel (5)

$$S = \{\langle \text{süß}, ?, ?, L \rangle\}$$

$$G = \{\langle ?, ?, ?, L \rangle\}.$$

Aktuelles Beispiel: (sauer,rot,Deutschland,L)<sup>-</sup>

## Beispiel (5)

$$S = \{\langle \text{süß}, ?, ?, L \rangle\}$$

$$G = \{\langle ?, ?, ?, L \rangle\}.$$

Aktuelles Beispiel:  $(\text{sauer}, \text{rot}, \text{Deutschland}, L)^-$

- Da  $(\text{sauer}, \text{rot}, \text{Deutschland}, L) \notin \langle \text{süß}, ?, ?, L \rangle$ , bleibt  $S$  unverändert.



## Beispiel (5)

$$S = \{\langle \text{süß}, ?, ?, L \rangle\}$$

$$G = \{\langle ?, ?, ?, L \rangle\}.$$

Aktuelles Beispiel:  $(\text{sauer}, \text{rot}, \text{Deutschland}, L)^-$

- Da  $(\text{sauer}, \text{rot}, \text{Deutschland}, L) \notin \langle \text{süß}, ?, ?, L \rangle$ , bleibt  $S$  unverändert.
- Da  $(\text{sauer}, \text{rot}, \text{Deutschland}, L) \in \langle ?, ?, ?, L \rangle$ , muss die Hypothese spezialisiert werden.

# Beispiel (5)

$$S = \{\langle \text{süß}, ?, ?, L \rangle\}$$

$$G = \{\langle ?, ?, ?, L \rangle\}.$$

Aktuelles Beispiel:  $(\text{sauer}, \text{rot}, \text{Deutschland}, L)^-$

- Da  $(\text{sauer}, \text{rot}, \text{Deutschland}, L) \notin \langle \text{süß}, ?, ?, L \rangle$ , bleibt  $S$  unverändert.
- Da  $(\text{sauer}, \text{rot}, \text{Deutschland}, L) \in \langle ?, ?, ?, L \rangle$ , muss die Hypothese spezialisiert werden.

Minimale Spezialisierungen:

$$\begin{array}{lll} \langle \text{süß}, ?, ?, L \rangle & \langle ?, \text{gelb}, ?, L \rangle & \langle ?, \text{grün}, ?, L \rangle \\ \langle ?, ?, \text{Italien}, L \rangle & \langle ?, ?, \text{Spanien}, L \rangle & \end{array}$$

# Beispiel (5)

$$S = \{\langle \text{süß}, ?, ?, L \rangle\}$$

$$G = \{\langle ?, ?, ?, L \rangle\}.$$

Aktuelles Beispiel:  $(\text{sauer}, \text{rot}, \text{Deutschland}, L)^-$

- Da  $(\text{sauer}, \text{rot}, \text{Deutschland}, L) \notin \langle \text{süß}, ?, ?, L \rangle$ , bleibt  $S$  unverändert.
- Da  $(\text{sauer}, \text{rot}, \text{Deutschland}, L) \in \langle ?, ?, ?, L \rangle$ , muss die Hypothese spezialisiert werden.

Minimale Spezialisierungen:

$$\begin{array}{lll} \langle \text{süß}, ?, ?, L \rangle & \langle ?, \text{gelb}, ?, L \rangle & \langle ?, \text{grün}, ?, L \rangle \\ \langle ?, ?, \text{Italien}, L \rangle & \langle ?, ?, \text{Spanien}, L \rangle & \end{array}$$

Kompaktifizierung: Nur  $\langle \text{süß}, ?, ?, L \rangle$  bleibt übrig

Daher:  $G = \langle \text{süß}, ?, ?, L \rangle$

# Beispiel (6)

$$S = \{\langle \text{süß}, ?, ?, L \rangle\}$$

$$G = \{\langle \text{süß}, ?, ?, L \rangle\}$$

Keine Beispiele mehr, und  $S = G = \{\langle \text{süß}, ?, ?, L \rangle\}$ .

Daher ist  $\langle \text{süß}, ?, ?, L \rangle$  das gelernte Konzept.

# Noch ein Beispiel

Beispielmenge:

(süß,rot,Italien,L)<sup>+</sup>

(süß,gelb,Italien,L)<sup>-</sup>

Starte mit

$$S = \{\langle \emptyset, \emptyset, \emptyset, \emptyset \rangle\}$$

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

## Noch ein Beispiel (2)

$$S = \{\langle \emptyset, \emptyset, \emptyset, \emptyset \rangle\}$$

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

Aktuelles Beispiel: (süß,rot,Italien,L)<sup>+</sup>

## Noch ein Beispiel (2)

$$S = \{\langle \emptyset, \emptyset, \emptyset, \emptyset \rangle\}$$

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

Aktuelles Beispiel:  $(\text{süß, rot, Italien, L})^+$

- Da  $(\text{süß, rot, Italien, L}) \in \langle ?, ?, ?, ? \rangle$ , wird  $G$  nicht verändert.

## Noch ein Beispiel (2)

$$S = \{\langle \emptyset, \emptyset, \emptyset, \emptyset \rangle\}$$

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

Aktuelles Beispiel: (süß,rot,Italien,L)<sup>+</sup>

- Da (süß,rot,Italien,L)  $\in \langle ?, ?, ?, ? \rangle$ , wird  $G$  nicht verändert.
- Da (süß,rot,Italien,L)  $\notin \langle \emptyset, \emptyset, \emptyset, \emptyset \rangle$  muss diese Hypothese verallgemeinert werden:



## Noch ein Beispiel (2)

$$S = \{\langle \emptyset, \emptyset, \emptyset, \emptyset \rangle\}$$

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

Aktuelles Beispiel:  $(\text{süß, rot, Italien, L})^+$

- Da  $(\text{süß, rot, Italien, L}) \in \langle ?, ?, ?, ? \rangle$ , wird  $G$  nicht verändert.
- Da  $(\text{süß, rot, Italien, L}) \notin \langle \emptyset, \emptyset, \emptyset, \emptyset \rangle$  muss diese Hypothese verallgemeinert werden:

Minimale Verallgemeinerung  $\langle \text{süß, rot, Italien, L} \rangle$ .

D.h.  $S = \{\langle \text{süß, rot, Italien, L} \rangle\}$ .

# Noch ein Beispiel (3)

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

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

Aktuelles Beispiel:  $(\text{süß, gelb, Italien, L})^-$

- $(\text{süß, gelb, Italien, L}) \notin \langle \text{süß, rot, Italien, L} \rangle$ .  $S$  wird nicht verändert
- $(\text{süß, gelb, Italien, L}) \in \langle ?, ?, ?, ? \rangle$ , Hypothese wird spezialisiert:

Minimale Spezialisierungen

$\langle \text{sauer, ?, ?, ?} \rangle$      $\langle ?, \text{grün, ?, ?} \rangle$      $\langle ?, \text{rot, ?, ?} \rangle$      $\langle ?, ?, \text{Deutschland, ?} \rangle$

$\langle ?, ?, \text{Spanien, ?} \rangle$      $\langle ?, ?, ?, \text{S} \rangle$      $\langle ?, ?, ?, \text{M} \rangle$

Kompaktifizierung: Es verbleibt nur  $\langle ?, \text{rot, ?, ?} \rangle$

D.h.  $G = \{\langle ?, \text{rot, ?, ?} \rangle\}$ .

# Noch ein Beispiel (4)

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

$$G = \{\langle ?, \text{rot}, ?, ? \rangle\}$$

Keine weiteren Beispiele: Alle Hypothesen  $h$  mit

$$\langle \text{süß, rot, Italien, L} \rangle \leq h \leq \langle ?, \text{rot}, ?, ? \rangle$$

sind konsistent.

# Weiteres Beispiel

Wie vorher aber mit drittem Beispiel:  
Beispielmenge:

(süß,rot,Italien,L)<sup>+</sup>

(süß,gelb,Italien,L)<sup>-</sup>

(süß,grün,Italien,L)<sup>+</sup>

# Beim letzten Beispiel

$$S = \{\langle \text{süß, rot, Italien, L} \rangle\}.$$

$$G = \{\langle ?, \text{rot}, ?, ? \rangle\}$$

Aktuelles Beispiel:  $(\text{süß, grün, Italien, L})^+$

- $(\text{süß, grün, Italien, L}) \notin \langle ?, \text{rot}, ?, ? \rangle$ .

Da  $\langle ?, \text{rot}, ?, ? \rangle$  nicht verallgemeinert werden darf, wird die Hypothese gelöscht.

D.h.  $G = \emptyset$

- $(\text{süß, grün, Italien, L}) \notin \langle \text{süß, rot, Italien, L} \rangle$ .

Verallgemeinere zu  $\langle \text{süß}, ?, \text{Italien, L} \rangle$ .

Kompaktifizierung: Löscht alle Hypothesen in  $S$ , da es keine in  $G$  gibt.

D.h.  $S = \emptyset$ .

- $G = S = \emptyset$ : Es gibt keine konsistente Hypothese.

# Nachteile

- Verrauschte Daten können nicht adäquat behandelt werden
- Bei verrauschten Daten findet die Methode nie eine konsistente Hypothese
- Abhilfe: Stärke Konzeptsprachen
- Problem dabei: Overfitting

# Erweiterungen

- Erlaube „ $M_a$ “ für Attribute, wobei  $M_a$  eine Teilmenge der möglichen Ausprägungen von  $a$  ist.
- Erlaube Disjunktionen dieser Konzepte. Damit kann man bereits alle Konzepte darstellen, wenn die Menge der Attribute und Ausprägungen endlich ist.