

Moderne Methoden der KI: Maschinelles Lernen

Prof. Dr. Hans-Dieter Burkhard
Vorlesung Sommer-Semester 2007

Konzept-Lernen

Konzept-Lernen
Lernen als Suche
Inductive Bias

Konzept-Lernen: Problemstellung

Ausgangspunkt:

Konzept beschreibt Menge von Objekten (mit bestimmten Eigenschaften) aus einer umfassenderen Menge

X : Menge von Objekten x

Merkmalen M_1, \dots, M_m aus (endlichen) Wertebereichen W_1, \dots, W_m

Objekte als Merkmalsvektoren $x = [x_1, \dots, x_m]$

C : Konzept definiert durch Umfang, d.h. als Teilmenge von X : $C \subseteq X$
bzw. durch charakteristische Funktion $c_C: X \rightarrow \{0,1\}$

$$c_C(x) = \begin{cases} 1, & \text{falls } x \in C \\ 0, & \text{sonst} \end{cases}$$

H.D. Burkhard
Sommer-Semester 2007

MMKI: Konzept-Lernen

2

Konzept-Lernen: Problemstellung

Konzept-Lernen:

Allgemeine Definition eines Konzeptes C anhand einiger positiver Beispiele ($x \in C$) und negativer Beispiele ($x \notin C$) erkennen

äquivalent:

Boolesche Funktion $c_C: X \rightarrow \{0,1\}$
anhand von Eingabe-/Ausgabepaaren lernen

H.D. Burkhard
Sommer-Semester 2007

MMKI: Konzept-Lernen

3

Konzept-Lernen: Problemstellung

Lernen als Suche

Suchraum (Zustände/Operatoren):

Menge von Hypothesen

(hier für Konzepte $C \subseteq X$ bzw. Boolesche Fkten. $X \rightarrow \{0,1\}$)
evtl. nur eingeschränkte Hypothesen-Menge

Übergänge zwischen Hypothesen

(hier z.B. Halbordnung bzgl. Inklusion)

Suchstrategie: Anordnung ausnutzen

(hier z.B. umfassendere Hypothese suchen)

H.D. Burkhard
Sommer-Semester 2007

MMKI: Konzept-Lernen

4

Konzept-Lernen: Notationen

Gesamtmenge: $X = W_1 \times \dots \times W_m$,

Objekte als Merkmalsvektoren $x = [x_1, \dots, x_m]$

Konzept: $C \subseteq X$ bzw. Charakt. Fkt. $c_C: c_C(x) = 1 \leftrightarrow x \in C$

korrekte Trainingsmenge D für Konzept C : Menge von Beispielen

$D = \{ [x, c_C(x)] \mid x \in X_D \}$ für eine Menge $X_D \subseteq X$
mit positiven Beispiele $[x, 1]$
und negativen Beispiele $[x, 0]$

Trainingsmenge D kann fehlerbehaftet ("verrauscht") bzgl. C sein:
fehlerhaftes Beispiel: $[x, c(x)]$ mit $c(x) \neq c_C(x)$

allgemein: $D = \{ [x, c(x)] \mid x \in X_D \}$
mit $c: X \rightarrow \{0,1\}$ (ohne Korrektheitsforderung)

H.D. Burkhard
Sommer-Semester 2007

MMKI: Konzept-Lernen

5

Konzept-Lernen: Notationen

Hypothese h als Boolesche Funktion $h: X \rightarrow \{0,1\}$

beschreibt Konzept $C_h = \{ x \mid h(x) = 1 \}$

Lernziel bei Konzept C :

Hypothese h_C finden mit $\forall x \in X: h(x) = 1 \leftrightarrow x \in C$

Hypothese h ist konsistent mit Trainingsmenge D :

$$\forall [x, c(x)] \in D: h(x) = c(x)$$

i.a. gibt es viele mit D konsistente Hypothesen
(Problem der korrekten Verallgemeinerung)

H.D. Burkhard
Sommer-Semester 2007

MMKI: Konzept-Lernen

6

Konzept-Lernen: Beispiel

Die Menge H der zugelassenen Hypothesen ist Entwurfsentscheidung.

Beispiel: Hypothesenmenge H_1

Hypothesen aus H_1 beschrieben durch verallgemeinerte Merkmalsvektoren $h = [h_1, \dots, h_m]$, mit $h_i \in \{?, x_i, \emptyset\}$ wobei der Eintrag h_i für das i -te Merkmal bedeutet:

- $h_i = ?$: beliebige Ausprägung des i -ten Merkmals zugelassen
- $h_i = x_i$: i -tes Merkmal muss Wert x_i haben
- $h_i = \emptyset$: kein Wert zugelassen

$h(x) = h([x_1, \dots, x_m]) = 1$ gdw. $\forall i=1, \dots, m: h_i \in \{?, x_i\}$

Nicht alle Konzepte $C \subseteq X$ erfasst: $H_1 \not\subseteq 2^X$

General-to-Specific-Anordnung

Lernen als Suche basiert auf Anordnung des Suchraumes

„General-to-Specific“-Anordnung des Hypothesenraumes H durch Halbordnungsrelation für Boolesche Funktionen $h: X \rightarrow \{0,1\}$

h_1 allgemeiner oder gleich h_2 ($h_1 \supseteq h_2$)
gdw. $\forall x \in X: h_2(x) = 1 \rightarrow h_1(x) = 1$

h_1 allgemeiner als h_2 ($h_1 \supset h_2$) gdw. $h_1 \supseteq h_2$ und $h_1 \neq h_2$

Im Beispiel H_1 : minimale Hypothese: $h = [\emptyset, \dots, \emptyset]$ ($C = \emptyset$)
maximale Hypothese: $h = [?, \dots, ?]$ ($C = X$)

Algorithmus Find-S

Idee: Mit speziellster Hypothese h beginnen.

Verallgemeinern, wenn ein positives Beispiel nicht überdeckt wird
(wenn $h(x) = 0$ für Beispiel $[x, 1] \in D$)

Ausgangspunkt: Ein Hypothesenraum H

Beschränkungen der Merkmalswerte durch die Hypothesen

Bezeichnung: b_i = Beschränkung des i -ten Merkmals durch h

(z.B. H_1 mit $b_i \in \{?, x_i, \emptyset\}$)

Algorithmus Find-S

0. Initialisierung: $h :=$ speziellste (minimale) Hypothese aus H

1. Für jedes positive Trainingsbeispiel $[[x_1, \dots, x_m], 1] \in D$:

Für jedes Merkmal $i=1, \dots, m$:

- Falls x_i die Beschränkung b_i erfüllt: Nichts verändern.

- Sonst: h minimal verallgemeinern durch

Verallgemeinerung von b_i zu b_i' , so dass b_i' durch x erfüllt ist.

2. Hypothese h ausgeben.

Algorithmus Find-S (Fortsetzung)

FIND-S ignoriert negative Beispiele.

Wenn Hypothesen $h \in H$ jeweils Konjunktionen von Merkmalsbeschränkungen (b_i) sind und Trainingsmenge korrekt ist, so gilt:

Find-S findet die spezifischste Hypothese h_{D^+} aus H , die mit den positiven Beispielen aus der Trainingsmenge D konsistent ist. Falls Zielkonzept C in H enthalten ist, so ist die Hypothese h_{D^+} auch konsistent mit den negativen Beispielen aus D .

Einige Probleme für Lernsysteme

Problem-Diskussion (am Beispiel *Find-S*):

- Ist die gefundene Hypothese h das korrekte Zielkonzept C ? Im allg. mehrere mit Trainingsmenge D konsistente Hypothesen in H .
 - Algorithmus sollte Zuverlässigkeit von h angeben.
- Grund für Auswahl bei mehreren konsistenten Möglichkeiten?
Hier: speziellste Hypothese, wegen Anordnung/Algorithmus (Design-Problem).
- Umgang mit fehlerhaften Beispielen:
 - Algorithmus sollte Inkonsistenzen in D erkennen und behandeln. (wird bei *Find-S* ignoriert: negative Beispiele ohne Einfluss)
- Umgang mit evtl. unterschiedlichen „besten“ Elementen in H :
 - Backtracking vorsehen.

List-Then-Eliminate-Algorithmus

Version Space bzgl. H und D :

$$VS_{H,D} := \{ h \in H \mid h \text{ konsistent mit } D \}$$

= alle potentiellen Ergebnisse

List-Then-Eliminate-Algorithmus:

0. Initialisierung: $V := H$
1. Für jedes Trainingsbeispiel $[x, c(x)] \in D$:
 $V := V - \{ h \mid h(x) \neq c(x) \}$
2. Ergebnis: $VS_{H,D} := H$

zu komplex (Aufflistung aller Hypothesen)

H.D.Burkhard
Sommer-Semester 2007 MMKI: Konzept-Lernen

13

Candidate-Elimination-Algorithmus

Kompaktere Repräsentation für Version Space mittels Begrenzungsmengen:

$$G := \text{Max}(VS_{H,D}) = \{ h \in VS_{H,D} \mid \neg \exists g \in VS_{H,D} : g \supseteq h \}$$

$$S := \text{Min}(VS_{H,D}) = \{ h \in VS_{H,D} \mid \neg \exists g \in VS_{H,D} : h \supseteq g \}$$

G : allgemeinste Hypothesen aus $VS_{H,D}$
 S : speziellste Hypothesen aus $VS_{H,D}$

Satz: $VS_{H,D} = \{ h \mid \exists g \in G \exists s \in S : g \supseteq h \supseteq s \}$
 (Voraussetzung: G, S existieren)

Candidate-Elimination-Alg. arbeitet mit Begrenzungsmengen

H.D.Burkhard
Sommer-Semester 2007 MMKI: Konzept-Lernen

14

Candidate-Elimination-Algorithmus

0. Initialisierung: $G := \text{Max } H, S := \text{Min } H$
1. Für jedes Trainingsbeispiel $d \in D$:
 Falls d positiv ($d = [x, 1]$):
 - $G := G - \{ g \mid g(x) \neq 1 \}$
 - Für alle $s \in S$ mit $s(x) \neq 1$:
 -- $S := S - \{s\}$
 -- $S := S \cup \text{Min} \{ h \mid h(x) = 1 \wedge \exists g \in G : g \supseteq h \supseteq s \}$
 -- $S := S - \{ h \mid \exists s \in S : h \supseteq s \}$
 Falls d negativ ($d = [x, 0]$):
 - $S := S - \{ s \mid s(x) \neq 0 \}$
 - Für alle $g \in G$ mit $g(x) \neq 0$:
 -- $G := G - \{g\}$
 -- $G := G \cup \text{Max} \{ h \mid h(x) = 0 \wedge \exists s \in S : g \supseteq h \supseteq s \}$
 -- $G := G - \{ h \mid \exists g \in G : g \supseteq h \}$
2. Ergebnis: $G = \text{Max}(VS_{H,D}), S = \text{Min}(VS_{H,D})$

H.D.Burkhard
Sommer-Semester 2007 MMKI: Konzept-Lernen

15

Candidate-Elimination-Algorithmus

- Ergebnis korrekt, falls
 - Trainings-Beispiele korrekt
andernfalls wird korrektes Konzept eliminiert
 - Zielkonzept in H enthalten
sonst evtl. kein Ergebnis (alle Hypothesen verworfen)
- Dabei gilt:
 - Ergebnis enthält alle alternativen Lösungen
 - Abbruchmöglichkeit: falls Ergebnis eindeutig ($S = G = \{h\}$)

H.D.Burkhard
Sommer-Semester 2007 MMKI: Konzept-Lernen

16

Weitere Probleme für Lernsysteme

(am Beispiel Candidate-Elimination-Algorithmus)

- Reihenfolge der Beispiele aus D :

Optimale Query-Strategie wählt Beispiel d aus, bei dem der aktuell konstruierte Version Space VS möglichst gleichmäßig aufgeteilt wird in:

$$VS(d+) := \{ h \in V \mid h(d) = 1 \}$$

$$VS(d-) := \{ h \in V \mid h(d) = 0 \}$$

allgemeines Prinzip: Entropie verringern

H.D.Burkhard
Sommer-Semester 2007 MMKI: Konzept-Lernen

17

Weitere Probleme für Lernsysteme

(am Beispiel Candidate-Elimination-Algorithmus)

Anwendung partiell gelernter Konzepte C :

Sei H eine Hypothesenmenge mit $C \in H$.
 Klassifikation ($x \in C?$) eines unbekanntes Objekts x ist mittels H möglich, falls $h(x)$ für alle $h \in H$ den gleichen Wert ergibt.

Es gilt: $x \in C$, falls $h(x)=1$ für alle $h \in \text{Min } H$ (speziell: S)
 $x \notin C$, falls $h(x)=0$ für alle $h \in \text{Max } H$ (speziell: G)

Allgemeineres Prinzip: Voting
 (gemäß Anzahl/Wahrsch. der Hypothesen $h \in H$ mit $h(x) = 1$ bzw. $=0$)

H.D.Burkhard
Sommer-Semester 2007 MMKI: Konzept-Lernen

18

„Inductive Bias“

- Einschränkung des Hypothesenraums
Konsequenz: Evtl. keine Lösung
- Vergrößerung des Hypothesenraums
Konsequenz:
 - Verschlechterung der Generalisierungsfähigkeit
 - Extremfall: Alle Hypothesen
Wenn beim Lernen mit korrekten Beispielen alle konsistenten Hypothesen behalten werden, gibt es keine Generalisierung (Voting für unbekannte Beispiele 50:50)

H.D.Burkhard
Sommer-Semester 2007 MMKI: Konzept-Lernen

19

„Inductive Bias“

Generalisierung (Klassifizierung neuer Objekte) nur möglich, wenn a priori Zusatzannahmen getroffen werden.
(Hier: Beschränkung des Hypothesenraum - „restriction bias“.)

- Zusatzannahme: **Inductive Bias**
- Beispiele:
 - Datenbank positiver/negativer Beispiele: **kein bias**
 - nur Beispiel-Objekte klassifizierbar
 - *Candidate Elimination*: **Hypothesenraum enthält Zielkonzept**
 - neue Objekte ggf. bei eindeutigem Votum klassifizierbar
 - *Find-S*: **Hypothesenraum enthält Zielkonzept**
Ungesehene Objekte sind negativ (CWA)
 - alle Objekte klassifizierbar, solange Hypothese existiert

H.D.Burkhard
Sommer-Semester 2007 MMKI: Konzept-Lernen

20

„Inductive Bias“

Generalisierung nur möglich,
wenn a priori Zusatzannahmen getroffen werden.

- Zusatzannahme: **Inductive Bias**

In der Praxis oft implizite Annahmen als inductive bias.

Analyse erforderlich

H.D.Burkhard
Sommer-Semester 2007 MMKI: Konzept-Lernen

21

ZUSAMMENFASSUNG

- Konzeptlernen kann als Suchproblem spezifiziert werden.
- Algorithmus *Find-S* benutzt partielle Ordnung „*General-to-Specific*“. Entlang eines Pfades wird die spezifischste Hypothese gefunden, die mit den Trainingsdaten konsistent ist.
- Algorithmus *Candidate-Elimination* berechnet obere/untere Grenzen für Version Space. Der Version Space beschreibt vollständig alle verfügbaren Hypothesen der Zielfunktion (und ermöglicht damit Abbruchkriterium, Inkonsistenz-Prüfung der Trainingsdaten, optimale Auswahl von Trainingsbeispielen, Voting).
- *Find-S* und *Candidate-Elimination* sind nicht geeignet für fehlerhafte Trainingsdaten. Die Zielfunktion muss im Hypothesenraum enthalten sein.
- Generalisierung erfordert einen **inductive bias**, d.h. a-priori gegebene Auswahlkriterien für Mengen konsistenter Hypothesen.

H.D.Burkhard
Sommer-Semester 2007 MMKI: Konzept-Lernen

22