

Was bisher geschah

Wissensrepräsentation und -verarbeitung durch

- ▶ Künstliche Neuronale Netze (insbes. auch CNN)
- ▶ Zustandsübergangssysteme
- ▶ Klassische Logiken
- ▶ Regelsysteme in klassischer Aussagen- und Prädikatenlogik
- ▶ Logische Programme (Prolog, Datalog)
- ▶ Nichtmonotonen Schließens bei unvollständigem Wissen (closed world assumption, schwache Negation)
- ▶ Beispiele zum Planen
- ▶ Answer Set Programming
- ▶ Mehrwertige Logiken, z.B. dreiwertige Łukasiewicz-Logik

Fuzzy-Logiken

Fuzzy-Logik: Sammelbegriff für verschiedene Logiken, meist mit

- ▶ Wahrheitswertbereich $[0, 1] \subseteq \mathbb{R}$ (oder Teilmenge davon)
- ▶ $\neg x \mapsto 1 - x$
- ▶ Wahrheitswertkonstanten 0 und 1

und definiert über Wahrheitswertfunktionen für andere Junktoren, oft \wedge , \vee oder \rightarrow

Beispiele:

- ▶ Standard-Fuzzy-Logik: $\wedge \mapsto \min$, $\vee \mapsto \max$
- ▶ Produkt-Logik: $x \wedge y \mapsto xy$
- ▶ Łukasiewicz-Logik: $x \rightarrow y \mapsto \min(1, 1 - x + y)$

Vierwertige Logik

sinnvoll z.B. zum Umgang mit widersprüchlichen Informationen

Beispiel: parakonsistente Logik von Belnap (1977)

Wahrheitswertbereich $\{0, \perp, \top, 1\}$ (auch $\{0, 1\}^2$)

mit zwei Ordnungen (beide partiell):

- ▶ Wahrheits-Ordnung: $0 <_W \perp <_W 1$ und $0 <_W \top <_W 1$
- ▶ Informations-Ordnung: $\perp <_I 0 <_I \top$ und $\perp <_I 1 <_I \top$

Wahrheitswertfunktionen:

\neg	\perp	0	1	\top
	\perp	1	0	\top

\wedge	\perp	0	1	\top
\perp	\perp	0	\perp	0
0	0	0	0	0
1	\perp	0	1	\top
\top	0	0	\top	\top

\vee	\perp	0	1	\top
\perp	\perp	\perp	1	1
0	\perp	0	1	\top
1	1	1	1	1
\top	1	\top	1	\top

Mehrwertige Mengen und Relationen

Übergang von zweiwertigen zu mehrwertigen Mengen:

- ▶ Menge $M \subseteq U$ mit
charakteristischer Funktion $\chi_M : U \rightarrow \{0, 1\}$
- ▶ Mehrwertige Menge über Wahrheitswertbereich W
Funktion $M : U \rightarrow W$
ordnet jedem $x \in U$ einen Wahrheitswert
(Zugehörigkeitsgrad) zu

Relation: Menge $R \subseteq A \times B$ von Paaren (Tupeln)

Übergang von zweiwertigen zu mehrwertigen Prädikaten
(Relationen):

- ▶ Relation $R \subseteq A \times B$ mit
charakteristischer Funktion $\chi_R : A \times B \rightarrow \{0, 1\}$
- ▶ Mehrwertige Relation über Wahrheitswertbereich W
Funktion $R : A \times B \rightarrow W$
ordnet jedem Paar $(a, b) \in A \times B$ einen Wahrheitswert zu

Erinnerung: Eigenschaften sind einstellige Relationen (Mengen).

Unsichere Regelsysteme

Ansätze:

1. Unsicherheit in den Daten (Wahrheitswerte an Fakten)

Regel $I_1 \wedge \dots \wedge I_n \rightarrow h$

angewendet auf Voraussetzungen I_i , je mit Wahrheitswert w_i
ordnet h den Wert $f(w_1, \dots, w_n)$ zu

2. Unsicherheit in den Regeln (Wahrheitswerte an Regeln)

Regel $I_1 \wedge \dots \wedge I_n \rightarrow_w h$

angewendet auf Voraussetzungen I_i
ordnet h den Wert w zu, falls alle I_i erfüllt sind

3. Kombination aus beiden

Beispiel

ProbLog

(<https://dtai.cs.kuleuven.be/problog/index.html>)

Fakten mit Wert:

0.5::heads1.

0.6::heads2.

Regeln:

twoHeads :- heads1, heads2.

Anfragen:

- ▶ heads1 = 0.5
- ▶ heads2 = 0.6
- ▶ twoHeads = 0.3

Beispiel

Fakten mit Wert:

`0.5::heads1.`

`0.6::heads2.`

Regeln:

`someHead :- heads1.`

`someHead :- heads2.`

Anfragen:

- ▶ `heads1 = 0.5`
- ▶ `heads2 = 0.6`
- ▶ `someHead = 0.8`

Beispiel

Fakten und Regeln mit Wert:

```
0.3::stress(X) :- person(X).
```

```
0.2::influences(X,Y) :- person(X), person(Y).
```

```
smokes(X) :- stress(X).
```

```
smokes(X) :- friend(X,Y), influences(Y,X), smokes(Y).
```

```
0.4::asthma(X) :- smokes(X).
```

WH: Wahrscheinlichkeiten

Begriffe:

- ▶ Zufalls-Experiment
- ▶ (endlicher) Wahrscheinlichkeitsraum $(\Omega, 2^\Omega, P)$
- ▶ Elementar-Ereignis
- ▶ zufälliges Ereignis

Beispiele:

- ▶ Experiment: dreimal würfeln,
- ▶ Ereignis V : Augenzahlen sind paarweise verschieden,
- ▶ Elementar-Ereignisse: $\{(x, y, z) \mid x, y, z \in \{1, \dots, 6\}\}$
- ▶ $P(V)$ bei Gleichverteilung?

WH: Bedingte Wahrscheinlichkeiten

Definition:

Bedingte Wahrscheinlichkeit von Ereignis A unter Ereignis B :

$$P(A | B) = P(A \cap B) / P(B)$$

Beispiele:

- ▶ zwei Würfel, $A =$ Augensumme ist > 7 ,
 $B =$ beide Zahlen sind ungerade.
- ▶ B eine Ursache (für Fehler, Krankheit, usw.),
 A eine Auswirkung (Symptom) (leichter zu beobachten)

Unterschied zu bisher betrachteten Regelsystemen:

- ▶ bisher: Aussagen über Wahrheit (von Aussagen)
- ▶ jetzt: Aussagen über Wahrscheinlichkeit (von Ereignissen)

Satz von Bayes

Satz von Bayes (einfache Form):

$$P(A | B) \cdot P(B) = P(B | A) \cdot P(A)$$

Beweis: Def. von $P(X | Y)$ einsetzen, vereinfachen.

Anwendung: Rechnen mit bedingten Wahrscheinlichkeiten

- ▶ 1/3 aller Studenten haben ein Notebook.
- ▶ 1/10 aller Studenten studieren Informatik.
- ▶ 9/10 aller Informatik-Studenten haben ein Notebook.
- ▶ Sie sehen einen Studenten mit einem Notebook.
- ▶ Mit welcher Wahrscheinlichkeit studiert er Informatik?

Das ist ein Beispiel für probabilistische Inferenz.
wird verallgemeinert auf längere Ketten von
Ursache-Wirkung-Beziehungen

WH: Unabhängige Ereignisse

Def: Ereignisse A, B heißen (stochastisch) unabhängig, falls $P(A \cap B) = P(A) \cdot P(B)$.

Satz: $P(B) > 0 \Rightarrow (A \text{ und } B \text{ unabh.} \iff P(A | B) = P(A))$.

Bsp:

zwei Würfel, $A = \text{Augensumme} > 7$, $B = \text{beide Zahlen ungerade}$.
 A und B sind *nicht* unabhängig.

Def: Nicht unabhängige A, B heißen *korreliert*.

Vorsicht: das bedeutet nicht,
dass A die Ursache für B ist, oder B die für A .
Es könnte z.B. eine gemeinsame Ursache C für A und B geben.
(correlation does not imply causation)

Beispiele:

- ▶ $A = \text{schweres Fahrzeug}$, $B = \text{hoher Verbrauch}$,
 $C = \text{unwegsames Gelände}$
- ▶ $A = \text{geringes Geburtsgewicht}$, $B = \text{hohe Säuglingssterblichkeit}$, $C = \text{starkes Rauchen}$

Diskrete Zufallsgrößen

- ▶ Def: Zufallsgröße ist Funktion $X : \Omega \rightarrow \text{endl. Menge } (\subseteq \mathbb{R})$
- ▶ einfachster Fall: $\Omega = \{0, 1\}^k$
 $X_k = (\vec{x} \mapsto \vec{x}_k)$ (die k -te Komponente)
- ▶ dann Wsk-Raum bestimmt durch Wsk der Elementar-E.,
Bsp: $P(0, 0) = 1/3, P(0, 1) = 1/6, P(1, 0) = 0, P(1, 1) = 1/2$
- ▶ (Motivation für Bayes-Netz: beschreibt solchen Wsk-Raum durch deutlich weniger als 2^k Parameter)
- ▶ zu Zufallsgröße X betrachte Ereignis $X = e$,
Bsp (Fortsetzung): $P(X_1 = 0 \cap X_2 = 1) = 1/6$.
 $P(X_2 = 1) = 1/6 + 1/2 = 2/3, P(X_1 = 0) = \dots$
- ▶ Def. Zufallsgrößen X, Y sind unabhängig:
jedes $X = e$ ist unabhängig von jedem $Y = f$

Kausal-Diagramme

Kausal-Diagramm: DAG

- ▶ Knoten: Sachverhalte
- ▶ Kanten: (vermutete) kausale (ursächliche) Beziehungen

Beispiel:

- ▶ Knoten: Winter, glatt, Tom betrunken, Unfall Tom / Jerry

Verbindungsmuster:

- ▶ seriell: $W \rightarrow G \rightarrow U$
- ▶ teilend: $G \rightarrow T, G \rightarrow J$
- ▶ zusammenführend: $B \rightarrow T, G \rightarrow T$

Bayes-Netze: Motivation, Definition

- ▶ Bayes-Netz (alternativ: *believe network*) ist DAG
 - ▶ Knoten: Zufallsvariablen
 - ▶ Kanten: (vermutete) kausale (ursächliche) Beziehungen
- ▶ Anwendung: probabilistisches Schließen, Bestimmung wahrscheinlicher Ursachen für Symptome
- ▶ BN erfunden von Judea Pearl, erhielt (u.a.) dafür den *ACM Turing Award* 2011,
https://amturing.acm.org/award_winners/pearl_2658896.cfm
- ▶ benannt nach Thomas Bayes (1701–1761), Satz von Bayes über bedingte Wahrscheinlichkeiten

Definition Bayes-Netz

- ▶ Syntax: ein Bayes-Netz N ist ein Paar (G, Θ) mit
 - ▶ G ist DAG, Knoten sind Zufallsgrößen
 - ▶ Θ : für jeden Knoten X mit Eltern X_1, \dots, X_k :
Wahrscheinlichkeiten $P(X = e \mid X_1 = e_1 \cap \dots \cap X_k = e_k)$
für alle $[e, e_1, \dots, e_k] \in W^{k+1}$
- ▶ Semantik: N beschreibt Wahrscheinlichkeitsraum durch
$$P(X = e) = P(X = e \mid \dots X_k = e_k \dots) \cdot \prod_k P(X_k = e_k)$$

induktive Definition:

IA: Quellen des DAG (ohne Vorgänger, d.h., ohne Bedingungen, d.h., $\prod \emptyset = 1$)

Beispiel Bayes-Netz

(nach Judea Pearl)

- ▶ Knoten: Einbruch R , Erdbeben E , Alarmanlage A (zuhause), John ruft (auf Arbeit) an J , Mary ruft an M .
- ▶ Kanten mit Parametern (Bsp)
 - ▶ $P(R = 1) = 0.001, P(E = 1) = 0.002$
 - ▶ $P(A = 1 \mid R = 0, E = 1) = 0.29, \dots$

Graphische Darstellung: Tafel

Bedingte Unabhängigkeit und BN

- ▶ (Wdhlg.) Def A und B unabhängig, falls $P(A \cap B) = P(A) \cdot P(B)$.
- ▶ Def: A und B bedingt unabhängig bezüglich C :
 $P(A \cap B \mid C) = P(A \mid C) \cdot P(B \mid C)$.
(Vorstellung: wir schränken den Wsk-Raum ein auf die Elementar-Ereignisse aus C , verwenden dort die Standard-Def. der Unabh.)
- ▶ Def: bedingte Unabh. von (diskreten) Zufallsgrößen entsprechend
- ▶ Satz: für jedes BN N , für alle $X, Y \in N$ mit $X \not\rightarrow_N^* Y$:
 X und Y sind bedingt unabh. bezüglich der Eltern von X .

Inferenz mit BN

- ▶ die Diagnose-Aufgabe: gegeben ein BN, gesucht sind bedingte Wahrscheinlichkeiten der Ursache(n), unter der Bedingung von Beobachtungen
- ▶ Bsp: $P(\text{Einbruch} = 1 \mid \text{John} = 1 \cap \text{Mary} = 1)$
- ▶ Bsp: $P(\text{Einbruch} = 1 \mid \text{John} = 1 \cup \text{Mary} = 1)$
- ▶ kann exakt bestimmt werden, dauert jedoch $2^{|M|}$
kann nicht besser gehen, weil aussagenlogische Erfüllbarkeit auf dieses Inferenzproblem reduziert werden kann
- ▶ die Alternative sind schnellere (Simulations)Verfahren, die einen Näherungswert liefern

Reading Group KW

Judea Pearl (2018):
The Seven Tools of Causal Inference with Reflections on Machine Learning

https://ftp.cs.ucla.edu/pub/stat_ser/r481.pdf