

# Probabilistic Relational Models

## Seminarvortrag



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

Alexander Galitzki  
galickis@gmail.com

Darmstadt, den 2. Dezember 2009

Was wir in dieser Präsentation kennen lernen:

- ▶ den **Formalismus** und seine Motivation,
- ▶ verschiedene **Arten** von PRMs,
- ▶ die exakte und approximative **Inferenz**,
- ▶ die **Lernalgorithmen**.

- ▶ Versuch, Bayes'sche Netze um Elemente der Prädikatenlogik zu erweitern
- ▶ Wahrscheinlichkeitsrechnung auf beliebigen Aussagen schwierig:

$$P(\phi) = \sum_{M: \phi \text{ wahr in } M} \mu(M)$$

( $\phi$  – eine prädikatenlogische Aussage,  $\mu$  – Wahrscheinlichkeit in einer Welt  $M$ )

- ▶ Benötigt ist eine Sprache, die:
  1. nur eine endliche Anzahl von Modellen zulässt und
  2. eine konsistente Wahrscheinlichkeitsverteilung ermöglicht.

# Definition

## Komponenten eines relationalen Schemas



- ▶ Klassenmengen  $\mathcal{X} = \{X_1, \dots, X_n\}$ ,
- ▶ Für jede Klasse  $X \in \mathcal{X}$ : Menge der Attribute  $\mathcal{A}(X)$  mit Wertebereich  $\mathcal{V}(X.A)$  für jedes Attribut  $A \in \mathcal{A}(X)$ ,
- ▶ Für jede Klasse  $X \in \mathcal{X}$ : Menge der Referenz-Slots  $\rho_i$  mit Definitionsbereich  $X$  und Bildbereich  $Y \in \mathcal{X}$ .
- ▶ Ein inverser Slot  $\rho^{-1}$  ist die inverse Funktion von  $\rho$ .
- ▶ Eine Slot-Kette  $\rho_1, \dots, \rho_k$  ist eine Abfolge von (ggf. inversen) Slots, so dass für alle  $i$  gilt:  $\rho_i$  bildet auf den Definitionsbereich von  $\rho_{i+1}$  ab.
- ▶ Eine Instanz  $\mathcal{I}$  gibt für jede Klasse  $X$  die Menge der Objekte der Klasse  $\mathcal{I}(X)$ .

# Definition

## Komponenten eines relationalen Schemas



- ▶ Klassenmengen  $\mathcal{X} = \{X_1, \dots, X_n\}$ ,
- ▶ Für jede Klasse  $X \in \mathcal{X}$ : Menge der Attribute  $\mathcal{A}(X)$  mit Wertebereich  $\mathcal{V}(X.A)$  für jedes Attribut  $A \in \mathcal{A}(X)$ ,
- ▶ Für jede Klasse  $X \in \mathcal{X}$ : Menge der Referenz-Slots  $\rho_i$  mit Definitionsbereich  $X$  und Bildbereich  $Y \in \mathcal{X}$ .
- ▶ Ein inverser Slot  $\rho^{-1}$  ist die inverse Funktion von  $\rho$ .
- ▶ Eine Slot-Kette  $\rho_1, \dots, \rho_k$  ist eine Abfolge von (ggf. inversen) Slots, so dass für alle  $i$  gilt:  $\rho_i$  bildet auf den Definitionsbereich von  $\rho_{i+1}$  ab.
- ▶ Eine Instanz  $\mathcal{I}$  gibt für jede Klasse  $X$  die Menge der Objekte der Klasse  $\mathcal{I}(X)$ .


# Definition

## Komponenten eines relationalen Schemas




- ▶ Klassenmengen  $\mathcal{X} = \{X_1, \dots, X_n\}$ ,
- ▶ Für jede Klasse  $X \in \mathcal{X}$ : Menge der Attribute  $\mathcal{A}(X)$  mit Wertebereich  $\mathcal{V}(X.A)$  für jedes Attribut  $A \in \mathcal{A}(X)$ ,
- ▶ Für jede Klasse  $X \in \mathcal{X}$ : Menge der Referenz-Slots  $\rho_i$  mit Definitionsbereich  $X$  und Bildbereich  $Y \in \mathcal{X}$ .
- ▶ Ein inverser Slot  $\rho^{-1}$  ist die inverse Funktion von  $\rho$ .
- ▶ Eine Slot-Kette  $\rho_1, \dots, \rho_k$  ist eine Abfolge von (ggf. inversen) Slots, so dass für alle  $i$  gilt:  $\rho_i$  bildet auf den Definitionsbereich von  $\rho_{i+1}$  ab.
- ▶ Eine Instanz  $\mathcal{I}$  gibt für jede Klasse  $X$  die Menge der Objekte der Klasse  $\mathcal{I}(X)$ .


# Beispielschema



# Abhängigkeiten im Beispielschema



# Abhängigkeiten im Beispielschema



# Definition

## Probabilistisches Modell



Ein PRM  $\Pi$  für ein relationales Schema definiert sich wie folgt. Für jede Klasse  $X \in \mathcal{X}$  und jedes beschreibende Attribut  $A \in \mathcal{A}(X)$  gibt es:

- ▶ eine Menge der Eltern  $Pa(X.A) = \{U_1, \dots, U_l\}$ , wobei  $U_j$  die Form  $X.B$  oder  $\gamma(X.K.B)$  hat,  $K$  eine Slot-Kette und  $\gamma$  eine Aggregatfunktion von  $X.K.B$  ist;
- ▶ eine gültige bedingte Wahrscheinlichkeitsverteilung  $P(X.A|Pa(X.A))$ .


Ein relationales Gerüst  $\sigma$  gibt die Menge der Objekte  $\sigma(X_i)$  für jede Klasse an sowie die Relationen zwischen diesen Objekten, nicht jedoch die Attributwerte.

Ein PRM  $\Pi$  zusammen mit einem relationalen Gerüst  $\sigma$  definieren ein Bayes'sches Netz mit Knoten für alle Attribute bzw. Aggregate und Kanten für alle Abhängigkeiten.

$$\begin{aligned} P(\mathcal{I}|\sigma, \mathcal{S}, \theta_{\mathcal{S}}) &= \prod_{x \in \sigma} \prod_{A \in \mathcal{A}(x)} P(\mathcal{I}_{x.A} | \mathcal{I}_{Pa(x.A)}) \\ &= \prod_{X_i} \prod_{A \in \mathcal{A}(X_i)} \prod_{x \in \sigma(X_i)} P(\mathcal{I}_{x.A} | \mathcal{I}_{Pa(x.A)}) \end{aligned}$$


- ▶ Eine Instanz besteht aus endlich vielen Objekten (1)
- ▶ Aber: keine Garantie, dass  $P(\mathcal{I}|\sigma, \mathcal{S}, \theta_S)$  eine Dichtefunktion ist. (2)
- ▶ Abhängigkeiten dürfen nicht zyklisch sein.
- ▶ Einführung von Abhängigkeitsgraphen:
  - ▶ für Instanzen (Zyklenfreiheit garantiert Kohärenz für *diese* Instanz)
  - ▶ für Klassenabhängigkeiten (Zyklenfreiheit garantiert Kohärenz für *alle* Instanzen)

# Graph der Klassenabhängigkeiten




## ▶ PRM mit struktureller Unsicherheit:

- ▶ Referenzielle Unsicherheit  
(Belegung der Referenz-Slots unbekannt)
- ▶ Existenzielle Unsicherheit  
(Existenz einiger Objekte unbekannt)




## ▶ PRM mit Klassenhierarchie

- ▶ PRM mit struktureller Unsicherheit:
  - ▶ Referenzielle Unsicherheit (Belegung der Referenz-Slots unbekannt)
  - ▶ Existenzielle Unsicherheit (Existenz einiger Objekte unbekannt)
- ▶ PRM mit Klassenhierarchie



## ► PRM mit struktureller Unsicherheit:

- Referenzielle Unsicherheit  
(Belegung der Referenz-Slots  
unbekannt)
- Existenzielle Unsicherheit  
(Existenz einiger Objekte  
unbekannt)




## ► PRM mit Klassenhierarchie

► PRM mit struktureller Unsicherheit:

- Referenzielle Unsicherheit  
(Belegung der Referenz-Slots unbekannt)
- Existenzielle Unsicherheit  
(Existenz einiger Objekte unbekannt)

► PRM mit Klassenhierarchie





- ▶ **Exakt** Ausnutzung der speziellen Struktur:
  - ▶ Dekomposition,
  - ▶ Wiederverwendung der Parameter.
  
- ▶ **Approximativ** Belief-Propagation-Algorithmus.
  - ▶ Idee: Benachbarte Knoten tauschen Informationen aus.
  - ▶ Konvergenz nur auf einfach zusammenhängenden Graphen
  - ▶ Sonst: kann konvergieren und dann gute Annäherung liefern

Log-Likelihood-Funktion gegeben ein Relationsgerüst  $\sigma$ , eine Abhängigkeitsstruktur  $\mathcal{S}$ , eine Instanz  $\mathcal{I}$ :

$$\begin{aligned}\log L(\theta_{\mathcal{S}}|\mathcal{I}, \sigma, \mathcal{S}) &= \log P(\mathcal{I}|\mathcal{S}, \sigma, \theta_{\mathcal{S}}) \\ &= \sum_{X_i} \sum_{A \in \mathcal{A}(X_i)} \left[ \sum_{x \in \sigma(X_i)} \log P(\mathcal{I}_{x.A}|\mathcal{I}_{Pa(x.A)}) \right] \\ &= \sum_{X_i} \sum_{A \in \mathcal{A}(X_i)} \sum_{v \in \mathcal{V}(X.A)} \sum_{\mathbf{u} \in \mathcal{V}(Pa X.A)} C_{X.A}[v, \mathbf{u}] \cdot \log \theta_{v|\mathbf{u}},\end{aligned}$$

wobei  $C_{X.A}[v, \mathbf{u}]$  die Anzahl der Beobachtungen von  $\mathcal{I}_{x.A} = v$  und  $\mathcal{I}_{Pa(x.A)} = \mathbf{u}$  ist.

$C_{X.A}[v, \mathbf{u}]$  können mittels SQL-Anfragen berechnet werden:

```
SELECT grade, intelligence, difficulty, COUNT(*)  
FROM registration, student, course  
GROUP BY grade, intelligence, difficulty
```

$C_{X.A}[v, \mathbf{u}]$  sind *suffiziente Statistiken* für die Parameter  $\theta_S$ .



Wichtige Aspekte:


- I. Prüfung der Abhängigkeitsstrukturen auf Zulässigkeit
- II. Bewertung der Kandidaten
- III. Effizienz des Suchverfahrens

# Strukturlernen (I)

## Zulässige Strukturen



- ▶ Konstruktion eines Abhängigkeitsgraphen
- ▶ Nach dem Hinzufügen der Kante  $(u, v)$  prüfen, ob ein Weg von  $v$  nach  $u$  existiert
- ▶ Komplexität mit Tiefensuche:  $O(|V| + |E|)$





Bewertung einer Struktur  $\mathcal{S}$  gegeben eine Instanz  $\mathcal{I}$  und ein Gerüst  $\sigma$ :

$$P(\mathcal{S}|\mathcal{I}, \sigma) \propto P(\mathcal{I}|\mathcal{S}, \sigma)P(\mathcal{S}|\sigma)$$

$P(\mathcal{S}|\sigma) = P(\mathcal{S})$ , wobei lange Slot-Ketten penalisiert werden.

$P(\mathcal{I}|\mathcal{S}, \sigma) = \int P(\mathcal{I}|\mathcal{S}, \theta_{\mathcal{S}}, \sigma)P(\theta_{\mathcal{S}}|\mathcal{S}) d\theta_{\mathcal{S}}$  kann bei bestimmten Verteilungsannahmen in geschlossener Form dargestellt werden.



- ▶ Lokale Suche im Raum der zulässigen Strukturen
- ▶ Lernen in Bayes-Netzen NP-schwer, daher kein effizientes Verfahren möglich
- ▶ Übergangsoperationen: *add edge*, *delete edge*, *reverse edge*.
- ▶ Verbesserungen: random restart, tabulist, simulated annealing etc.



- ▶ PRMs erweitern Bayes'sche Netze um prädikatenlogische Elemente.
- ▶ PRMs erweitern relationale Schemata um probabilistische Elemente.
- ▶ Mit den Erweiterungen (strukturelle Unsicherheit, Klassenhierarchie) kann man weitere Zusammenhänge in den Daten modellieren.
- ▶ Ein PRM kann direkt aus einer relationalen Datenbank gelernt werden.