

Untersuchungen zum Inferenzschutz von fragmentierten Speicherungen von Datenbankinstanzen

Marcel Preuß

Lehrstuhl Informatik 6

Technische Universität Dortmund

23. November 2010

Ein kurzer Überblick

Vertraulichkeit durch Fragmentierung

- Grundlagen zur Fragmentierung

- Fragmentierung und partielle lokale Verwaltung

Inferenzsicherheit der fragmentierten Speicherung

- Vorgehensweise für Untersuchungen zur Inferenzsicherheit

- Wahl des logischen Systems

- Logik-orientierte Modellierung der (fragm.) Relationeninstanz

- Inferenzsicherheit unter Funktionalen Abhängigkeiten

Vertraulichkeit durch Fragmentierung

Wieso Fragmentierung?

Oft: Nur Assoziationen zwischen Informations-Aspekten sensibel

Beispiel: Welcher Patient wegen welcher Krankheit behandelt?

- ▶ Behandelte Krankheiten \rightsquigarrow komplett unspannend
- ▶ Behandelte Patienten \rightsquigarrow bedingt sensibel
- ▶ Assoziation: Patient und Krankheit \rightarrow hochgradig sensibel

Grundsätzliche Idee der Fragmentierung

Ziel: Sensible Assoziationen durch Fragmentierung aufbrechen

- ▶ Betrachte Relationeninstanz r zu Schema $\langle R|A_R| \rangle$
- ▶ Attributmenge A_R in Teilmengen zerlegen
 - ▶ Fragmentierung $\mathcal{F} = \{\langle F_1|A_{F_1}|SC_{F_1}\rangle, \dots, \langle F_n|A_{F_n}|SC_{F_n}\rangle\}$
 - ▶ Fragment $\langle F_i|A_{F_i}|SC_{F_i}\rangle$ ist Relationenschema mit $A_{F_i} \subseteq A_R$
- ▶ Bilde Projektionen von r gemäß der Fragmente
→ sogenannte Fragment-Instanzen f_1, f_2, \dots, f_n

Beispiel-Instanz

| <i>Patient</i> | <u>SSN</u> | Name | Geburtstag | Plz | Krankheit | Arzt |
|----------------|------------|----------|------------|-------|----------------|--------|
| | 12345 | Hellmann | 03.01.1981 | 94142 | Bluthochdruck | White |
| | 98765 | Dooley | 07.10.1953 | 94141 | Fettleibigkeit | Warren |
| | 24689 | McKinley | 12.02.1952 | 94139 | Bluthochdruck | White |
| | 13579 | Ripley | 03.01.1981 | 94139 | Fettleibigkeit | Warren |

Abbildung: Instanz *patient* zu Schema *Patient*

Was fällt auf?

- ▶ Attribut SSN ist Primärschlüssel
- ▶ sensible Assoziationen enthalten

Fragmentierung der Beispiel-Instanz

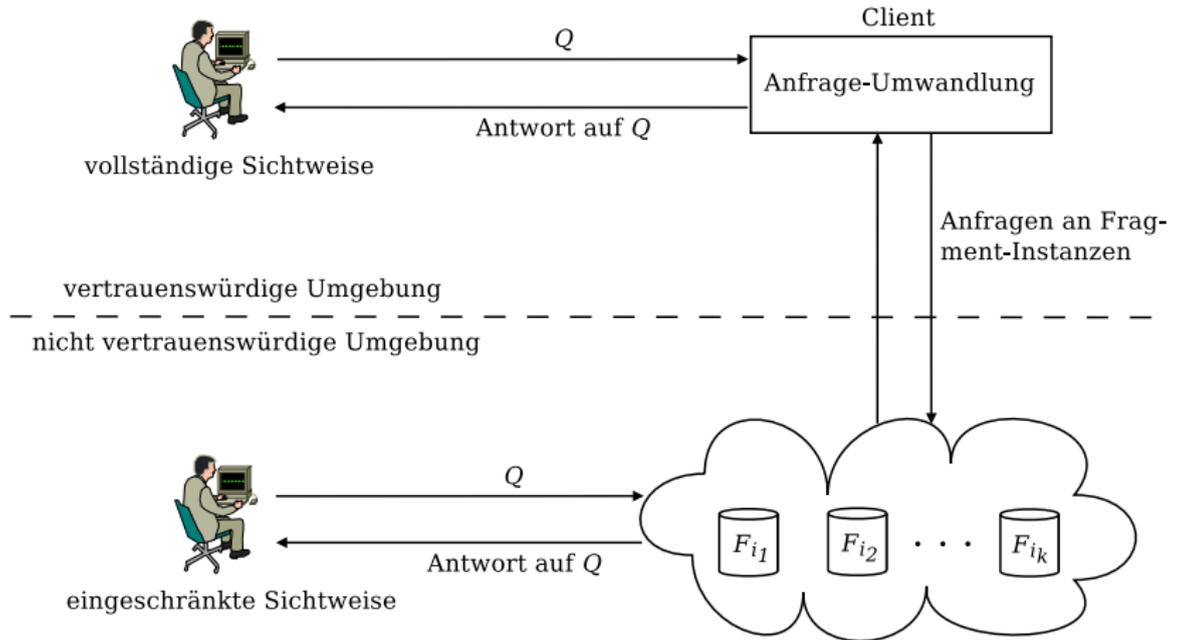
| F_1 | Name | F_2 | Geburtstag | Plz | F_3 | Krankheit | Arzt |
|-------|----------|-------|------------|-------|-------|----------------|--------|
| | Hellmann | | 03.01.1981 | 94142 | | Bluthochdruck | White |
| | Dooley | | 07.10.1953 | 94141 | | Fettleibigkeit | Warren |
| | McKinley | | 12.02.1952 | 94139 | | | |
| | Ripley | | 03.01.1981 | 94139 | | | |

Abbildung: Mögliche Fragment-Instanzen f_1 , f_2 und f_3 von *patient*

Was fällt auf?

- ▶ Primärschlüssel SSN in keinem Fragment enthalten
- ▶ sensible Assoziationen aufgebrochen

Konzept: Vertraulichkeit durch Fragmentierung



Ein konkreter Fragmentierungs-Ansatz

Konkreter Ansatz: Fragmentierung und partielle lokale Verwaltung

Getroffene Annahmen:

- ▶ Externe Server nicht vertrauenswürdig, aber ehrlich
- ▶ Client ist vollkommen vertrauenswürdig
- ▶ Client bietet (begrenzten) lokalen Speicherplatz
- ▶ lokale Verwaltung von Daten teurer als externe Verwaltung
→ bevorzugt externen Speicher nutzen

Aufbau der Fragmentierung

Zu den Annahmen passende Fragmentierung?

- ▶ Zwei Fragmente $\langle F_o | A_{F_o} | SC_{F_o} \rangle$ und $\langle F_s | A_{F_s} | SC_{F_s} \rangle$
 - ▶ Instanzen zu F_o ausschließlich lokal verwalten
 - ▶ Instanzen zu F_s können extern gespeichert werden
- ▶ Jedes Attribut in mindestens einem Fragment enthalten
- ▶ Rekonstruktion der ursprünglichen Instanz über Tupel-IDs
→ als Primärschlüssel in SC_{F_o} und SC_{F_s} vereinbart

Beispiel-Fragmentierung

| F_o | <u>tid</u> | SSN | Name | Geburtstag |
|-------|------------|-------|----------|------------|
| | 1 | 12345 | Hellmann | 03.01.1981 |
| | 2 | 98765 | Dooley | 07.10.1953 |
| | 3 | 24689 | McKinley | 12.02.1952 |
| | 4 | 13579 | Ripley | 03.01.1981 |

| F_s | <u>tid</u> | Plz | Krankheit | Arzt |
|-------|------------|-------|----------------|--------|
| | 1 | 94142 | Bluthochdruck | White |
| | 2 | 94141 | Fettleibigkeit | Warren |
| | 3 | 94139 | Bluthochdruck | White |
| | 4 | 94139 | Fettleibigkeit | Warren |

Abbildung: Fragmentierung von *patient* bei partieller lokaler Verwaltung

Definition von Vertraulichkeits-Anforderungen

Wie Vertraulichkeits-Anforderungen **formal** definieren?

Idee: Vertraulichkeits-Constraints

- ▶ $\langle R|A_R| \rangle$ sei gegebenes Relationenschema
- ▶ Vertraulichkeits-Constraint c ist Teilmenge $c \subseteq A_R$
- ▶ Vertraulichkeits-Constraint c heißt
 - ▶ einfach, falls $|c| = 1$
 - ▶ assoziierend, falls $|c| > 1$

Semantik von Vertraulichkeits-Constraints

Gegeben sei:

- ▶ Relationenschema $\langle R | A_R | \ \rangle$
- ▶ Menge \mathcal{C} von Vertraulichkeits-Constraints,
- ▶ Fragmentierung $\mathcal{F} = \{ \langle F_o | A_{F_o} | SC_{F_o} \rangle, \langle F_s | A_{F_s} | SC_{F_s} \rangle \}$ zu R

\mathcal{F} heißt korrekt bezüglich $\mathcal{C} \iff$ für jedes $c \in \mathcal{C}$ gilt: $c \not\subseteq A_{F_s}$

Beispiel: Vertraulichkeits-Constraints

$$c_0 = \{\text{SSN}\}$$

$$c_1 = \{\text{Name, Geburtstag}\}$$

$$c_2 = \{\text{Name, Plz}\}$$

$$c_3 = \{\text{Name, Krankheit}\}$$

$$c_4 = \{\text{Name, Arzt}\}$$

$$c_5 = \{\text{Geburtstag, Plz, Krankheit}\}$$

$$c_6 = \{\text{Geburtstag, Plz, Arzt}\}$$

Abbildung: Menge \mathcal{C} von Vertraulichkeits-Constraints für *Patient*

Beispiel-Fragmentierung, korrekt bezüglich \mathcal{C}

| F_o | <u>tid</u> | SSN | Name | Geburtstag |
|-------|------------|-------|----------|------------|
| | 1 | 12345 | Hellmann | 03.01.1981 |
| | 2 | 98765 | Dooley | 07.10.1953 |
| | 3 | 24689 | McKinley | 12.02.1952 |
| | 4 | 13579 | Ripley | 03.01.1981 |

| F_s | <u>tid</u> | Plz | Krankheit | Arzt |
|-------|------------|-------|----------------|--------|
| | 1 | 94142 | Bluthochdruck | White |
| | 2 | 94141 | Fettleibigkeit | Warren |
| | 3 | 94139 | Bluthochdruck | White |
| | 4 | 94139 | Fettleibigkeit | Warren |

Abbildung: Fragmentierung von *patient* bei partieller lokaler Verwaltung

Inferenzsicherheit der fragmentierten Speicherung

Vorgehensweise für Untersuchungen zur Inferenzsicherheit

- ▶ CQE ist als inferenzsicher nachgewiesen
- ▶ Formalisiere Fragmentierung im CQE-Framework
 - ▶ Logisches System wählen
 - ▶ Logik-orientierte Modellierung der (fragmentierten) Relationeninstanz
 - ▶ Logik-orientierte Modellierung der Vertraulichkeits-Politik
- ▶ Formuliere formale Beweise zur Inferenzsicherheit
 - ▶ Annahmen zu potentiellen Angreifern
 - ▶ Annahmen zum Vorwissen von potentiellen Angreifern

Logisches System des CQE-Framework: Syntax

Syntax des verwendeten logischen Systems (\rightarrow Sprache \mathcal{L})

- ▶ Prädikatenlogik 1. Ordnung mit Gleichheit
 - ▶ Prädikatensymbol R mit Stelligkeit $|A_R|$
 - ▶ ausgezeichnetes (binäres) Prädikatensymbol $=$
 - ▶ unendlich große, feste Domäne Dom
 \rightarrow Konstantenzeichen des DB-Schemas
 - ▶ unendlich große Variablen-Menge $Var := \{X_1, X_2, \dots\}$
- ▶ in einer Formel $R(t_1, \dots, t_{|A_R|})$ ist t_i Konstante oder Variable
- ▶ nur geschlossene Formeln konstruierbar
 \rightarrow ausschließlich quantifizierte Variablen (\forall, \exists)

Logisches System des CQE-Framework: Semantik

Eine Interpretation \mathcal{I} für \mathcal{L} ist eine DB-Interpretation \Leftrightarrow

- ▶ Universum $\mathcal{U} = \text{Domäne } Dom$
- ▶ für alle $v \in Dom$ gilt: $\mathcal{I}(v) = v$
- ▶ für R gilt: $\mathcal{I}(R) \subset \underbrace{\mathcal{U} \times \dots \times \mathcal{U}}_{|A_R| \text{ mal}}$ ist endlich groß
- ▶ für $=$ gilt: $\mathcal{I}(=) = \{(v, v) \mid v \in \mathcal{U}\}$

\mathcal{I} kann als vollständige Datenbankinstanz aufgefasst werden!

Sichtweise auf Fragment-Instanz f_s

- ▶ Annahme: ursprüngliche DB zwar vollständig
- ▶ Aber: A_R nicht komplett in $\langle F_s | A_{F_s} | SC_{F_s} \rangle$ enthalten
- ▶ Sichtweise: Fragment-Instanz f_s als Teil von r
→ Werte zu A_{F_s} bekannt, Werte zu $A_R \setminus A_{F_s}$ unbekannt

Noch einmal graphisch verdeutlicht

| R | a_1 | a_2 | a_3 |
|-----|--------------|--------------|--------------|
| | $\mu_1[a_1]$ | $\mu_1[a_2]$ | $\mu_1[a_3]$ |
| | $\mu_2[a_1]$ | $\mu_2[a_2]$ | $\mu_2[a_3]$ |
| | $\mu_3[a_1]$ | $\mu_3[a_2]$ | $\mu_3[a_3]$ |

| F | a_1 | a_2 |
|-----|--------------|--------------|
| | $\mu_1[a_1]$ | $\mu_1[a_2]$ |
| | $\mu_2[a_1]$ | $\mu_2[a_2]$ |
| | $\mu_3[a_1]$ | $\mu_3[a_2]$ |

(a) Ursprüngliche Instanz r

(b) Fragment-Instanz f

| $R(F)$ | a_1 | a_2 | a_3 |
|--------|--------------|--------------|-------|
| | $\mu_1[a_1]$ | $\mu_1[a_2]$ | ? |
| | $\mu_2[a_1]$ | $\mu_2[a_2]$ | ? |
| | $\mu_3[a_1]$ | $\mu_3[a_2]$ | ? |

(c) f im Kontext von r

Modellieren der ursprünglichen Instanz: Positives Wissen

Gegeben sei:

- ▶ ursprüngliche Relationeninstanz r
- ▶ Relationenschema $\langle R | A_R | \rangle$ mit $A_R = \{a_1, \dots, a_{|A_R|}\}$

Positives Wissen aus r in \mathcal{L} :

$$db_r^+ := \left\{ R(v_1, \dots, v_{|A_R|}) \mid \exists \mu \in r : \bigwedge_{i=1}^{|A_R|} \mu[a_i] = v_i \right\}$$

Positives Wissen: Beispielhafte Modellierung

| <i>Person</i> | Name | Geburtstag | Plz |
|---------------|-------------|-------------------|------------|
| | Hellmann | 03.01.1981 | 94142 |
| | McKinley | 12.02.1952 | 94139 |
| | Ripley | 03.01.1981 | 94139 |

$$db_{person}^+ = \{ \textit{Person}(\textit{Hellmann}, 03.01.1981, 94142), \\ \textit{Person}(\textit{McKinley}, 12.02.1952, 94139), \\ \textit{Person}(\textit{Ripley}, 03.01.1981, 94139) \}$$

Vollständigkeit der Datenbankinstanz

Problem: Ein potentieller Angreifer weiß aber noch mehr

- ▶ Ursprüngliche Instanz r als vollständig angenommen
- ▶ jede nicht aufgezählte Wertekombination gilt auch nicht in r
→ Wissen der Form $\neg R(v_1, \dots, v_{|A_R|})$
- ▶ Problem: Domäne unendlich groß → nicht explizit aufzählbar
- ▶ Rettende Idee: Completeness-Sentence

Modellieren der ursprünglichen Instanz: Negatives Wissen

Erstmal beispielhaft:

$$\begin{aligned}
 & (\forall X_N)(\forall X_G)(\forall X_P) [\\
 & (X_N = \text{Hellmann} \wedge X_G = 03.01.1981 \wedge X_P = 94142) \vee \\
 & (X_N = \text{McKinley} \wedge X_G = 12.02.1952 \wedge X_P = 94139) \vee \\
 & (X_N = \text{Ripley} \wedge X_G = 03.01.1981 \wedge X_P = 94139) \vee \\
 & \neg \text{Person}(X_N, X_G, X_P) \quad]
 \end{aligned}$$

Und jetzt formal als Completeness-Sentence in db_r^- :

$$(\forall X_1) \dots (\forall X_{|A_R|}) \left[\bigvee_{\mu \in r} \left(\bigwedge_{j=1}^{|A_R|} (X_j = \mu[a_j]) \right) \vee \neg R(X_1, \dots, X_{|A_R|}) \right]$$

Logik-orientierte Modellierung von r

Damit: Prädikatenlogische Modellierung von r klar

$$db_r := db_r^+ \cup db_r^-$$

Aber: Potentieller Angreifer kennt nur Fragment f_s

→ Modelliere f_s in Framework für r

Neue (kleinere) Beispiel-Instanz

| <i>Person</i> | Name | Geburtstag | Plz |
|---------------|-------------|-------------------|------------|
| | Hellmann | 03.01.1981 | 94142 |
| | McKinley | 12.02.1952 | 94139 |
| | Ripley | 03.01.1981 | 94139 |

Abbildung: Instanz *person* zum Relationen-Schema *Person*

Menge \mathcal{C} von Vertraulichkeits-Constraints für Schema *Person*

- ▶ $c_0 = \{Name, Geburtstag\}$
- ▶ $c_1 = \{Name, Plz\}$

Fragmentierung der neuen Beispiel-Instanz

| F_o | <u>tid</u> | Name | F_s | <u>tid</u> | Geburtstag | Plz |
|-------|------------|----------|-------|------------|------------|-------|
| | 1 | Hellmann | | 1 | 03.01.1981 | 94142 |
| | 2 | McKinley | | 2 | 12.02.1952 | 94139 |
| | 3 | Ripley | | 3 | 03.01.1981 | 94139 |

Abbildung: Mögliche Fragment-Instanzen f_o und f_s zu *person*

Positives Wissen aus f_s : Grundsätzliche Ideen

Potentieller Angreifer kennt $\langle F_s | A_{F_s} | SC_{F_s} \rangle$ und $\langle R | A_R | \quad \rangle$
→ er weiß: Werte zu $A_R \setminus A_{F_s}$ werden ihm vorenthalten

Rückschlüsse von f_s auf r über positives Wissen

- ▶ f_s entspricht (bis auf tid) Projektion von r auf A_{F_s}
- ▶ Also: für $\mu \in f_s$ existiert (genau) ein $\nu \in r$ mit $\nu \upharpoonright A_{F_s} = \mu \upharpoonright A_{F_s}$

Modellieren der Fragment-Instanz f_s : Positives Wissen

Angreifer kennt Werte für $A_{F_s} = \{a_{i_1}, \dots, a_{i_k}\} \subseteq \{a_1, \dots, a_{|A_R|}\}$

Bilde Index-Mengen für (un)bekannte Attribut-Werte

- ▶ $\text{Ind}_{F_s}^+ = \{i_1, \dots, i_k\}$
- ▶ $\text{Ind}_{F_s}^- = \{1, \dots, |A_R|\} \setminus \{i_1, \dots, i_k\} = \{i_{k+1}, \dots, i_{|A_R|}\}$

Konstruktion von $db_{f_s}^+$:

- ▶ $\forall \mu \in f_s$: füge $(\exists X_{i_{k+1}}) \dots (\exists X_{i_{|A_R|}}) R(t_1, \dots, t_{|A_R|})$ hinzu
- ▶ Dabei gilt für $j \in \{1, \dots, |A_R|\}$:
 - ▶ falls $j \in \text{Ind}_{F_s}^+$: $t_j = \mu[a_j]$
 - ▶ falls $j \in \text{Ind}_{F_s}^-$: $t_j = X_j$

Positives Wissen: Beispielhafte Modellierung

| F_s | <u>tid</u> | Geburtstag | Plz |
|-------|------------|------------|-------|
| | 1 | 03.01.1981 | 94142 |
| | 2 | 12.02.1952 | 94139 |
| | 3 | 03.01.1981 | 94139 |

$$db_{f_s}^+ = \{ \begin{array}{l} (\exists X_N) \textit{Person}(X_N, 03.01.1981, 94142), \\ (\exists X_N) \textit{Person}(X_N, 12.02.1952, 94139), \\ (\exists X_N) \textit{Person}(X_N, 03.01.1981, 94139) \end{array} \}$$

Altbekanntes Problem: negatives Wissen

Problem: User weiß noch mehr

- ▶ Datenbankinstanz als vollständig angenommen
- ▶ für $\mu \notin f_s$: **kein** Tupel ν mit $\nu \upharpoonright A_{F_s} = \mu$ in r
→ Wissen der Form $(\forall X_{i_{k+1}}) \dots (\forall X_{i_{|A_R|}}) \neg R(t_1, \dots, t_{|A_R|})$
- ▶ altes Problem: unendliche große Domäne Dom
- ▶ alter Bekannter: Completeness-Sentence

Modellieren der Fragment-Instanz f_s : Negatives Wissen

Zur Erinnerung:

- ▶ $\text{Ind}_{F_s}^+ = \{i_1, \dots, i_k\}$
- ▶ $\text{Ind}_{F_s}^- = \{1, \dots, |A_R|\} \setminus \{i_1, \dots, i_k\} = \{i_{k+1}, \dots, i_{|A_R|}\}$

Modifizierter Completeness-Sentence für $db_{f_s}^-$:

$$(\forall X_1) \dots (\forall X_{|A_R|}) \left[\bigvee_{\mu \in f_s} \left(\bigwedge_{j \in \text{Ind}_{F_s}^+} (X_j = \mu[a_j]) \right) \vee \neg R(X_1, \dots, X_{|A_R|}) \right]$$

Negatives Wissen: Beispielhafte Modellierung

| F_s | <u>tid</u> | Geburtstag | Plz |
|-------|------------|------------|-------|
| | 1 | 03.01.1981 | 94142 |
| | 2 | 12.02.1952 | 94139 |
| | 3 | 03.01.1981 | 94139 |

$$\begin{aligned}
 & (\forall X_N)(\forall X_G)(\forall X_P) [\\
 & (X_G = 03.01.1981 \wedge X_P = 94142) \vee \\
 & (X_G = 12.02.1952 \wedge X_P = 94139) \vee \\
 & (X_G = 03.01.1981 \wedge X_P = 94139) \vee \\
 & \neg Person(X_N, X_G, X_P) \\
 &]
 \end{aligned}$$

Wahl des Typs der Vertraulichkeits-Politik

Vertraulichkeits-Politik als Potential Secrets modellieren

- ▶ Annahme zum Ziel von Vertraulichkeits-Constraints:
existierende Werte bzw. Assoziationen schützen
- ▶ modellieren als Potential Secrets $pot_sec(\mathcal{C})$
 - ▶ falls Ψ_i wahr in DB: Benutzer darf dies *nicht* erfahren
 - ▶ sonst: Benutzer darf dies erfahren
- ▶ Annahme: Potentielle Angreifer kennen \mathcal{C} bzw. $pot_sec(\mathcal{C})$

Überlegungen zur Modellierung der Vertraulichkeits-Politik

Grundsätzliche Idee:

- ▶ Betrachte Constraint $c_i = \{a_{i_1}, \dots, a_{i_k}\}$
- ▶ alle Kombinationen zugehöriger Werte schützen
- ▶ alle Kombinationen als Potential Secrets definieren
- ▶ leider unendlich viele wegen $|Dom| = \infty$
- ▶ benutze **freie** Variablen X_{i_1}, \dots, X_{i_k} für a_{i_1}, \dots, a_{i_k}
→ endlich große Repräsentation

Logik-orientierte Modellierung der Vertraulichkeits-Politik

Betrachte Vertraulichkeits-Constraint $c_i = \{a_{i_1}, \dots, a_{i_k}\}$ aus \mathcal{C}

- ▶ $\text{Ind}_{c_i}^+ = \{i_1, \dots, i_k\}$
- ▶ $\text{Ind}_{c_i}^- = \{1, \dots, |A_R|\} \setminus \{i_1, \dots, i_k\} = \{i_{k+1}, \dots, i_{|A_R|}\}$

Konstruktion von $\text{pot_sec}(\mathcal{C})$

- ▶ $\forall c_i \in \mathcal{C}$: konstruiere

$$\Psi_i(\mathbf{X}_i) = (\exists X_{i_{k+1}}) \dots (\exists X_{i_{|A_R|}}) R(X_1, \dots, X_{|A_R|})$$

- ▶ Dabei gilt für $j \in \{1, \dots, |A_R|\}$:
 - ▶ falls $j \in \text{Ind}_{c_i}^+$: X_j ist freie Variable
 - ▶ falls $j \in \text{Ind}_{c_i}^-$: X_j ist gebundene Variable
- ▶ $\mathbf{X}_i = (X_{i_1}, \dots, X_{i_k})$ ist Vektor der freien Variablen

Expansion der Vertraulichkeits-Politik

Gegeben: $\Psi_i(\mathbf{X}_i)$ mit $\mathbf{X}_i = (X_{i_1}, \dots, X_{i_k})$

Konstruiere $\text{ex}(\Psi_i(\mathbf{X}_i))$:

- ▶ bilde jede Konstantenkombination $\mathbf{v}_i = (v_{i_1}, \dots, v_{i_k})$
- ▶ bilde Formel $\Psi_i(\mathbf{v}_i) \in \text{ex}(\Psi_i(\mathbf{X}_i))$

Expansion für $\text{pot_sec}(\mathcal{C})$:

$$\text{ex}(\text{pot_sec}(\mathcal{C})) := \bigcup_{\Psi(\mathbf{X}) \in \text{pot_sec}(\mathcal{C})} \text{ex}(\Psi(\mathbf{X}))$$

Vernachlässigtes Vorwissen

Jetzt bekannt: Modellierung der Sichtweise eines potentiellen Angreifers auf eine fragmentierte DB-Instanz

Aber: Potentielle Angreifer können auch Vorwissen haben
→ Vorwissen + DB-Wissen \rightsquigarrow Inferenzen?

In CQE: Vorwissen explizit durch $prior \subset \mathcal{L}$ modelliert

Bisherige Resultate

Resultate zur Inferenzsicherheit laut Diplomarbeit:

- ▶ **inferenzsicher**, wenn $prior = \emptyset$
- ▶ **nicht inferenzsicher**, wenn Vorwissen „beliebig“,
aber: $\forall \Psi(\mathbf{v}) \in \text{ex}(pot_sec(C)) : prior \not\equiv_{DB} \Psi(\mathbf{v})$
- ▶ **inferenzsicher** unter eingeschränkten Funktionalen Abh. (FDs)

Ziel: „Spielraum“ für Vorwissen erweitern!

Neues Resultat: Inferenzsicherheit unter **allgemeinen** FDs

Prädikatenlogische Modellierung von FDs

Betrachte: Relationenschema $\langle R | A_R | SC_R \rangle$ mit $SC_R = \Sigma$

$$\text{FD} \in \Sigma: \underbrace{\{a_{e_1}, \dots, a_{e_\ell}\}}_{\subseteq A_R} \rightarrow \underbrace{\{a_e\}}_{\in A_R}$$

In prior_Σ :

$$\begin{aligned}
 (\forall X_1) \dots (\forall X_{|A_R|}) (\forall Y_1) \dots (\forall Y_{|A_R|}) [& (R(X_1, \dots, X_{|A_R|}) \wedge \\
 & R(Y_1, \dots, Y_{|A_R|}) \wedge \\
 & X_{e_1} = Y_{e_1} \wedge \dots \wedge X_{e_\ell} = Y_{e_\ell}) \\
 & \Rightarrow X_e = Y_e]
 \end{aligned}$$

Inferenzsicherheit unter FDs

Gegeben sei:

- ▶ ursprüngliche Instanz r zu
- ▶ Schema $\langle R|A_R|SC_R \rangle$ mit $A_R = \{a_1, \dots, a_{|A_R|}\}$
- ▶ Menge \mathcal{C} von Vertraulichkeits-Constraints zu $\langle R|A_R|SC_R \rangle$
- ▶ $\mathcal{F} = \{\langle F_o|A_{F_o}|SC_{F_o} \rangle, \langle F_s|A_{F_s}|SC_{F_s} \rangle\}$, korrekt bzgl. \mathcal{C}
- ▶ f_o und f_s Fragment-Instanzen zu \mathcal{F} bzgl. r
- ▶ $db_{f_s} := db_{f_s}^+ \cup db_{f_s}^-$ zu f_s als Sichtweise eines Angreifers
- ▶ $pot_sec(\mathcal{C})$ als Vertraulichkeits-Politik
- ▶ $prior_\Sigma$ zu $SC_R = \Sigma$ als Vorwissen eines Angreifers

Zu zeigen: $\forall \Psi(\mathbf{v}) \in \text{ex}(pot_sec(\mathcal{C})) : prior_\Sigma \cup db_{f_s} \not\equiv_{DB} \Psi(\mathbf{v})$

Beweisskizze

Zu zeigen: $\forall \Psi(\mathbf{v}) \in \text{ex}(\text{pot_sec}(\mathcal{C})) : \text{prior}_\Sigma \cup \text{db}_{f_s} \not\models_{DB} \Psi(\mathbf{v})$

Ablauf des Beweises:

1. Wähle $\tilde{\Psi}(\mathbf{v}) \in \text{ex}(\text{pot_sec}(\mathcal{C}))$ beliebig
2. Zeige: es existiert ein \mathcal{I}^* mit
 - ▶ $\mathcal{I}^* \models_M \text{prior}_\Sigma$
 - ▶ $\mathcal{I}^* \models_M \text{db}_{f_s}$
 - ▶ $\mathcal{I}^* \not\models_M \tilde{\Psi}(\mathbf{v})$

Im Folgenden: für $j \in \{1, \dots, |A_R|\}$ gilt $j \in \text{Ind}_{F_s}^+ \Leftrightarrow$
 Term t_j ist Konstante in beliebigem $\Phi \in \text{db}_{f_s}^+$

Semantischer Korrektheitsbeweis (1)

Über Formeln aus $db_{f_s}^+$:

- ▶ betrachte $\tilde{\Psi}(\mathbf{v}) \in \text{ex}(\text{pot_sec}(\mathcal{C}))$ mit $\mathbf{v} = (v_{i_1}, \dots, v_{i_p})$
- ▶ es gilt: $\tilde{\Psi}(\mathbf{X}) \in \text{pot_sec}(\mathcal{C})$ mit $\mathbf{X} = (X_{i_1}, \dots, X_{i_p})$
- ▶ weiter: $c = \{a_{i_1}, \dots, a_{i_p}\} \in \mathcal{C}$
- ▶ Fragmentierung \mathcal{F} ist korrekt bzgl. \mathcal{C}
 - ▶ also: $c = \{a_{i_1}, \dots, a_{i_p}\} \not\subseteq A_{F_s}$
 - ▶ demnach: $\exists m \in \{i_1, \dots, i_p\} : a_m \notin A_{F_s}$
- ▶ folglich: für alle Formeln aus $db_{f_s}^+$ gilt

$$\dots (\exists X_m) \dots R(t_1, \dots, t_{|A_{R|}}) \quad \text{mit} \quad t_m := X_m$$

- ▶ insbesondere: $m \notin \text{Ind}_{F_s}^+$

Semantischer Korrektheitsbeweis (2)

Ziel des Beweises: DB-Interpretation \mathcal{I}^*

Hilfsweise: Konstruiere DB-Interpretation \mathcal{I}_r mit $\mathcal{I}_r \models_M db_r$

- ▶ für alle $R(u_1, \dots, u_{|A_R|}) \in db_r^+$: $(u_1, \dots, u_{|A_R|}) \in \mathcal{I}_r(R)$
- ▶ keine weiteren Tupel in $\mathcal{I}_r(R)$

Eigenschaften von \mathcal{I}_r :

- ▶ offensichtlich: $\mathcal{I}_r \models_M db_r^+$
- ▶ offensichtlich: $\mathcal{I}_r \models_M db_r^-$
- ▶ $\mathcal{I}_r \models_M \text{prior}_\Sigma$, weil r alle FDs aus Σ beachtet

Semantischer Korrektheitsbeweis (3)

Idee: konstruiere gewünschtes \mathcal{I}^* aus \mathcal{I}_r

- ▶ für alle $(u_1, \dots, u_m, \dots, u_{|A_R|}) \in \mathcal{I}_r(R)$:
füge $(u_1, \dots, \varphi_m(u_m), \dots, u_{|A_R|})$ in $\mathcal{I}^*(R)$ ein
- ▶ keine weiteren Tupel in $\mathcal{I}^*(R)$

$\varphi_m : \mathcal{U}_m \rightarrow \mathcal{U} \setminus \{v_m\}$ ist **injektive** Funktion, wobei

- ▶ für alle $(u_1, \dots, u_m, \dots, u_{|A_R|}) \in \mathcal{I}_r(R)$: $u_m \in \mathcal{U}_m$
- ▶ \mathcal{U} ist (unendlich großes) Universum von \mathcal{I}^*
- ▶ v_m ist aus $\mathbf{v} = (v_{i_1}, \dots, v_{i_p})$

φ_m kann stets konstruiert werden, weil $||(\mathcal{U} \setminus \{v_m\})|| > ||\mathcal{U}_m||$

Semantischer Korrektheitsbeweis (4)

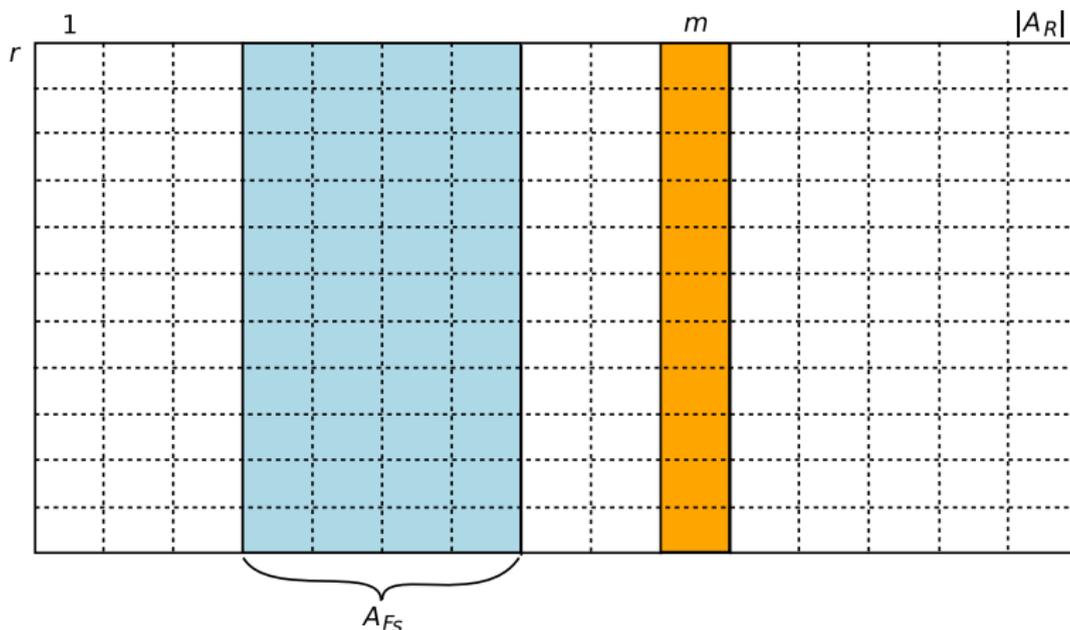
Ziel: für $\tilde{\Psi}(\mathbf{v}) \in \text{ex}(\text{pot_sec}(\mathcal{C}))$ gilt $\text{prior}_\Sigma \cup \text{db}_{f_s} \not\models_{DB} \tilde{\Psi}(\mathbf{v})$

Zwischenstand: \mathcal{I}^* konstruiert

Noch zu zeigen: \mathcal{I}^* erfüllt die gewünschten Eigenschaften

- ▶ $\mathcal{I}^* \models_M \text{db}_{f_s}$
- ▶ $\mathcal{I}^* \models_M \text{prior}_\Sigma$
- ▶ $\mathcal{I}^* \not\models_M \tilde{\Psi}(\mathbf{v})$

Semantischer Korrektheitsbeweis (5)



Es gilt: $\mathcal{I}^* \models_M db_{f_s}$ wegen $\mathcal{I}_r \models_M db_r$ und $m \notin \text{Ind}_{F_S}^+$

Semantischer Korrektheitsbeweis (6)

Noch zu zeigen: $\mathcal{I}^* \models_M \text{prior}_\Sigma$

Formel aus prior_Σ :

$$(\forall X_1) \dots (\forall X_{|A_R|}) (\forall Y_1) \dots (\forall Y_{|A_R|}) [
 \begin{array}{l}
 R(X_1, \dots, X_{|A_R|}) \wedge \\
 R(Y_1, \dots, Y_{|A_R|}) \wedge \\
 X_{e_1} = Y_{e_1} \wedge \dots \wedge X_{e_\ell} = Y_{e_\ell} \\
 \Rightarrow X_e = Y_e
 \end{array}
]$$

Auffällig: nur spaltenweise Gleichheiten entscheidend!
(spaltenweise, weil „getypte“ Formeln in prior_Σ)

Diese Gleichheiten aus \mathcal{I}_r müssen in \mathcal{I}^* **genau** erhalten bleiben
→ auch keine „neuen“ Gleichheiten

Semantischer Korrektheitsbeweis (7)

Betrachte aus $\mathcal{I}_r(R)$:

$(u_1, \dots, u_m, \dots, u_{|A_R|})$ und $(w_1, \dots, w_m, \dots, w_{|A_R|})$

Dafür in $\mathcal{I}^*(R)$:

$(u_1, \dots, \varphi_m(u_m), \dots, u_{|A_R|})$ und $(w_1, \dots, \varphi_m(w_m), \dots, w_{|A_R|})$

Bleiben **alle** Gleichheiten **spaltenweise** erhalten?

- ▶ für $j \in \{1, \dots, |A_R|\} \setminus \{m\}$: offensichtlich ja
- ▶ für Index m :
 - ▶ für $u_m = w_m$ gilt: $\varphi_m(u_m) = \varphi_m(w_m)$ (weil Funktion)
 - ▶ für $u_m \neq w_m$ gilt: $\varphi_m(u_m) \neq \varphi_m(w_m)$ (wegen Injektivität)

Semantischer Korrektheitsbeweis (8)

Es bleibt noch zu zeigen: $\mathcal{I}^* \not\models_M \tilde{\Psi}(\mathbf{v})$ mit $\mathbf{v} = (v_{i_1}, \dots, v_{i_p})$

$\mathcal{I}^* \models_M \tilde{\Psi}(\mathbf{v}) \Leftrightarrow$

- ▶ es existiert ein $(u_1, \dots, u_m, \dots, u_{|A_R|}) \in \mathcal{I}^*(R)$, in dem
- ▶ für **alle** $j \in \{i_1, \dots, i_p\} : u_j = v_j$

Das gilt aber nicht, weil

- ▶ für $(u_1, \dots, u_m, \dots, u_{|A_R|}) \in \mathcal{I}^*(R)$ gilt: $\varphi_m(\cdot) = u_m$
- ▶ $\varphi_m : \mathcal{U}_m \rightarrow \mathcal{U} \setminus \{v_m\}$
- ▶ $m \in \{i_1, \dots, i_p\}$

q.e.d.

Das war es...

Vielen Dank für eure Aufmerksamkeit!