



Birte Glimm  
Institut für Künstliche Intelligenz | 19. Jan 2012


## Semantic Web Grundlagen SPARQL Implementierungstechniken

## Organisatorisches: Inhalt

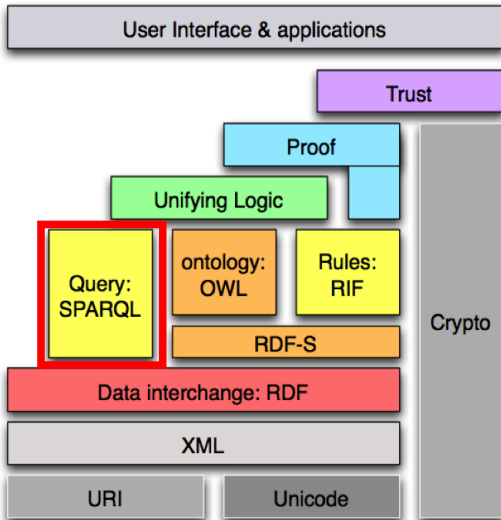
Einleitung und XML	17. Okt	Hypertableau II	12. Dez
Einführung in RDF	20. Okt	Übung 4	15. Dez
RDF Schema	24. Okt	SPARQL Syntax & Intuition	19. Dez
fällt aus	27. Okt	SPARQL Semantik	22. Dez
Logik – Grundlagen	31. Okt	SPARQL 1.1	9. Jan
Übung 1	3. Nov	Übung 5	12. Jan
Semantik von RDF(S)	7. Nov	SPARQL Entailment	16. Jan
RDF(S) & Datalog Regeln	10. Nov	<b>SPARQL Implementierung</b>	<b>19. Jan</b>
OWL Syntax & Intuition	14. Nov	Ontology Editing	23. Jan
Übung 2	17. Nov	Übung 6	26. Jan
OWL & BLs	21. Nov	Ontology Engineering	30. Jan
OWL 2	24. Nov	Linked Data	2. Feb
Tableau	28. Nov	SemWeb Anwendungen	6. Feb
Übung 3	1. Dez	Übung 7	9. Feb
Blocking & Unravelling	5. Dez	Wiederholung	13. Feb
Hypertableau	8. Dez	Übung 8	16. Feb

Abfragen und RIF wurde gestrichen

## Die Abfragesprache SPARQL



## Die Abfragesprache SPARQL



## Agenda

- ▶ Einleitung und Motivation
- ▶ Row Stores
  - ▶ Optimierungen
- ▶ Column Stores
- ▶ Andere Lösungen

## Agenda

- ▶ Einleitung und Motivation
- ▶ Row Stores
  - ▶ Optimierungen
- ▶ Column Stores
- ▶ Andere Lösungen

## Einführung und Motivation

- ▶ Die Menge an Daten im Semantic Web wächst kontinuierlich
  - ▶ Mehr als 25 Milliarden RDF Triple im Web verfügbar (Linked Data)
  - ▶ DBPedia: 3,4 Millionen Entitäten, 1 Milliarde Triple
- ▶ Effiziente Techniken zur Auswertung von Anfragen essentiell
- ▶ Wie können wir den  $Bgp(\cdot)$  Operator effizient auswerten (ohne Entailment)?
- ▶ In welcher Reihenfolge sollten die anderen Operatoren ausgewertet werden?

## Mehr und Mehr Tripel

- ▶ Billion Triple Challenge 2008: 1 Milliarde Tripel
- ▶ Billion Triple Challenge 2010: 3 Milliarden Tripel
- ▶ Billion Triple Challenge 2011: 2 Milliarden Tripel
- ▶ <http://www.w3.org/wiki/LargeTripleStores>:
  - ▶ BigOWLIM: 12 Milliarden Tripel (Juni 2009)
  - ▶ Garlik 4store: 15 Milliarden Tripel (Oktober 2009)
  - ▶ OpenLink Virtuoso: 15.4 Milliarden Tripel
  - ▶ AllegroGraph: 1+ Billionen Tripel



## Und Komplexe Abfragemuster

```
SELECT DISTINCT ?a ?b ?lat ?long WHERE
{ ?a dbpedia:spouse ?b.
  ?a dbpedia:wikilink dbpediares:actor.
  ?b dbpedia:wikilink dbpediares:actor.
  ?a dbpedia:placeOfBirth ?c.
  ?b dbpedia:placeOfBirth ?c.
  ?c owl:sameAs ?c2.
  ?c2 pos:lat ?lat.
  ?c2 pos:long ?long.
}
```

## Agenda

- ▶ Einleitung und Motivation
- ▶ Row Stores
  - ▶ Optimierungen
- ▶ Column Stores
- ▶ Andere Lösungen

## RDF in Row Stores

### Row Store:

- ▶ Relationale Datenbank, die Tripel in Reihen einer Relation speichert
- ▶ MySQL, PostgreSQL, Oracle, DB2, SQLServer, ...

### Zugrunde liegendes Prinzip:

- ▶ Tripel werden in einer (sehr großen) Tabelle mit drei Attributen gespeichert (s, p, o)
- ▶ SPARQL Abfragen werden in SQL Abfragen umgeschrieben
- ▶ Die Datenbank übernimmt die Auswertung
  - ▶ Strings werden oft auf eindeutige Integer IDs abgebildet
  - ▶ Verwendet von vielen Tripel Stores z.B. 3Store, Jena, HexaStore, RDF-3X, ...

## RDF in Row Stores

### Row Store:

- ▶ Relationale Datenbank, die Tripel in Reihen einer Relation speichert
- ▶ MySQL, PostgreSQL, Oracle, DB2, SQLServer, ...

### Zugrunde liegendes Prinzip:

- ▶ Tripel werden in einer (sehr großen) Tabelle mit drei Attributen gespeichert (s, p, o)
- ▶ SPARQL Abfragen werden in SQL Abfragen umgeschrieben
- ▶ Die Datenbank übernimmt die Auswertung
  - ▶ Strings werden oft auf eindeutige Integer IDs abgebildet
  - ▶ Verwendet von vielen Tripel Stores z.B. 3Store, Jena, HexaStore, RDF-3X, ...

Einfache Erweiterung auf Quadrupel (Graph, Subjekt, Prädikat, Objekt)      Hier aber Fokus auf Tripel

## Beispiel Tripel Tabelle

```

ex:Sebastian ex:lehrt          ex:EinführungKI ;
              ex:arbeitetFür  ex:KIT ;
              ex:drVon        ex:TUDresden .
ex:Birte     ex:lehrt          ex:SemWebGrundlagen ;
              ex:arbeitetFür  ex:Ulm ;
              ex:drVon        ex:UoManchester .
ex:Markus   ex:lehrt          ex:KR&R ;
              ex:arbeitetFür  ex:KIT ;
              ex:drVon        ex:UoOxford ,
                              ex:SemanticWiki .
  
```

Subjekt	Prädikat	Objekt
ex:Sebastian	ex:lehrt	ex:EinführungKI
ex:Sebastian	ex:arbeitetFür	ex:KIT
ex:Sebastian	ex:drVon	ex:TUDresden
ex:Birte	ex:lehrt	ex:SemWebGrundlagen
ex:Birte	ex:arbeitetFür	ex:Ulm
ex:Birte	ex:drVon	ex:UoManchester
ex:Markus	ex:lehrt	ex:KR&R
ex:Markus	ex:arbeitetFür	ex:UoOxford
ex:Markus	ex:arbeitetFür	ex:SemanticWiki
ex:Markus	ex:drVon	ex:KIT

## Umwandlung von SPARQL in SQL Abfragen

### Prinzipieller Ansatz:

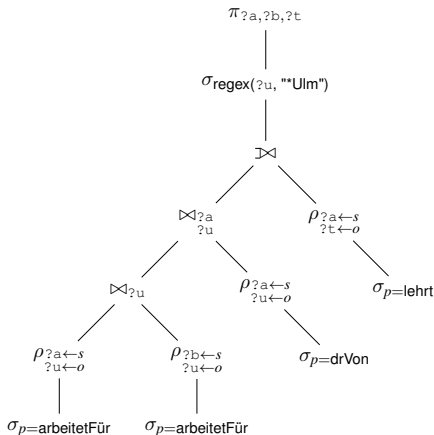
- ▶ Für jedes Tripel Muster eine Kopie der Tripel Tabelle
- ▶ Konstanten im Abfragemuster führen zu Bedingungen
- ▶ Gemeinsame Variablen in Mustern führen zu Joins
- ▶ FILTER Bedingungen erzeugen Constraints
- ▶ OPTIONAL Klauseln erzeugen Outer Joins
- ▶ UNION Klauseln erzeugen Union Ausdrücke

## Beispiel: Umwandlung von SPARQL in SQL Abfragen

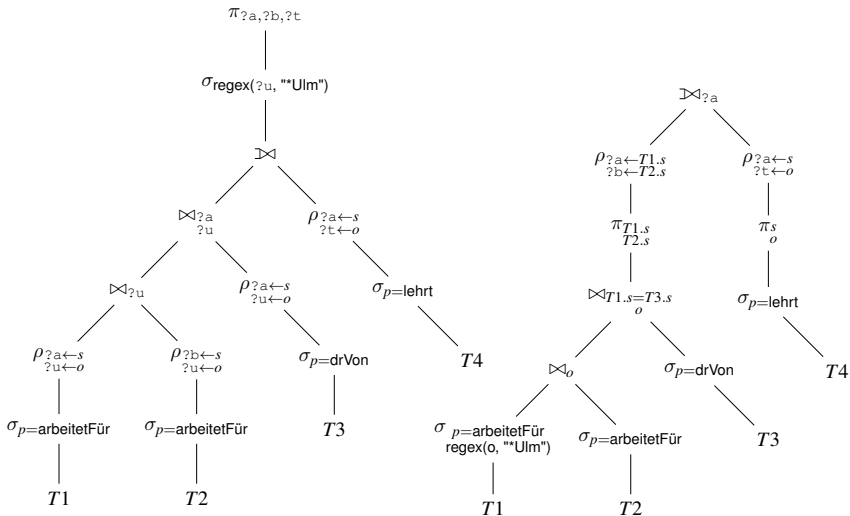
```
SELECT ?a ?b ?t WHERE {
  ?a arbeitetFür ?u . ?b arbeitetFür ?u . ?a drVon ?u .
  OPTIONAL { ?a lehrt ?t } FILTER (regex(?u, "*Ulm"))}
```

Algebra Übersetzung:

```
Project(
  Filter(
    regex(?u, "*Ulm"),
    LeftJoin(
      Bgp(...),
      Bgp(...),
      true
    )
  ),
  {?a, ?b, ?t })
```




# Beispiel: Algebra Optimierung






## Beispiel: Umwandlung von SPARQL in SQL Abfragen




## Beispiel: Umwandlung von SPARQL in SQL Abfragen

```
SELECT T4.s as a, T4.o as t
FROM Triples T4
WHERE T4.p="lehrt"
```



## Beispiel: Umwandlung von SPARQL in SQL Abfragen

```
SELECT T4.s as a, T4.o as t
FROM Triples T4
WHERE T4.p="lehrt"
```



## Beispiel: Umwandlung von SPARQL in SQL Abfragen

```

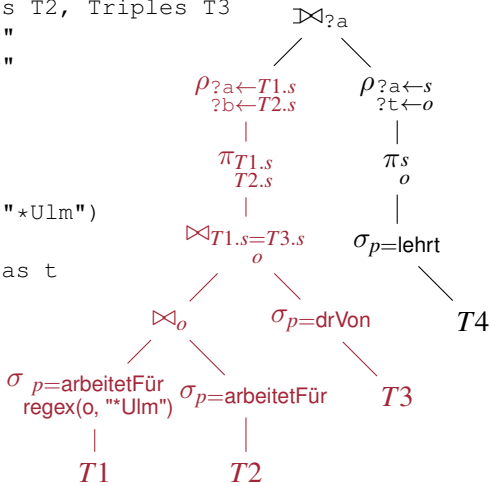
SELECT T1.s as a, T2.s as b
FROM Triples T1, Triples T2, Triples T3
WHERE T1.p="arbeitetFür"
      AND T2.p="arbeitetFür"
      AND T3.p="drVon"
      AND T1.o=T2.o
      AND T1.s=T3.s
      AND T1.o=T3.o
      AND REGEXP_LIKE(T1.o, "*Ulm")

```

```

SELECT T4.s as a, T4.o as t
FROM Triples T4
WHERE T4.p="lehrt"

```



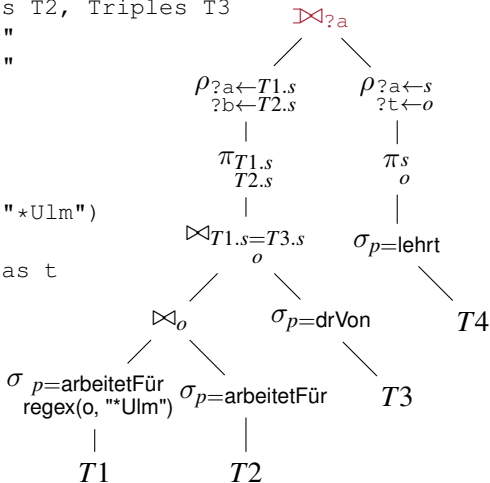
## Beispiel: Umwandlung von SPARQL in SQL Abfragen

```

SELECT T1.s as a, T2.s as b
FROM Triples T1, Triples T2, Triples T3
WHERE T1.p="arbeitetFür"
      AND T2.p="arbeitetFür"
      AND T3.p="drVon"
      AND T1.o=T2.o
      AND T1.s=T3.s
      AND T1.o=T3.o
      AND REGEXP_LIKE(T1.o, "*Ulm")
  
```

```


SELECT T4.s as a, T4.o as t
FROM Triples T4
WHERE T4.p="lehrt"
  
```



## Beispiel: Umwandlung von SPARQL in SQL Abfragen

```

SELECT * FROM
( SELECT T1.s as a, T2.s as b
  FROM Triples T1, Triples T2, Triples T3
 WHERE T1.p="arbeitetFür"
       AND T2.p="arbeitetFür"
       AND T3.p="drVon"
       AND T1.o=T2.o
       AND T1.s=T3.s
       AND T1.o=T3.o
       AND REGEXP_LIKE(T1.o, "*Ulm")
) AS R1 LEFT OUTER JOIN (
  SELECT T4.s as a, T4.o as t
  FROM Triples T4
 WHERE T4.p="lehrt"
) AS R2 ON (R1.a=R2.a)
  
```



# Ist das Alles?

Ist das Alles?

Nein



## Ist das Alles?

### Nein

- ▶ Welche Indexe sollen wir zur Auswertung der Tripel Muster verwenden?
- ▶ Wie können wir die Speichieranforderungen reduzieren?
- ▶ Was ist der beste Ausführungsplan?

## Ist das Alles?

### Nein

- ▶ Welche Indexe sollen wir zur Auswertung der Tripel Muster verwenden?
- ▶ Wie können wir die Speichieranforderungen reduzieren?
- ▶ Was ist der beste Ausführungsplan?

Existierende Datenbanken nicht unbedingt geeignet:

- ▶ Zahlreiche self-joins auf einer großen Tabelle schlecht unterstützt
- ▶ Abfrageoptimierer generieren oft schlechte Pläne für eine große Tripel Tabelle
- ▶ Erweiterbares generisches Tabellenmanagement nicht nötig

## Agenda

- ▶ Einleitung und Motivation
- ▶ Row Stores
  - ▶ Optimierungen
- ▶ Column Stores
- ▶ Andere Lösungen

## Dictionary für Strings

Strings werden auf eindeutige Integers abgebildet (z.B. durch Hashing)

- ▶ Gleichmäßige Größe  $\rightsquigarrow$  einfacher zu handhaben
- ▶ Mapping ist meist klein  $\rightsquigarrow$  kann im Hauptspeicher gehalten werden

### Beispiel

<code>&lt;http://example.org/Birte&gt;</code>	<b>194760</b>
<code>&lt;http://example.org/Sebastian&gt;</code>	<b>679375</b>
<code>&lt;http://example.org/Markus&gt;</code>	<b>4634</b>

## Dictionary für Strings

Strings werden auf eindeutige Integers abgebildet (z.B. durch Hashing)

- ▶ Gleichmäßige Größe  $\rightsquigarrow$  einfacher zu handhaben
- ▶ Mapping ist meist klein  $\rightsquigarrow$  kann im Hauptspeicher gehalten werden

### Beispiel


<code>&lt;http://example.org/Birte&gt;</code>	194760
<code>&lt;http://example.org/Sebastian&gt;</code>	679375
<code>&lt;http://example.org/Markus&gt;</code>	4634

**Achtung:** Natürliche Ordnung für das Sortieren geht nicht mehr  
 $\rightsquigarrow$  Filterauswertung kann teurer werden

## Indexe für häufige Tripel Muster

- ▶ Muster mit einer Variable sind häufig
- ▶ Bsp.: `ex:Einstein ex:invented ?x`

↪ Anlegen eines clustered Index über (s, p, o)



1. ID Lookup:  
`ex:Einstein =16,`  
`ex:invented =24`
2. Lookup des Präfix im  
Index: (16,24,0)
3. Lese Ergebnisse solange  
Präfix matched:  
(16, 24, 567), (16, 24, 876)  
(sind sortiert!)

Geht auch für Muster der Form `ex:Einstein ?p ?x`


## Indexe für häufige Tripel Muster

- ▶ Ähnliche Indexe für alle 6 Kombinationen: SPO, OPS, PSO, SOP, OSP, POS
- ▶ Deckt alle typischen Muster ab
- ▶ Ergibt sortierte Indexe für alle Muster mit zwei Variablen
- ↪ Triple Tabelle nicht länger benötigt da alle Tripel in den Indexen

## Relevanz der Sortierung für Joins


Eingaben auf dem Join Attribut sortiert  $\rightsquigarrow$  Merge Join:

- ▶ Sequentieller Scan beider Tabellen
- ▶ Sofortiger Join der Tripel
- ▶ Teile ohne Matches überspringen
- ▶ Pipelining möglich



Eingaben auf dem Join Attribut unsortiert  $\rightsquigarrow$  Hash Join:

- ▶ Hash Tabelle f. eine Tabelle
- ▶ Scanne die andere, nutze Hashing zum matchen
- ▶ Jeder Eingabe Tripel wird angefasst
- ▶ Kein Pipelining





## Weitere Indexe

SPARQL erlaubt Duplikate (außer mit `DISTINCT`)

- ▶ Duplikate können für Anwendung wichtig sein (Zählen)

↪ Häufig Abfragen mit vielen Duplikaten

Bsp.: `SELECT ?x WHERE {?x ?y ex:Deutschland}`

Um Elemente abzufragen, die zu Deutschland in Beziehung stehen

↪ Viele identische Zwischenergebnisse

Lösung:

- ▶ Berechnung von aggregierten Indexen SP, SO, PO, PS, OP, OS, S, P, O

Bsp.: SO enthält, für jedes Paar (s, o), die Anzahl der Tripel mit Subjekt s und Objekt o

- ▶ Statt identischer Bindungen speichern wir Multiplizitäten

Bsp.: `?x ↦ ex:Einstein : 4, ?x ↦ ex:Merkel : 10`

## Kompression um Speicher zu Sparen

- ▶ Komprimiere Sequenzen von Tripeln in lexikographischer Ordnung

$(v_1, v_2, v_3)$ ; für SPO,  $v_1 = S, v_2 = P, v_3 = O$

- ▶ Schritt 1: Berechne Deltas pro Attribut

(16, 19, 5356)	(16, 19, 5356)
(16, 24, 567)	(0, 5, -4798)
(16, 24, 676)	(0, 0, 109)
(27, 19, 643)	(11, -5, -34)
(27, 48, 10486)	(0, 29, 9843)
(50, 10, 10456)	(23, -38, -30)

- ▶ Schritt 2: Kodiere jedes Delta Tripel separat in 1-13 bytes

gap bit	header (7 bits)	Delta mit Wert 1 (0-4 bytes)	Delta mit Wert 2 (0-4 bytes)	Delta mit Wert 3 (0-4 bytes)
------------	--------------------	---------------------------------	---------------------------------	---------------------------------

↑  
Wenn gap=1,  
Delta für v3  
mit im Header  
sonst Wert 0


↙  
Sonst enthält der Header die Länge der Kodierungen für  
die drei Deltas ( $5*5*5=125$  Kombinationen)

## Effektivität und Effizienz der Kompression

- ▶ Byte-level Kodierung fast so effektiv wie bit-level Kodierungstechniken (Gamma, Delta, Golomb)
- ▶ Deutlich schneller ( $10\times$ ) bei der Dekodierung
- ▶ Beispiel Barton Datensatz (Neumann & Weikum 2010):
  - ▶ Rohdaten 51 Millionen Tripel, 7GB unkomprimiert
  - ▶ Alle 6 Hauptindexe:
    - ▶ 1.1 GB Größe, 3.2s Dekomprimierung mit Byte-level Kodierung
    - ▶ 1.06 GB Größe, 42.5s Dekomprimierung mit Delta Kodierung
- ▶ Zusätzliche Kompression mit LZ77  $2\times$  kompakter, aber deutlich langsamer bei der Dekomprimierung
- ▶ Kompression immer auf Seiten Level

## Zurück zur Beispiel Abfrage

```
SELECT ?a ?b ?t WHERE {
  ?a arbeitetFür ?u . ?b arbeitetFür ?u . ?a drVon ?u .
  OPTIONAL { ?a lehrt ?t } FILTER (regex(?u, "*Ulm"))}
```



- ▶ Welcher der beiden Pläne ist besser?
- ▶ Wie viele Zwischenergebnisse?

## Selektivitätsabschätzung für Abfragemuster

- ▶ Selektivitätsabschätzung sehr wichtig für gute Abfrageoptimierer (join order)
- ▶ In Standard Datenbanken:
  - ▶ Histogramm für die Attribute
  - ▶ Angenommene Unabhängigkeit zwischen Attributen
 ~~~ zu vereinfachend und ungenau
- ▶ Zusätzliche Join Statistiken für Tripel Blöcke:

|                                                                                                                     |                                |     |                   |     |
|---------------------------------------------------------------------------------------------------------------------|--------------------------------|-----|-------------------|-----|
| ...<br>(16, 19, 5356)<br>(16, 24, 567)<br>(16, 24, 876)<br>(27, 19, 643)<br>(27, 48, 10486)<br>(50,10,10456)<br>... | Beginn<br>(s, p, o)            |     | Ende<br>(s, p, o) |     |
|                                                                                                                     | Anzahl der Tripel              |     |                   |     |
|                                                                                                                     | Anzahl verschiedener 1-Präfixe |     |                   |     |
|                                                                                                                     | Anzahl verschiedener 2-Präfixe |     |                   |     |
|                                                                                                                     | Join Partner für Subjekt       |     |                   |     |
|                                                                                                                     |                                | s=s | s=p               | s=o |
|                                                                                                                     | Join Partner für Prädikat      |     |                   |     |
|                                                                                                                     |                                | p=s | p=p               | p=o |
|                                                                                                                     | Join Partner für Objekt        |     |                   |     |
|                                                                                                                     |                                | o=s | o=p               | o=o |

Annahme:  
 Unabhängigkeit  
 zwischen Tri-  
 peln; zusätzlich  
 Berechnung  
 exakter Statisti-  
 ken für häufige  
 Pfade in den  
 Daten

## Verarbeitung von Updates

Wie können wir Änderungen an den Daten verarbeiten?  
SPARQL 1.1 definiert Updates!

### **Annahmen:**

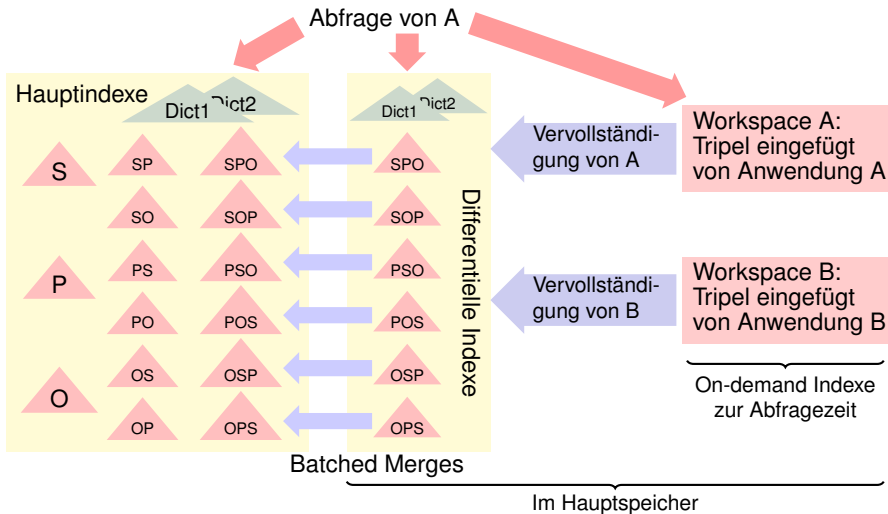
- ▶ Lesende Abfragen wesentlich häufiger als Updates
- ▶ Updates meist Einfügen, weniger Löschen von Daten
- ▶ Verschiedene Anwendungen können nebenläufig updaten

### **Lösung:**

Differenzielle Indexe

## Differentielle Updates

### Staging Architektur für Updates in RDF-3X



## Löschen:

- ▶ Einfügen des gleichen Triples mit Löschflag
- ▶ Verändere scan/join Operatoren



## Agenda

- ▶ Einleitung und Motivation
- ▶ Row Stores
  - ▶ Optimierungen
- ▶ Column Stores
- ▶ Andere Lösungen

## Prinzipien

### **Beobachtungen und Annahmen:**

- ▶ Wenig verschiedene Prädikate
- ▶ Abfragemuster haben meist keine Variablen als Prädikate
- ▶ Bedarf zur Abfrage von Tripeln mit gleichem Prädikat

### **Design Konsequenzen:**

- ▶ Nutzung einer Tabelle mit 2 Attributen pro Prädikat

## Beispiel: Column Store

```

ex:Sebastian  ex:lehrt          ex:EinführungKI ;
               ex:arbeitetFür ex:KIT ;
               ex:drVon       ex:TUDresden .
ex:Birte      ex:lehrt          ex:SemWebGrundlagen ;
               ex:arbeitetFür ex:UUlm ;
               ex:drVon       ex:UoManchester .
ex:Markus     ex:lehrt          ex:KR&R ;
               ex:drVon       ex:KIT ;
               ex:arbeitetFür ex:UoOxford ,
                               ex:SemanticWiki .
  
```

| lehrt        |                     |
|--------------|---------------------|
| Subjekt      | Objekt              |
| ex:Sebastian | ex:EinführungKI     |
| ex:Birte     | ex:SemWebGrundlagen |
| ex:Markus    | ex:KR&R             |

| drVon        |                 |
|--------------|-----------------|
| Subjekt      | Objekt          |
| ex:Sebastian | ex:TUDresden    |
| ex:Birte     | ex:UoManchester |
| ex:Markus    | ex:KIT          |

| arbeitetFür  |                 |
|--------------|-----------------|
| Subjekt      | Objekt          |
| ex:Sebastian | ex:KIT          |
| ex:Birte     | ex:UUlm         |
| ex:Markus    | ex:UoOxford     |
| ex:Markus    | ex:SemanticWiki |

## Vereinfachtes Beispiel: Abfrage Konvertierung

```
SELECT ?a ?b ?t WHERE {  
  ?a arbeitetFür ?u .  
  ?b arbeitetFür ?u .  
  ?a drVon ?u .  
}
```

```
SELECT W1.Subjekt as a, W2.Subjekt as b  
FROM arbeitetFür W1, arbeitetFür W2, drVon P3  
WHERE W1.Objekt=W2.Objekt  
      AND W1.Subjekt=P3.Subjekt  
      AND W1.Objekt=P3.Objekt
```

## Vereinfachtes Beispiel: Abfrage Konvertierung


```
SELECT ?a ?b ?t WHERE {  
  ?a arbeitetFür ?u .  
  ?b arbeitetFür ?u .  
  ?a drVon ?u .  
}
```

```
SELECT W1.Subjekt as a, W2.Subjekt as b  
FROM arbeitetFür W1, arbeitetFür W2, drVon P3  
WHERE W1.Objekt=W2.Objekt  
      AND W1.Subjekt=P3.Subjekt  
      AND W1.Objekt=P3.Objekt
```

Bisher ist das nur eine andere relationale RDF Repräsentation.  
Aber was sind Column Stores?

## Column Stores und RDF

Column Stores speichern Spalten einer Tabelle separat



- ▶ Vorteile:
  - ▶ Schnell wenn nur auf das Subjekt oder nur das Objekt zugegriffen wird, nicht auf beides
  - ▶ Erlaubt sehr kompakte Repräsentation
- ▶ Probleme:
  - ▶ Subjekt und Objekt Spalten müssen wieder kombiniert werden bei Zugriff auf beides
  - ▶ Ineffizient für Muster mit Prädikatsvariablen

## Kompression in Column Stores

Allgemeine Idee:

- ▶ Subjekt wird nur einmal gespeichert
- ▶ Nutzung der gleichen Ordnung nach Subjekt für alle Spalten, inkl. NULL Werte wenn nötig

| Subjekt      | drVon           | lehrt               | arbeitetFür     |
|--------------|-----------------|---------------------|-----------------|
| ex:Sebastian | ex:TUDresden    | ex:GrundlagenKI     | ex:KIT          |
| ex:Birte     | ex:UoManchester | ex:SemWebGrundlagen | ex:UUlm         |
| ex:Markus    | ex:KIT          | ex:KR&R             | ex:UoOxford     |
| ex:Markus    | NULL            | NULL                | ex:SemanticWiki |

- ▶ Zusätzliche Kompression, um NULL Werte nicht zu speichern

| drVon:bit[1110] |
|-----------------|
| ex:TUDresden    |
| ex:UoManchester |
| ex:KIT          |

| lehrt:range[1-3]    |
|---------------------|
| ex:GrundlagenKI     |
| ex:SemWebGrundlagen |
| ex:KR&R             |

## Agenda

- ▶ Einleitung und Motivation
- ▶ Row Stores
  - ▶ Optimierungen
- ▶ Column Stores
- ▶ Andere Lösungen



## Property Tabellen

Entitäten mit ähnlichen Prädikaten werden in einer relationalen Tabelle gespeichert (z.B. durch Nutzung der Typen oder eines Clustering Algorithmus)

```

ex:Sebastian  ex:lehrt      ex:GrundlagenKI ;
               ex:arbeitetFür ex:KIT ;
               ex:drVon      ex:TUDresden .
ex:Birte      ex:lehrt      ex:SemWebGrundlagen ;
               ex:arbeitetFür ex:UUlm ;
               ex:drVon      ex:UoManchester .
ex:Markus     ex:lehrt      ex:KR&R ;
               ex:drVon      ex:KIT ;
               ex:arbeitetFür ex:UoOxford , ex:SemanticWiki .
  
```

| Subjekt      | lehrt               | drVon           |
|--------------|---------------------|-----------------|
| ex:Sebastian | ex:GrundlagenKI     | ex:TUDresden    |
| ex:Birte     | ex:SemWebGrundlagen | ex:UoManchester |
| ex:Markus    | ex:KR&R             | ex:KIT          |

übrige Tripel

| Subjekt      | Prädikat       | Objekt          |
|--------------|----------------|-----------------|
| ex:Sebastian | ex:arbeitetFür | ex:KIT          |
| ex:Birte     | ex:arbeitetFür | ex:UUlm         |
| ex:Markus    | ex:arbeitetFür | ex:UoOxford     |
| ex:Markus    | ex:arbeitetFür | ex:SemanticWiki |

## Property Tabellen: Pro und Kontra

### Vorteile:

- ▶ Ähnlicher zu bestehenden relationalen DBMS
- ▶ Weniger self-joins als mit Tripel Tabellen

### Nachteile:

- ▶ Potentiell viele `NULL` Werte
- ▶ Mehrwertige Attribute problematisch
- ▶ Abfrage Transformation hängt vom Schema ab
- ▶ Änderungen am Schema teuer

## Noch viele weitere Techniken

- ▶ Speicherung von RDF Daten als bit-Vektor Matrizen
- ▶ Konvertierung von RDF in XML und Nutzung von XML Methoden (XPath, XQuery)
- ▶ Speicherung von RDF Daten in Graph-Datenbanken
- ▶ ...

### Welche Technik ist die Beste?

- ▶ Performanz hängt stark von der Vorberechnung, Optimierung und Implementierung ab

## Vergleichende Studie

|               | Q1          | Q2         | Q3         | Q4         |              |
|---------------|-------------|------------|------------|------------|--------------|
| cold caches   |             |            |            |            |              |
| RDF-3X        | 0.27+0.01   | 0.26+0.01  | 0.94+0.01  | 5.32+0.06  |              |
| RDF-3X (2008) | 4.02+0.03   | 0.36+0.01  | 4.5+0.04   | 112.0+3.32 |              |
| COLSTORE      | >30min      | >30min     | 946.4+8.01 | >30min     |              |
| ROWSTORE      | 17.44 +0.29 | >30min     | 641.2+0.88 | 373.0+2.15 |              |
| warm caches   |             |            |            |            |              |
| RDF-3X        | 0.01+0.01   | 0.01+0.01  | 0.01+0.01  | 0.23+0.01  |              |
| RDF-X (2008)  | 0.54+0.01   | 0.01+0.01  | 0.28+0.01  | 105.7+1.71 |              |
| COLSTORE      | >30min      | >30min     | 547.9+83.0 | >30min     |              |
| ROWSTORE      | 0.69+0.03   | >30min     | 637.1+4.97 | 212.0+1.43 |              |
|               | Q5          | Q6         | Q7         | Q8         | geom. Mittel |
| cold caches   |             |            |            |            |              |
| RDF-3X        | 2.37+0.04   | 0.46+0.01  | 3.99+0.05  | 0.35+0.01  | 0.94+0.01    |
| RDF-3X (2008) | 6.82+0.63   | 1.28+0.06  | >30min     | 44.23+0.67 | >7.43+0.07   |
| COLSTORE      | >30min      | 665.9+38.4 | 18.71+0.32 | >30min     | >208.0+1.49  |
| ROWSTORE      | >30min      | 6.89+0.07  | >30min     | 142.3+13.4 | >87.22+0.68  |
| warm caches   |             |            |            |            |              |
| RDF-3X        | 0.08+0.01   | 0.03+0.01  | 0.03+0.01  | 0.01+0.01  | 0.04+0.01    |
| RDF-X (2008)  | 3.72+0.02   | 0.73+0.01  | >30min     | 15.12+0.20 | >2.59+0.06   |
| COLSTORE      | >30min      | 650.0+31.7 | 0.86+0.02  | >30min     | >150.0+1.48  |
| ROWSTORE      | >30min      | 0.81+0.04  | >30min     | 60.29+0.87 | >43.98+0.22  |

Laufzeiten in Sekunden auf dem BTC 2008 Datensatz ([Neumann & Weikum, 2009])

## Zusammenfassung

- ▶ Diverse Implementierungstechniken für Tripel Stores
- ▶ Eng verwandt mit Datenbanken
- ▶ Transaktionsmanagement oft (noch) vernachlässigt
- ▶ Oft auch Erweiterung um Regelsprachen
- ▶ Optimierungen essentiell für vernünftige Performanz