

# Datenbanksysteme

Wintersemester 2016/17

Prof. Dr.-Ing. Sebastian Michel  
TU Kaiserslautern

[smichel@cs.uni-kl.de](mailto:smichel@cs.uni-kl.de)

## Verschachtelte (Engl. Nested) Anfragen

### Wieso und wo gibt es verschachtelte Anfragen?

- Unteranfragen können beinahe überall in SQL auftreten, z.B. im SELECT, als "Relation" in FROM oder natürlich in der WHERE Klausel.
- Macht Formulierung von Anfragen oft angenehmer, da natürlicher, vgl. z.B. WHERE EXISTS
- Für Anfrageverarbeitung in der Regel allerdings nicht wünschenswert, da naive Ausführung teuer

Literaturempfehlung: Ganski und Wong. Optimization of Nested SQL Queries Revisited. SIGMOD 1987.

<http://www.csd.uoc.gr/~hy460/pdf/p23-ganski.pdf>

bzw. auch Won Kim. On optimizing SQL-like nested query. ACM TODS, 1982.

## Klassifizierung (Typen) von Schachtelungen

---

**Typ A** Verschachteltes Prädikat, welches einen (aggregierten Wert) liefert und **unabhängig** von äußerer Anfrage ist.

```
SELECT *  
FROM exams e  
WHERE e.note = (SELECT max(note) FROM exams)
```

---

**Typ N** Verschachteltes Prädikat, bei dem innere Anfrage eine Relation zurück gibt, aber **unabhängig** ist von äußerer Anfrage.

```
SELECT *  
FROM exams e  
WHERE e.department IN (SELECT f.id  
                        FROM department f  
                        WHERE f.name='Informatik')
```

---

Typen nach Won Kim '82. On optimizing SQL-like nested query.

# Klassifizierung (Typen) von Schachtelungen

---

**Typ J** Verschachteltes Prädikat. Innere Anfrage referenziert äußere Anfrage, ist also **abhängig (korreliert)**. Keine Aggregation in innereren Anfrage.

```
SELECT BestNr
FROM Bestellung B
WHERE ProdNr IN (SELECT ProdNr
                  FROM Lieferung L
                  WHERE L.LiefNr = B.BestNr
                  AND L.Datum = current_date)
```

---

**Typ JA** Wie J nur nun mit Aggregation.

---

Typen nach Won Kim '82. On optimizing SQL-like nested query.

## Entschachteln von Anfragen: Konstante Unteranfragen

```
SELECT *  
FROM exams e  
WHERE e.note = (SELECT max(note) FROM exams)
```

- **Naive Ausführung:** Für jedes Tupel aus Exams e wird ein Mal über Exams iteriert. **Teuer.**
- **Unterfrage berechnet einen konstanten Wert**
- **Kann vom Anfrageoptimierer erkannt, berechnet und als Konstante bereitgestellt werden.**

```
DEFINE m = (SELECT max(note) from Exams)
```

```
SELECT *  
FROM exams e  
WHERE e.note = m
```

## Entschachteln von Anfragen: Unabhängige Unteranfragen

```
SELECT *  
FROM exams e  
WHERE e.department IN (SELECT f.id  
                        FROM department f  
                        WHERE f.name='Informatik')
```

- **Unterfrage ist unabhängig von der äußeren Anfrage**
- Hier eine **Existenzaussage** via **IN**, ähnlich/identisch zu **EXISTS** oder **ANY**.
- Kann einfach entschachtelt werden mit Hilfe eines Joins bzw. Semijoin, unten dargestellt.
- Oder Unteranfrage wird berechnet, materialisiert und als Filter benutzt.

```
SELECT DISTINCT e.*  
FROM exams e, department f  
WHERE e.department = f.id AND f.name='Informatik'
```

## Verschachtelte vs. Unverschachtelte Anfrage

```

SELECT p.pname,
  ( SELECT c.city
    FROM company c
    WHERE p.cid = c.cid ) AS city
FROM product p;
  
```

**Kann leicht  
entschachtelt  
werden:**

```


SELECT p.pname, c.city
FROM product p, company c
WHERE p.cid = c.cid
  
```

**Achtung:** Annahme im Beispiel, dass jedes Produkt auch Firma und somit City hat, sonst unten LEFT OUTER JOIN nötig.

Sequential Scan auf company  
mit Filter p.cid=c.cid:



**Nach Entschachtelung  
Plan mit Hashjoin:**



## Entschachteln von Anfragen: Abhängige Unteranfragen

```
SELECT BestNr  
FROM Bestellung B  
WHERE ProdNr IN (SELECT ProdNr  
                FROM Lieferung L  
                WHERE L.LiefNr = B.BestNr  
                AND L.Datum = current_date)
```

**Kann entschachtelt werden zu**

```
SELECT BestNr  
FROM Bestellung B, Lieferung L  
WHERE B.ProdNr = L.ProdNr  
        AND L.LiefNr = B.BestNr  
        AND L.Datum = current_date
```



## Entschachteln von Anfragen: Abhängige Unteranfragen

Unteranfragen müssen nicht nur im WHERE Block stehen: Berechne für jede Firma die Anzahl an Produkten, die dort hergestellt werden.

```
SELECT DISTINCT C.cname, (SELECT count(*)  
                        FROM Product P  
                        WHERE P.cid = C.cid)  
FROM Company C
```

**Kann mit Hilfe von GROUP BY entschachtelt werden zu**

```
SELECT C.cname, count(*)  
FROM Company C, Produkt P  
WHERE C.cid = P.cid  
GROUP BY C.cname
```

Ist das so korrekt?

## Entschachteln von Anfragen: Abhängige Unteranfragen

Nein, die Entschachtelung war nicht korrekt. Was ist mit Firmen, die gar keine Produkte haben?

```
SELECT C.cname, count(p.name)
FROM Company C LEFT OUTER JOIN Product P
ON C.cid = P.cid
GROUP BY C.cname
```

## Verschachtelte Anfragen mit EXIST, IN, ANY

Finde alle Firmen mit Produkten günstiger als 150.

```
SELECT DISTINCT c.cname  
FROM company c  
WHERE EXISTS (SELECT *  
                FROM product p  
                WHERE c.cid=p.cid and p.price < 150);
```

Wie kann man diese Anfrage mittels **IN** oder **ANY** ausdrücken?

## Verschachtelte Anfragen mit EXIST, IN, ANY (2)

```
SELECT DISTINCT c.cname  
FROM company c  
WHERE c.cid IN (SELECT p.cid  
                FROM product p  
                WHERE c.cid=p.cid and p.price < 150);
```

```
SELECT DISTINCT c.cname  
FROM company c  
WHERE 150 > ANY (SELECT p.price  
                FROM product p  
                WHERE c.cid=p.cid);
```

Nun zur Entschachtelung ...

## Verschachtelte Anfragen mit EXIST, IN, ANY (3)

```
SELECT DISTINCT c.cname  
FROM company c  
WHERE EXISTS (SELECT *  
                FROM product p  
                WHERE c.cid=p.cid and p.price < 150);
```

**Kann entschachtelt geschrieben werden als**

```
SELECT DISTINCT c.cname  
FROM company c, product p  
WHERE c.cid = p.cid and p.price < 150
```

**Existenzquantoren sind einfach zu entschachteln.**

# Allquantor

Product (pname, price, cid) Company(cid, cname, city)

Finde alle Firmen, die nur Produkte mit Preis unter 150 haben.

```
SELECT DISTINCT C.cname
FROM Company C
WHERE NOT EXISTS (SELECT *
                   FROM Product P
                   WHERE P.cid = C.cid AND P.price >= 150)
```

Wie sehen die **alternativen Formulierungen** mit **ALL** und **NOT IN** aus?

# Entschachteln von Anfragen

**Beispielanfrage, die für jeden Studenten dessen bestes Examen berechnet:**

```
SELECT s.name, e.course
FROM students s, exams e
WHERE s.id = e.sid AND
      e.grade = (SELECT min(e2.grade)
      FROM exams e2
      WHERE s.id = e2.sid)
```

- **Unteranfrage ist abhängig von der äußeren Anfrage**
- Für jedes Paar von Student und Examen (s,e) muss im Prinzip geschaut werden ob diese Prüfung auch die beste des Studenten ist.
- Ein sogenannter **dependent Join**.

# Entschachteln von Anfragen

Die vorherige Anfrage kann umgeformt werden zu

```
SELECT s.name, e.course
FROM students s, exams e,
      (SELECT e2.sid as id, min(e2.grade) as best
       FROM exams e2
       GROUP BY e2.sid) m
WHERE s.id = e.sid AND
       s.id=e.sid AND m.id=s.id AND e.grade=m.best
```


D.h. wir haben zwar eine Verschachtelung, aber keine abhängige Unteranfrage. Prima.




## Dependent Join

Analog, finde Firmennamen und Produktnamen der teuersten Produkte der Firma.

```
SELECT DISTINCT c.cname, px.pname
FROM company c, product px
WHERE c.cid = px.cid
      and px.price = (SELECT max(p.price)
                     FROM product p
                     WHERE c.cid=p.cid);
```





|    | QUERY PLAN<br>text  |
|----|---|
| 1  | HashAggregate (cost=2182.64..2182.65 rows=1 width=436)          |
| 2  | Group Key: c.cname, px.pname                                    |
| 3  | -> Hash Join (cost=14.25..2182.64 rows=1 width=436)             |
| 4  | Hash Cond: ((px.cid = c.cid) AND (px.price = (SubPlan 1)))      |
| 5  | -> Seq Scan on product px (cost=0.00..13.10 rows=310 width=226) |
| 6  | -> Hash (cost=11.70..11.70 rows=170 width=222)                  |
| 7  | -> Seq Scan on company c (cost=0.00..11.70 rows=170 width=222)  |
| 8  | SubPlan 1   |
| 9  | -> Aggregate (cost=13.88..13.89 rows=1 width=4)                 |
| 10 | -> Seq Scan on product p (cost=0.00..13.88 rows=2 width=4)      |
| 11 | Filter: (c.cid = cid)   |

# Dependent Join

## Dependent Join

- Naiver Nested Loops Join, bei dem die rechte Relation von dem aktuellen Tupel der linken Seite abhängt.
- Zur Erinnerung, “normaler Join”

$$T_1 \bowtie_p T_2 := \sigma_p(T_1 \times T_2)$$

- Dependent Join hingegen ist definiert als

$$T_1 \bowtie_p T_2 := \{t_1 \circ t_2 \mid t_1 \in T_1 \wedge t_2 \in T_2(t_1) \wedge p(t_1 \circ t_2)\}$$

- Wenn wir mit  $\mathcal{A}(T)$  die Attribute eines Ausdrucks  $T$  der rel. Algebra bezeichnen und mit  $\mathcal{F}(T)$  die freien Variablen in  $T$ , dann muss  $\mathcal{F}(T_2) \subseteq \mathcal{A}(T_1)$  gelten.

# Dependent Join und Potenzial von Entschachtelung

## Ziel der Entschachtelung

- Ersetze dependent Join durch “normalen” Join
- Wieso?

## Potenzial

- Nach der Entschachtelung können andere Implementierungen des Join-Operators benutzt werden, nicht nur Nested Loops Join.
- Dies bringt natürlich mehr Flexibilität und bringt in der Regel große Gewinne in der Performance der Anfrage.

Weitere Literatur: Aktuelle Arbeit von Neumann und Kemper. Unnesting Arbitrary Queries. Fachtagung Datenbanksysteme für Business, Technologie und Web (BTW), 2015.

# Optimierung von mehreren Anfragen

## Multi Query Optimization

- Gegeben eine Menge von Anfragen, die von einem oder mehreren Benutzern “zeitgleich” an die DB geschickt wurden.
- DB kann nun schauen ob Anfragen Gemeinsamkeiten haben, um Berechnungskosten für die gesamte Menge zu verringern.

## Beispiel: Gegeben sind folgende Anfragen

```
SELECT * FROM (R NATURAL JOIN T) NATURAL JOIN S  
SELECT * FROM (R NATURAL JOIN U) NATURAL JOIN S
```

Welche Gemeinsamkeiten gibt es hier?

## Optimierung von mehreren Anfragen (2)

```
SELECT * FROM (R NATURAL JOIN T) NATURAL JOIN S  
SELECT * FROM (R NATURAL JOIN U) NATURAL JOIN S
```

- Der Joinoperator ist kommutativ und assoziativ, wie wir gesehen haben.
- Also, beide Anfragen haben gemeinsam den Join zwischen R und S.

## Optimierung von mehreren Anfragen (3)

Wir können die Anfragen also “umschreiben” zu ...

```
SELECT * FROM (R NATURAL JOIN S) NATURAL JOIN T  
SELECT * FROM (R NATURAL JOIN S) NATURAL JOIN U
```

- ... und die **Teilanfrage (R NATURAL JOIN S) nur ein Mal ausführen.**
- Was gibt es dabei zu beachten?
- Evtl. ist die Teilanfrage (R **NATURAL JOIN** S) sehr teuer.
- **Mögliche Vorgehensweise:** Jede Anfrage wird getrennt voneinander übersetzt und dann erst geschaut ob es gemeinsame Teilausdrücke gibt.
- Eine einfache Möglichkeit: **Shared Scans**, d.h. Lesen der Relationen wird nur ein Mal ausgeführt, für versch. Anfragen.

# Materialisierte Sichten (Materialized Views)

## Vgl. (Dynamische) Sicht

- =Makro für Query
- Ergebnis der Anfrage wird nicht vorberechnet
- Rechenaufwand zum Zeitpunkt der Anfrage (=query time)
- erst wenn die Sicht benutzt wird, wird auch das Ergebnis der Sicht berechnet

## Materialisierte Sicht

- Ergebnis der Sicht wird **vorberechnet**
- wenn eine Anfrage die Sicht benutzt, ist das Ergebnis der Sicht bereits vollständig berechnet
- Rechenaufwand vorher
- Problem bei Updates:  
Tabellen, die zur Vorbereitung der Sicht benutzt werden, ändern sich ⇒ Materialisierte Sicht muss angepasst werden



## Ausnutzen von Materialisierten Sichten

Gegeben eine **materialisierte Sicht**, die durch folgende Anfrage erzeugt wurde:

```
SELECT  $L_V$   
FROM  $R_V$   
WHERE  $C_V$ 
```

Daneben haben wir eine **Anfrage**, die wie folgt aufgebaut ist

```
SELECT  $L_Q$   
FROM  $R_Q$   
WHERE  $C_Q$ 
```

$L_V$  ist eine Liste von Attributen,  $R_V$  eine Liste von Relationen und  $C_V$  ein Prädikat. **Kann teil der Anfrage durch Sicht V ersetzen, falls folgendes gilt:**

- Alle Relationen auf  $R_V$  treten auch in der Liste  $R_Q$  auf
- Das Prädikat  $C_Q$  ist äquivalent zu  $C_V$  **AND**  $C$ , für ein Prädikat  $C$ . Oder einfach nur identisch zu  $C_V$ .
- Für den Fall, dass  $C$  gebraucht wird müssen entsprechende Attribute in  $L_V$  vorhanden sein, bzw. in den Relationen  $R_V$ .
- Attribute aus  $L_Q$  sind auch in  $L_V$

## Annutzen von Materialisierten Sichten (2)

```
SELECT  $L_V$   
FROM  $R_V$   
WHERE  $C_V$ 
```

```
SELECT  $L_Q$   
FROM  $R_Q$   
WHERE  $C_Q$ 
```

... also falls die Bedingungen von zuvor zutreffen, dann kann man die Anfrage so anpassen, dass die View benutzt wird, durch:

- Ersetze die Liste von Relationen  $R_Q$  durch die View  $V$  und alle restlichen Relationen, die nicht in  $R_V$  sind.
- Ersetze  $C_Q$  durch  $C$ , falls  $C$  nicht gebraucht wird (weil  $C_V = C_Q$ ), dann gibt es keine WHERE Klausel.

# Materialisierte Sichten Bestimmung

## (engl. **Materialized View Selection**)

- Welche Views sollen materialisiert werden?
- Frage ist ähnlich zur Frage welche Indexe angelegt werden sollen.
- Auch hier müssen Information zum **Workload** (welche Queries, wie oft, welche Indexe gibt es, welche Updates) gegeben sein.

## Richtlinien, welche Sichten evtl. angelegt werden sollen

- Sichten sollten Relationen in **FROM** Klausel haben, die Teilmenge der FROM Klausel von Anfragen des Workloads sind.
- Die **WHERE** Klausel besteht aus einem Prädikat, das Teil eines konjunktiven (AND) Prädikats von Anfragen ist.
- Attribute, die in der **SELECT** Klausel sind ausreichend um Anfragen des Workloads zu beantworten.

# Updates und Materialisierte Sichten

- Wenn sich die Tabellen, die einer materialisierten Sicht zugrunde liegen ändern, so haben diese Änderungen auch Auswirkungen auf die Sicht.
- Für jede kleine Änderung eine komplette Neuberechnung der Sicht auszuführen ist natürlich keine gute Idee.

## Inkrementelle Instandhaltung von materialisierten Sichten

- Z.B. Sicht  $V = R \bowtie S$ . Relation  $R$  wird verändert. Wir haben also  $V^{alt}$ ,  $R^{alt}$  und  $R^{neu}$ .
- Versuchen dann  $V^{neu}$  zu bestimmen, ohne neue Berechnung.
- **Fall Insert:** Betrachte dazu in  $R^{alt}$  eingefügtes Tupel  $i_R$ . Dann  $V^{neu} = V^{alt} \cup (i_r \bowtie S)$ . Ähnlich bei Delete, Selektion, ...
- Auch periodische oder durch andere Kriterien angestoßene Neuberechnung, z.B. nachts.

# Tuning des Datenbankschemas

- Neben dem Tuning mit Hilfe von Indexen kann auch das Schema einer Datenbank benutzt werden, um die Performance der Anfrageausführung zu erhöhen.
- Auch hierfür braucht man Annahmen bzw. Erfahrungswerte über Datenbank Workloads, d.h. welche Anfragen werden wie oft ausgeführt.

## Wiederholung: Normalisierung von Relationen

Um Qualitätsprobleme im ursprünglichen Entwurf zu beheben, wird das bestehende Relationenschema  $\mathcal{R}$  in mehrere Relationenschemata  $\mathcal{R}_1, \dots, \mathcal{R}_n$  zerlegt, die dann “besser” sind.

- Die Güte einer Zerlegung wird mit **Normalformen** beschrieben.
- Normalformen: 1NF, 2NF, 3NF, BCNF, 4NF, ...

### Korrektheitskriterien für Zerlegung:

- **Verlustlosigkeit:** Die in der ursprünglichen Relationenausprägung  $R$  des Schemas  $\mathcal{R}$  enthaltenen Daten müssen aus den Ausprägungen  $R_1, \dots, R_n$  der neuen Relationenschemata  $\mathcal{R}_1, \dots, \mathcal{R}_n$  rekonstruierbar sein.
- **Abhängigkeitsbewahrung:** Alle FDs in  $F_{\mathcal{R}}$  sollten in den  $F_{\mathcal{R}_1}, F_{\mathcal{R}_2}, \dots, F_{\mathcal{R}_n}$  bewahrt bleiben.

## Wiederholung: Dritte Normalform

- Intuition: Nicht-Schlüssel Attribut darf kein anderes Nicht-Schlüssel Attribut bestimmen.

Ein Relationenschema  $\mathcal{R}$  ist in dritter Normalform, wenn für jede für  $\mathcal{R}$  geltende FD der Form  $\alpha \rightarrow B$  mit Attribut  $B \in \mathcal{R}$  mindestens eine von drei Bedingungen gilt:

1.  $B \in \alpha$ , d.h. die FD ist **trivial**
2.  $\alpha$  is **Superschlüssel** von  $R$
3.  $B$  ist **prim**

### Eigenschaften:

- 3NF verhindert **partielle und transitive** Abhängigkeiten
- 3NF  $\Rightarrow$  2NF

## Wiederholung: Boyce-Codd-Normalform

Die Boyce-Codd-Normalform (BCNF) ist nochmals eine Verschärfung der 3NF. **Intuition:** Jedes Attribut darf **nur** den gesamten Schlüssel beschreiben und nichts anderes.

**Ein Relationenschema  $\mathcal{R}$  mit FDs  $F$  ist in BCNF, wenn für jede für  $\mathcal{R}$  geltende funktionale Abhängigkeit der Form  $\alpha \rightarrow B$  mit Attribut  $B \in \mathcal{R}$  mindestens eine von zwei Bedingungen gilt:**

1.  $B \in \alpha$ , d.h. die FD ist **trivial**
  2.  $\alpha$  ist Superschlüssel von  $\mathcal{R}$
- Unterschied zu 3NF: 3. Bedingung fällt weg (B ist prim).
  - Man kann jede Relation **verlustlos** in BCNF-Relationen zerlegen
  - **Aber:** manchmal lässt sich dabei die **Abhängigkeitserhaltung nicht** erzielen!



# Tuning des Datenbankschemas: Beispiel

**Contracts**(cid: integer, supplierId: integer, projectId: integer,  
deptId: integer, partId: integer, qty: integer, value: real)

**Departments**(did: integer, budget: real, annualreport: varchar)

**Parts**(pid: integer, cost)

**Projects**(jid: integer, mgr: char(20))

**Supplier**(sid: integer, address: char(50))

Ein Tupel in der Relation Contract, gegeben durch cid C, ist ein Vertrag, dass Anbieter S (sid) eine Anzahl von Q (qty) Items des Typs P (pid) zu Project J (jid), assoziiert mit Abteilung D (did) liefert, der Wert dieses Vertrags ist *value* V.

## Tuning des Datenbankschemas: Beispiel (Cont'd)

**Contracts**(cid: integer, supplierId: integer, projectId: integer,  
deptId: integer, partId: integer, qty: integer, value: real)

**Departments**(did: integer, budget: real, annualreport: varchar)

**Parts**(pid: integer, cost)

**Projects**(jid: integer, mgr: char(20))

**Supplier**(sid: integer, address: char(50))

Wir haben folgende funktionale Abhängigkeiten (FDs), für Contracts:

- **Ein Projekt kauft ein Produkt mit einem einzelnen Vertrag.**  
D.h. es gibt keine zwei verschiedene Verträge eines Projekts über das selbe Produkt.  $JP \rightarrow C$
- **Eine Abteilung kauft nicht mehr als ein Produkt von einem bestimmten Anbieter:**  $SD \rightarrow P$
- Natürlich ist C (cid) Schlüssel

## Tuning des Datenbankschemas: Beispiel (Cont'd)

- Betrachten wir die funktionale Abhängigkeit  $SD \rightarrow P$
- $P$  ist prim, da Teil des Kandidatenschlüssels  $JP$ , also ist **Contracts in 3NF**
- Aber sie ist **nicht in BCNF**.

### Zerlegung in BCNF

- Anhand von  $SD \rightarrow P$
- D.h. wir bekommen zwei Relationen  $SDP$  und  $CSJDQV$ .
- Leider nicht abhängigkeitsbewahrend:  $JP \rightarrow C$  kann nicht mehr überprüft werden; müssten also Relation  $JPC$  noch dazu anlegen.

**Was ist nun falls folgende Frage häufig auftritt: Finde die Anzahl (Q) der bestellten Teile für P in Vertrag C?**

# Denormalisierung

Es kann Sinn machen aus Gründen der Performance auf eine mögliche starke Normalform zu verzichten.

- Die durch die bei Anfragen evtl. wegfallenden Joins wird die Performance erhöht.
- **Jedoch werden Daten redundant gespeichert.**
- D.h. es besteht ein **nicht trivialer Tradeoff zwischen Performance und Redundanz.**

## Denormalisierung (2)

- Wie wir gesehen haben ist die **Relation Contracts in 3NF**.
- Was ist wenn eine **häufig auftretende Anfrage** überprüfen soll, dass der Wert eines Vertrags das Budget der Abteilung nicht übersteigt?

Zur Erinnerung:

**Contracts**(cid: integer, supplierId: integer, projectId: integer,  
deptId: integer, partId: integer, qty: integer, value: real)

**Departments**(did: integer, budget: real, annualreport: varchar)

...

### Idee

- **Wir könnten budget aus der Relation Departments in die Relation Contracts aufnehmen.**
- Was bedeutet dies?

## Denormalisierung (3)

- Die Anfrage könnte nun sehr effizient ausgeführt werden.
- Aber mit dieser Änderung ist Contracts **nicht mehr in 3NF**, da wir nun die funktionale Abhängigkeit  $D \rightarrow B$  haben.
- Trotzdem könnte man mit dieser Redundanz evtl. leben, je nachdem wie wichtig die Performance der Anfrage ist (**Tradeoff!**)

# Vertikale Partitionierung

- Nehmen wir die Zerlegung der Relation Contracts in SDP und CSJDQV an, welche nun in BCNF sind.
- Weiter nehmen wir an, dass die folgenden beiden Anfragen häufig auftreten:
  - Finde alle Verträge (Contracts) vom Anbieter S
  - Finde alle Verträge von Abteilung D

## Zerlegung von CSJDQV

- Wir könnten die Relation CSJDQV zerlegen in: CS, CD und CJQV.
- Was ist der Vorteil solch einer Zerlegung?
- Was ist wenn die folgende Anfrage häufig auftritt: Finde die Summe aller Values der Verträge eines bestimmten Anbieters?

# Zusammenfassung Anfrageverarbeitung und Optimierung

- Wie kann auf Daten zugegriffen werden? Gibt es Indexe und wie liegen die Daten auf der Festplatte?
- Diverse Pufferstrategien wie CLOCK, LRU.
- Wie können Joins implementiert werden? Hash vs. Sort-Merge vs. Nested-Loops
- Welche Implementierung bzw. welcher Index eignet sich für Anfrage?
- Welche Option ist am günstigsten?
- Regelbasierte und Kostenbasierte Optimierung.
- Wie werden Kosten berechnet bzw. abgeschätzt?
- Suchraum der Anfrageoptimierung.
- Weitere Tricks zur Anfrageoptimierung, z.B. Entschachteln von Anfragen.