

Data Warehousing

Answering Queries using Views

Ulf Leser

Wissensmanagement in der
Bioinformatik



Inhalt dieser Vorlesung

- Materialisierte Sichten
- Answering Queries Using Views
- Query Containment
- Ableitbarkeit
- Query Optimierung mit MVs
- MVs in Oracle

Materialisierte Sichten (MV)

- Grundidee
 - Viele Anfragen wiederholen sich häufig
 - Bilanzen, Bestellungsplanung, Produktionsplanung
 - Kennzahlenberechnung
 - Viele Anfragen sind Variationen derselben Anfrage
 - Alle Verkäufe nach Produkt, Monat und Region
 - Alle Verkäufe in Region X nach Produkt, Monat und Shop
 - Alle Verkäufe in Region Y nach Produkt, Monat und Shop
- Materialisierter View
 - Einmaliges Berechnen und Speichern einer Anfrage
 - Transparente Verwendung in folgenden Anfragen

Arbeiten mit einem Cube ...

```
SELECT L.shop_id, P.product_id, T.day_id, sum(amount*price)
FROM sales S, time T, product P, localization L
WHERE   S.day_id = T.day_id AND
        S.product_id = P.product_id AND
        S.shop_id = L.shop_id AND
        P.pg_id = 159
GROUP BY L.shop_id, P.product_id, S.time_id
```

```
SELECT L.shop_id, P.product_id, T.day_id, sum(amount*price)
FROM sales S, time T, product P, localization L
WHERE   S.day_id = T.day_id AND
        S.product_id = P.product_id AND
        S.shop_id = L.shop_id AND
        P.pg_id = 159
GROUP BY L.region_id, P.product_id, S.time_id
```

```
SELECT L.shop_id, P.product_id, T.day_id, sum(amount*price)
FROM sales S, time T, product P, localization L
WHERE   S.day_id = T.day_id AND
        S.product_id = P.product_id AND
        S.shop_id(+) = L.shop_id AND
        P.pg_id = 159 AND
        T.year = ,1999'
GROUP BY L.shop_id, P.product_id, S.time_id
```

Roll-Up

„Slice“

Materialisierter View

```
CREATE MATERIALIZED VIEW all_groups
AS
SELECT L.shop_id, P.product_id, T.day_id, T.year, P.pg_id,
       sum(amount*price)
FROM sales S, time T, product P, localization L
WHERE   S.day_id = T.day_id AND
        S.product_id = P.product_id AND
        S.shop_id = L.shop_id
GROUP BY L.shop_id, P.product_id, S.time_id
```

```
SELECT * FROM all_groups A
WHERE   A.pg_id = 159
```

OK

```
SELECT * FROM all_groups A
WHERE   A.pg_id = 159
Group by A.region_id
```

Nein

```
SELECT * FROM all_groups A
WHERE   P.pg_id = 159 AND
        // S.shop_id(+) = L.shop_id AND
        T.year = ,1999'
```

Nein

Materialisierte Sichten – Themen

- Wahl von Views zur Materialisierung
 - MVs kosten: Platz und Aktualisierungsaufwand
 - Wahl der optimalen MVs hängt von Workload ab
 - Auswahl der „optimale“ Menge von MV
- Automatische Aktualisierung von MV
 - Aktualisierung bei Änderungen
 - U.U. schwierig: Aggregate, Joins, Outer-Joins, ...
 - Algorithmen zur inkrementellen Aktualisierung
- Automatische Verwendung von MV
 - „Answering Queries using Views“
 - Umschreiben der Anfrage notwendig
 - Schwierigkeit hängt von Komplexität der Anfrage / Views ab
 - Algorithmen zur transparenten und kostenoptimalen Verwendung der materialisierten Sichten

Answering Queries using Views

- Gegeben
 - Eine Query q
 - Eine Menge V von materialisierten Views
- Fragen
 - Kann man Antworten für q unter Verwendung von V berechnen?
 - Kann man q **nur mit Views** aus V beantworten?
 - Kann man q unter Verwendung von V **korrekt beantworten**?
 - Ist es günstig, Views aus V zur Beantwortung von q zu verwenden? Welche?
 - ...


➤ **Viele und schwierige Probleme**

Datalog Notation

- Schreibweise: **Datalog**
 - $q(X, Y) :-$
 $\text{sales}(X, A, B, C), \text{time}(A, Y, D), D > 1999$
 - SELECT Klausel
 - Regelkopf, „Exported Variables“
 - FROM Klausel
 - Relationen werden zu Prädikaten
 - Attribute werden über Position statt Name adressiert
 - WHERE Klausel
 - Joins werden durch gleiche Variablen in verschiedenen Prädikaten angezeigt
 - Bedingungen mit „>, <„ werden explizit angegeben
 - Gleichheitsbedingungen „Attribut = Wert“ werden durch Konstante in Literal angegeben

SQL – Datalog

```
SELECT S.price, L.region_name
FROM sales S, time T, localization L, product P
WHERE S.day_id = T.day_id AND
      S.product_id = P.product_id AND
      S.shop_id = L.shop_id AND
      L.shop_name = 'KB' AND
      T.year > 1999
```



Begriffe

```
q(P, RN) :-  
    sales(SID, PID, TID, LID, P, ...),  
    time(TID, D, M, Y),  
    localization(LID, 'KB', RN),  
    product(PID, PN, PGN),  
    Y > 1999
```

- q ist der **Kopf** (oft synonym für ganze Query)
- **Variablen** sind in GROSSBUCHSTABEN
- sales, time, .. sind **Prädikate**
 - Relationen des Schemas
- sales(SID, ...), time(TID, ...) sind **Literale**
 - Eine Query kann ein Prädikat mehrmals enthalten - mehrere Literale desselben Prädikats
 - Literale sind eindeutig

Query Containment

- Gegeben
 - Query q
 - View v (zunächst nur einer)
- Anfrageäquivalenz
 - Ist Ergebnis von v identisch dem Ergebnis von q ?
 - Kurz: Ist v äquivalent zu q , $V \Leftrightarrow Q$
- Anfragecontainment („enthalten in“)
 - Ist das Ergebnis von v im Ergebnis von q enthalten?
 - Kurz: Ist v in q enthalten, $V \subseteq Q$
- Rückführung
 - $V \subseteq Q, Q \subseteq V \Rightarrow V \Leftrightarrow Q$
- Frage: Definition von „äquivalent“, „enthalten in“ für Queries?

Definition

- Definition
 - Sei S ein Schema. Seien q_1 und q_2 Anfragen gegen S
 - Eine *Instanz* von S ist eine beliebige Datenbank D mit Schema S , geschrieben D^S
 - Das *Ergebnis* einer Query q in einer Datenbank D^S , geschrieben $q(D^S)$, ist die Menge aller Tupel, die die Ausführung von q in D^S ergibt (zur genauen Semantik siehe Domänen / Tupelkalkül)
 - q_1 ist äquivalent zu q_2 , geschrieben $q_1 \Leftrightarrow q_2$, gdw.
 $q_1(D^S) = q_2(D^S)$ für jede mögliche Instanz D^S von S
 - q_1 ist enthalten in q_2 , geschrieben $q_1 \subseteq q_2$, gdw.
 $q_1(D^S) \subseteq q_2(D^S)$ für jede mögliche Instanz D^S von S
- **Semantische Definition:** Es zählt das Ergebnis einer Query, nicht die Syntax

Beispiele

Regelkopf wird hier unterschlagen

$q \Leftrightarrow q$

$\text{product}(\text{PID}, \text{PN}, \text{PGID}, \text{'Wasser'}) \subseteq \text{product}(\text{PID}, \text{PN}, \text{PGID}, \text{PGN})$

$\text{product}(\text{PID}, \text{PN}, \text{PGID}, \text{PGN}) \not\subseteq \text{localization}(\text{SID}, \text{SN}, \text{RID}, \text{RN})$

$\text{product}(\text{PID}, \text{PN}, \text{PGID}, \text{PGN}), \text{PGN} > \text{'Wasser'} \subseteq \text{product}(\text{PID}, \text{PN}, \text{PGID}, \text{PGN})$

$\text{sales}(\text{SID}, \text{PID}, \dots, \text{P}, \dots), \text{P} > 80, \text{P} < 150 \not\subseteq \text{sales}(\text{SID}, \text{PID}, \dots, \text{P}, \dots), \text{P} > 100, \text{P} < 150$

$\text{sales}(\text{SID}, \text{PID}, \dots, \text{P}, \dots), \text{P} > 100, \text{P} \leq 150, \text{P} < 170, \text{P} \geq 150 \Leftrightarrow \text{sales}(\text{SID}, \text{PID}, \dots, 150, \dots)$

$\text{sales}(\text{SID}, \text{PID}, \dots, \text{P}, \dots), \text{product}(\text{PID}, \text{PN}, \dots) \subseteq \text{sales}(\text{SID}, \text{PID}, \dots, \text{P}, \dots)$
(Bei Projektion auf sales)

Weitere Beispiele

$q_1(B, D) :- \text{path}(A, B), \text{path}(B, C), \text{path}(C, D), \text{path}(D, E)$
 $q_2(A, C) :- \text{path}(A, B), \text{path}(B, C), \text{path}(C, D)$
 $q_1 \subseteq q_2$



$q_1(C, B) :- \text{path}(A, B), \text{path}(C, A), \text{path}(B, C), \text{path}(A, D)$
 $q_2(X, Z) :- \text{path}(X, Y), \text{path}(Y, Z)$
 $q_1 \subseteq q_2$



$q_1(A, C) :- \text{path}(A, B), \text{path}(B, C)$
 $q_2(A, C) :- \text{threeNodePath}(A, B, C)$
 $q_1 \subseteq q_2$



$q_1(B, D) :- \text{path}(A, B), \text{path}(B, C), \text{path}(C, D), \text{path}(A, E), \text{path}(E, D)$
 $q_2(A, C) :- \text{path}(A, C), \text{path}(C, E), \text{path}(E, A), \text{path}(A, B), \text{path}(D, C)$
 $q_1 \subseteq q_2$



Wie kann man Containment beweisen?

- *Definition*

Ein *Containment Mapping* (CM) h von Anfrage q_2 nach Anfrage q_1 ist ein Symbol Mapping von q_2 nach q_1 für das gilt:

- $\forall s \in \text{constants}(q_2)$ gilt: $h(s) = s$
 - Jede Konstante in q_2 wird auf dieselbe Konstante in q_1 abgebildet
- $\forall l \in q_2$ gilt: $\exists l' \in q_1$ mit $h(l) = l'$
 - Jedes Literal in q_2 wird auf (mindestens) ein Literal in q_1 abgebildet
- $h(\text{head}(q_2)) = \text{head}(q_1)$
 - Der Kopf von q_2 wird auf den Kopf von q_1 abgebildet
- Die Bedingungen von q_1 implizieren die Bedingungen von $h(q_2)$

- *Bemerkung*

- Jede exportierte Variable in q_2 wird als auf eine exportierte Variable in q_1 abgebildet, und zwar die erste auf die erste, die zweite auf die zweite, etc.

Vom Containment Mapping zum Query Containment

- *Theorem*
 - $q_1 \subseteq q_2$ gdw. es ein CM von q_2 nach q_1 gibt
- *Lemma*
 - $q_1 \Leftrightarrow q_2$ gdw. es ein CM von q_2 nach q_1 und ein CM von q_1 nach q_2 gibt
- *Beweise*
 - Nicht schwierig; über die Semantik von Anfragen
 - Literatur
- *Richtungen beachten!*
 - Containment Mapping von q_2 nach q_1
 - Bedingungen von q_1 implizieren Bedingungen von q_2

Aufgabe

- Gegeben
 - Query q
 - View(s) v
- Gesucht
 - Eine Methode, q mit Hilfe von v zu beantworten
- Ist das Query Containment?
 - Nur fast – v muss eventuell modifiziert werden
- Trick
 - Was nicht passt, wird passend gemacht

Anwendung

- Möglichkeit 1: q nicht in v , v nicht in q
 - Kein (erkennbarer) Zusammenhang zwischen Queries
 - v wird nicht für q benutzt
- Möglichkeit 2: v und q äquivalent
 - v als Ergebnis von q ausgeben
 - Seltener Spezialfall
 - Test auf Äquivalenz sehr teuer (2 x Containment)
 - Benutzung nur bei „syntaktischer Äquivalenz“

Anwendung

- Möglichkeit 3: v in q aber nicht umgekehrt
 - v ist ein partielles Ergebnis für q
 - Jedes Tupel von v ist korrekte Antwort für q , aber v berechnet nicht alle korrekten Antworten
 - Erweiterung von v i.d.R. nicht hilfreich
 - Berechnung von $q \setminus v$ nicht trivial
 - Nur selten einfache (und damit schnelle) Lösungen
 - Keine Verwendung (in Datenbanken), aber
 - Informationsintegration
 - Datentransformationen

Anwendung 2

- Möglichkeit 4: q in v aber nicht umgekehrt
 - Ergebnis von q vollständig enthalten in v
 - Nicht alle Tupel von v sind korrekte Ergebnisse für q , aber v berechnet alle Ergebnisse von q
 - Manche Tupel müssen aus dem Ergebnis von v entfernt werden
- Probleme
 - **Vollständigkeit**: v enthält alle Tupel – auch die richtigen Attribute?
 - **Ableitbarkeit**: Wie findet man Filter F auf v , so dass nur die richtigen Tupel selektiert werden, also $F(v) \Leftrightarrow q$?

2. Ableitbarkeit

- Jetzt hat man alle Attribute, aber zu viele Tupel
- Wie findet man die richtigen?

➤ Ableitbarkeit

- Wenn $q \subseteq v$, dann gilt: $\forall t: q(t) \Rightarrow v(t)$
- Gesucht: Formel F : $\forall t: q(t) \Leftrightarrow v(t) \wedge F(t)$
- Der allgemeine Fall ist **unentscheidbar** wegen Unentscheidbarkeit der Prädikatenlogik
- Deswegen viele Einschränkungen auf den zugelassenen Operationen in q und v
 - Konjunktive Anfragen

Beispiel

Annahme: q und v enthalten dieselben Literale und Joins

$v_1(P, PN, SN)$	$:-$	$s(SID, PID, LID, P), p(PID, PN), l(LID, SN)$
$v_2(P, PN, SN)$	$:-$	$s(SID, PID, LID, P), p(PID, PN), l(LID, SN)$ $P > 100, P < 300, SN = ,Kreuzberg'$
$q_1(P, PN, SN)$	$:-$	$s(SID, PID, LID, P), p(PID, PN), l(LID, SN),$ $PN = ,Gerolsteiner'$
$q_2(P, PN, SN)$	$:-$	$s(SID, PID, LID, P), p(PID, PN), l(LID, SN),$ $P > 100, P < 200, SN = ,Kreuzberg'$
$q_3(P, PN, SN)$	$:-$	$s(SID, PID, LID, P), p(PID, PN), l(LID, SN),$ $SN = ,Kreuzberg'$

$v_1 \wedge PN = ,Gerolsteiner' \Leftrightarrow q_1$

$v_1 \wedge \dots \Leftrightarrow q_x$

$v_2 \wedge \dots \not\Leftrightarrow q_1$

$v_2 \wedge P < 200 \Leftrightarrow q_2$

$v_2 \wedge \dots \not\Leftrightarrow q_3$

2.3 Ableitbarkeit von Gruppierungen

- Annahmen
 - q und v haben die Form

```
SELECT G1, G2, . . . , Gn, sum(A1)
FROM . . .
WHERE . . .
GROUP BY G1, G2, . . . Gn
```
 - Ohne Gruppierung / Aggregation soll gelten: $q \Leftrightarrow v$
 - Bzw. $q \Leftrightarrow h(v) \wedge B \wedge J$
- Wir betrachten nur die Aggregatsfunktion SUM
 - Bei anderen Funktionen Summierbarkeit über Hierarchien beachten
- $G_1, G_2, \dots, G_n$ sind die **Gruppierungsattribute**
 - Nur hier seien Unterschiede zwischen q und v

Intuition

- Sei v

```
SELECT  T.year_id, T.month_id,  
        T.day_id, sum(...)  
FROM    Sales S, Time T  
WHERE   ...  
GROUP BY T.year_id, T.month_id,  
        T.day_id
```

- Welche Gruppierungen in einer Query q können mit v berechnet werden?

Year	Month	Day	SUM
1997	1	1	150
1997	1	2	130
1997	1	3	145
1997	1	4	122
...	...	...	...
1997	1	31	145
1997	2	1	133
1997	2	2	122
...	...	...	...
1997	3	10	180
1997	12	31	480
1998	1	1	240
...	...	...	...
2003	6	18	345

Beobachtung

- In v sind alle Kombinationen von $G = \{\text{YEAR_ID}, \text{MONTH_ID}, \text{DAY_ID}\}$ mit Summe vorhanden
- Aufsummierung für jede Untermenge von G möglich

```
SELECT  T.year_id, T.month_id,  
        sum(...)  
FROM    v  
GROUP BY T.year_id, T.month_id
```

```
SELECT  T.year_id, T.day_id,  
        sum(...)  
FROM    v  
GROUP BY T.year_id, T.day_id
```

Year	Month	SUM
1997	1	15000
1997	2	13300
...	...	...
1997	12	48000
1998	1	24000
...	...	...
2003	6	34500

Year	Day	SUM
1997	1	1500
1997	2	1330
...	...	...
1997	31	4800
1998	1	2400
...	...	...
2003	30	3450

Sommersemester 2005

5

Orthogonale Gruppierungen

- Sei v

```
SELECT  T.month_id, P.pg_id,  
        R.shop_name, sum(...)  
FROM    Sales S, Time T, Product P,  
        Region R  
WHERE   ...  
GROUP BY T.month_id, P.pg_id,  
        R.shop_name
```

Month	PG_ID	Shop_name	SUM
1	22245	KB	150
1	22245	Mitte	130
...	...	...	145
1	22246	KB	133
1	22246	Mitte	144
...	...	...	122
2	22245	KB	122
2	22245	Mitte	...
...	...	...	145

```
SELECT  P.pg_id, R.shop_name,  
        sum(...)  
FROM    v  
GROUP BY P.pg_id,  
        R.shop_name
```

```
SELECT  P.month_id, sum(...)  
FROM    v  
GROUP BY P.month_id
```

Direkte Ableitbarkeit

- Theorem

- Sei v ein View mit Gruppierungsattributen G_v und q eine Query mit Gruppierungsattributen G_q und q und v haben äquivalente SPJ Klauseln
 - SPJ: „Select – Project – Join“
- q ist **direkt ableitbar** aus v , $q \succ_1 v$, gdw.
 - $G_q \subset G_v$ und $|G_q| = |G_v| - 1$ oder
 - $G_q = G_v \setminus a_x \cup a_y$ mit $a_x \in G_v$, $a_y \notin G_v$ und a_y ist funktional abhängig von a_x

- Funktionale Abhängigkeit


- Foreign Key Constraints
- Zusicherung wie „CREATE DIMENSION ... ATTRIBUTE DETERMINES ...“

Ableitbarkeit


- Lemma
 - q ist *ableitbar* aus v , $q \succ v$, gdw.
 - q ist direkt ableitbar aus v oder
 - Es existieren Views $v_1, \dots, v_n$ so, dass: $q \succ v_n \succ \dots \succ v_1 \succ v$
- Also
 - Jede **Untermenge einer Menge von Gruppierungsattributen** ist aus dieser ableitbar

Ableitbarkeit bei funkt. Abhängigkeiten

```
SELECT T.month_id, P.pg_id, R.shop_name, sum(...)
FROM   Sales S, Time T, Product P, Region R
WHERE  ...
GROUP BY T.month_id, P.pg_id, R.shop_name
```



```
SELECT T.year_id, v.pg_id,
       v.shop_name, v.sum
FROM   v, Time T
WHERE  v.month_id = T.month_id
GROUP BY T.year_id, v.pg_id,
       v.shop_name
```




```
SELECT v.month_id, P.pg_name,
       v.shop_name
FROM   v, Product P
WHERE  v.pg_id = P.pg_id
```

- Erfordert Rewriting mit zusätzlichen Joins
- Eventuell **weitere Aggregationen**
 - Abh. innerhalb einer Klassifikationsstufe: Keine Agg.
 - Abh. zwischen K-stufen: Agg. entlang der Hierarchie




Aggregationsgitter



Aggregationsgitter: Verwendung

- Gegeben eine Menge Z von Queries mit Gruppierung
- Gesucht: „Optimale“ Menge Z' von Views, mit der sich alle Queries berechnen lassen
 - Optimal: Maximale Zeitersparnis
 - Optimal: Minimaler Platzverbrauch/ Aktualisierungszeit
- Mögliches Vorgehen
 - Erstellen des kompletten Aggregationsgitter des Models
 - Markierung der Gruppierungsmengen aus Z
 - Wahl von Z'
 - Kleinsten gemeinsamer Vorfahr aller Knoten aus Z
 - Hoher Platzverbrauch, da alles aus kleiner Granularität berechnet
 - U.U. hoher Nach-Berechnungsaufwand
 - Menge von Vorfahren, so dass alle Z erreichbar sind
 - U.U. hoher Platzverbrauch, da mehrere Views materialisiert werden

4 Klassifikationsstufen



Platzverbrauch

- Größe des Aggregationsgitter wächst exponentiell in der Anzahl möglicher Klassifikationsstufen
 - n Klassifikationsstufen - 2^n mögliche Gruppierungen
 - Identisch zur Anzahl berechneter Gruppierungen des CUBE Operators
- Platzverbrauch einer materialisierten Gruppierung hängt ab von **Anzahl Klassifikationsknoten** der beteiligten Gruppierungsattribute
 - Durch Nicht-speichern der 0-Summen kann Platz gespart werden („... having SUM() != 0 ...“)
 - Keine Auswirkung auf abgeleitete Summen
 - Ersparnis abhängig von **Füllgrad des Würfels**. Bedingt die Wahrscheinlichkeit, dass eine konkrete Kombination von Klassifikationsknoten in der Gruppierung vorhanden ist

Auswahl der optimalen Views

- Abgeschätzt werden muss
 - Platzverbrauch
 - Aktualisierungskosten
 - Gewinn für gegebene Workload
- Verschiedene Algorithmen sind vorgeschlagen worden
 - Optimale Lösung ist NP hartes/vollständiges Probleme
 - Heuristiken (Greedy, Simulated Annealing, ...)
- Literatur

Inhalt dieser Vorlesung

- Anfrageoptimierung mit MVs
- Materialisierte Sichten in Oracle

Anfrageoptimierung mit MVs ([TCL+00])

- Kostenbasierte Anfrageoptimierung
 - Anfrage parsen
 - Aufzählen von Query Execution Plans (QEP)
 - Joinreihenfolge
 - Joinmethode
 - Operatorreihenfolge
 - etc.
 - Bottom-Up Bewertung von Teilplänen (Access Paths)
 - Konstruktion vollständiger Pläne aus besten Teilplänen
 - Dynamische Programmierung

Anfrageoptimierung mit MVs


- Wo passen hier materialisierte Sichten?
- Sketch
 - Jede materialisierte Sicht ist ein potentieller Teilplan
 - Bei Bottum-Up Bewertung von Teilplänen auch materialisierte Sichten berücksichtigen
 - **Matching**: Gibt es für den aktuellen Teilplan einen / mehrere geeignete MVs?
 - Hinzufügen von Kompensationsoperationen notwendig?
 - Bewertung der Kosten (MV + Kompensation)
 - Auswahl des MV als Access Path, wenn er geringere Kosten als andere Teilpläne in Aussicht stellt

Beispiel (Snowflakeschema)

```
SELECT Y.year, sum(amount)
FROM Sales S, Product P, Days D, Months M, Years Y
WHERE P.name=„Gerolsteiner“ AND
      P.product_id = S.product_id AND
      S.day_id = D.day_id AND
      D.month_id = M.id AND M.year_id = Y.id AND
      Y.year in (1997, 1998, 1999)
GROUP BY Y.year
```


```
CREATE MATERIALIZED VIEW v_time AS
SELECT Y.id, Y.year, M.id, M.month, D.id, D.day
FROM Year Y, Month M, Day D
WHERE Y.id = M.year_id AND
      M.id = D.month_id
```

Ausführungsplan Query




Alternativplan

```
CREATE MATERIALIZED VIEW v_time AS
SELECT ...
FROM Year Y, Month M, Day D
WHERE   Y.id = M.year_id AND
        M.id = D.month_id
```



Alternativen bewerten



Einschränkungen

- Matching muss sehr schnell gehen
 - Exponentielle Algorithmen vermeiden
- I.d.R. werden vom Optimierer nicht alle Pläne aufgezählt
 - Typischerweise nur Left-Deep Joins
 - Gezieltes Suchen nach MVs muss eingebaut werden
- Matching erkennt in echten Systemen **nicht alle Matches**
 - Abhängig von Datenbanksystem
 - Beispiele für Einschränkungen
 - Keine Funktionen in Bedingungen
 - Keine Negation
 - Keine Self-joins
 - ...

Einschränkungen – Beispiele [GL01]

- Möglichkeiten, die SQLServer verpasst (Stand 2001)
 - Äquivalente Formelausdrücke
 - Q: where $A+B=10$
 - V: where $(B/2+A/2)*10=50$
 - Induzierbare Äquivalenzen
 - Q: where $A=2$ and $B=2$
 - V: where $A=B$
 - Ersetzung konstanter/berechenbarer Output-Columns
 - Q: select A,B ... where ... $B=3$
 - V: select A where ...
 - Q: select ... where $A*B>50$
 - V: select $A*B$... where
 - ...

Materialisierte Sichten in Oracle

- Anlegen von materialisierten Sichten
- Aktualisierungstechniken
- Optimierung / Rewriting mit materialisierten Sichten

Definition von MVs

```
CREATE MATERIALIZED VIEW product_sales_mv
BUILD IMMEDIATE
REFRESH FAST
ENABLE QUERY REWRITE
AS
SELECT P.prod_name, SUM(S.amount), COUNT(*)
FROM   sales S, products P
WHERE  S.product_id = P.id
GROUP BY P.prod_name;
```

- Materialisierte Sicht **wird als Tabelle angelegt**
 - Indexierung, Partitionierung, STORAGE Klauseln, etc.
- Aktualisierung erfolgt über Trigger
- „**Query Rewrite**“ muss explizit erlaubt werden

Reengineering

- Materialisierte Sichten können über existierende Tabellen gelegt werden

```
CREATE MATERIALIZED VIEW sum_sales_tab  
ON PREBUILT TABLE  
ENABLE QUERY REWRITE  
AS  
...
```

- Nachträgliche Benutzung der Rewrite / Aktualisierungsmechanismen

Aktualisierungsstrategien

- „Mastertabellen“ – Im MV referenzierte Tabellen
- Wann wird aktualisiert
 - „On Demand“ – Nur bei Aufruf von speziellen Funktionen im Package DBMS_MVIEW
 - „On Commit“ – Beim Abschluss von Transaktionen, die mindestens eine Mastertabelle verändern
- Wie wird aktualisiert
 - „COMPLETE“ – Komplette Neuberechnung des Views bei Änderungen an mindestens einer Mastertabelle
 - „FAST“ – Inkrementelles Nachführen von Änderungen
 - Was nur unter bestimmten Bedingungen geht
 - „FORCE“ – Ausführung von FAST, wenn möglich; sonst COMPLETE

FAST Refresh

- Erfordert das explizite Anlegen eines „MV Logs“

```
CREATE MATERIALIZED VIEW LOG ON sales
WITH SEQUENCE, ROWID
(prod_id, cust_id, time_id, channel_id,
 promo_id, quantity_sold, amount_sold)
INCLUDING NEW VALUES;
```

- Legt **Trigger** auf Mastertabellen an
- MV-Log speichert **Deltas** von Änderungen
- FAST Refresh spielt diese Deltas in MV ein
- Diverse **Einschränkungen**
 - *A materialized view log must be present **for each table**.*
 - *The rowids of all the tables must appear ...*
 - *If there are no outer joins, you ...*
 - *If there are outer joins, ...*

Rewrite Methoden

- Oracle versucht Rewriting auf mehrere Arten (V9.2)
 - Rewriting erfolgt auf syntaktischer Ebene, nicht im Operatorbaum
- Text Match
 - „Full Text Match“ und „Partial Text Match“
 - Rein syntaktischer Match
 - Keine Unterscheidung von Groß-/ Kleinschreibung und Leerzeichen
 - Aber: Reihenfolge von Bedingungen, andere Tabellenaliase, etc.
 - Keine logische Implikation, kein Mapping, etc.
- General Query Rewrite
 - Nicht anwendbar bei „Complex materialized views“
 - Unterschiedliche Methoden ja nach Art des MV
 - Only join – only aggregate – join and aggregate - complex
 - Viele Einschränkungen - Dokumentation

Zusammenfassung MVs

- Hochkomplexes Thema
- **Ultimative Anfragebeschleunigung** möglich – keinerlei Berechnung mehr
- Trade-Off zwischen
 - Performancegewinn
 - Platzbedarf, Aktualisierungskosten
- Query Rewrite in RDBMS funktioniert mit Heuristiken