

Data-Warehouse-Technologien

Prof. Dr.-Ing. Kai-Uwe Sattler¹ Prof. Dr. Gunter Saake²
Dr. Veit Köppen²

¹TU Ilmenau
FG Datenbanken & Informationssysteme

²Universität Magdeburg
Institut für Technische und Betriebliche Informationssysteme

Letzte Änderung: 18.10.2019

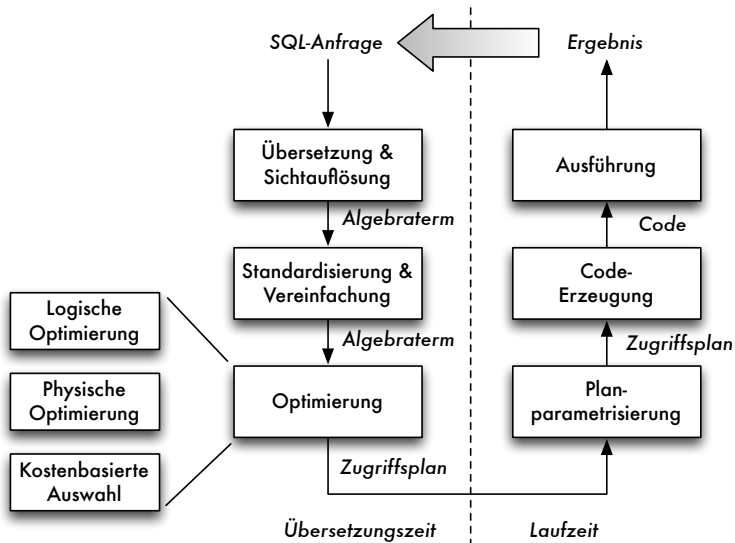
Teil VIII

Anfrageverarbeitung und -optimierung

Anfrageverarbeitung und -optimierung

- 1 Überblick
- 2 Star-Join
- 3 Optimierung des GROUP BY
- 4 Berechnung des CUBE

Überblick



Phasen der Anfrageverarbeitung

1 Übersetzung und Sichtexpansion

- ▶ Im Anfrageplan arithmetische Ausdrücke vereinfachen
- ▶ Unteranfragen auflösen
- ▶ Einsetzen der Sichtdefinition

2 Logische oder auch algebraische Optimierung

- ▶ Anfrageplan unabhängig von der konkreten Speicherungsform umformen; etwa Hineinziehen von Selektionen in andere Operationen

3 Physische oder Interne Optimierung

- ▶ Konkrete Speicherungstechniken (Indexe, Cluster) berücksichtigen
- ▶ Algorithmen auswählen
- ▶ Mehrere alternative interne Pläne

Phasen der Anfrageverarbeitung (2)

4 **Kostenbasierte Auswahl**

- ▶ Statistikinformationen (Größe von Tabellen, Selektivität von Attributen) für die Auswahl eines konkreten internen Planes nutzen

5 **Planparametrisierung**

- ▶ Bei vorkompilierten Anfragen (etwa Embedded-SQL): Ersetzen der Platzhalter durch Werte

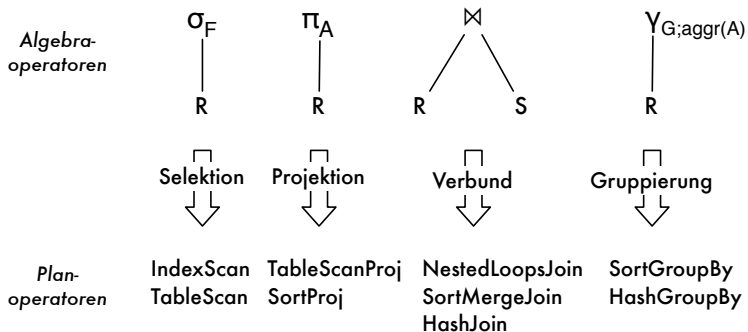
6 **Code-Erzeugung**

- ▶ Umwandlung des Zugriffsplans in ausführbaren Code

Phasen der Anfrageverarbeitung (3)

- Repräsentation von Anfragen während der Verarbeitung
 - ▶ Algebraausdrücke → **Operatorbaum**
 - ★ Operatoren als Knoten
 - ★ Kanten repräsentieren Datenfluss
 - ▶ Spätere Phasen → **Zugriffs- oder Anfrageplan** (query execution plan – QEP)
 - ★ Konkrete Algorithmen als Operatorknoten

Logische vs. physische Operatoren



- R, S – Relationen
- A – Attributmenge
- F – Bedingung
- G – Gruppierungselemente

Optimierung von Star-Joins

- Star-Joins stellen typisches Muster für Data-Warehouse-Anfragen dar
- Typische Eigenschaften durch das Star-Schema:
 - ▶ Sehr große Faktentabelle
 - ▶ Deutlich kleinere, unabhängige Dimensionstabellen

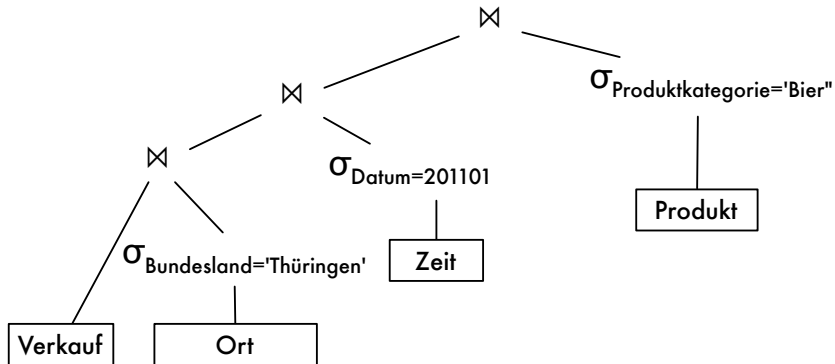
⇒ Heuristiken klassischer relationaler Optimierer schlagen hier oft fehl!

Optimierung von Star-Joins (2)

- Beispiel: Join über Faktentabelle `Verkauf` und die drei Dimensionstabellen `Produkt`, `Zeit` und `Geographie`:
 - ▶ 4-Wege Join
 - ▶ In RDBMS üblicherweise nur paarweiser Join: Sequenz paarweiser Joins notwendig
 - ▶ 4! mögliche Join-Reihenfolgen
 - ▶ Heuristik zur Verringerung der zu untersuchenden Möglichkeiten: Joins zwischen Relationen, die nicht durch eine Join-Bedingung in der Anfrage verknüpft sind, werden nicht betrachtet

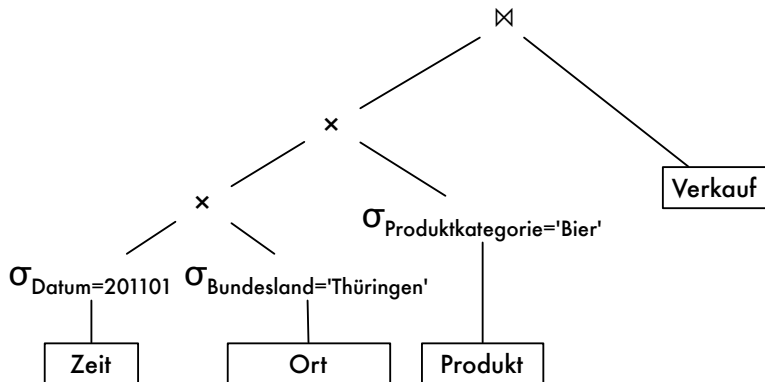
Optimierung von Star-Joins (3)

- Heuristik liefert z.B. folgenden Ausführungsplan (Plan A):



Optimierung von Star-Joins (4)

- Folgender Ausführungsplan (Plan B) wird üblicherweise nicht betrachtet (mit Kreuzprodukt der Dimensionstabellen):



Star-Join: Berechnungsbeispiel

- Annahmen:

- ▶ Tabelle Verkauf: 10.000.000 Datensätze
- ▶ 10 Geschäfte in Thüringen (von 100 in Deutschland)
- ▶ 20 Verkaufstage im Januar 2010 (von 1000 gespeicherten Tagen)
- ▶ 50 Produkte in Produktkategorie „Bier“ (von 1000)
- ▶ Gleichverteilung/gleiche Selektivität der einzelnen Ausprägungen

Plan	Operation	Anzahl Ergebnistupel
A	1. Join	1.000.000
	2. Join	20.000
	3. Join	1.000
B	1. Kreuzprodukt	200
	2. Kreuzprodukt	10.000
	3. Join	1.000

Semi-Join von Dimensionstabellen

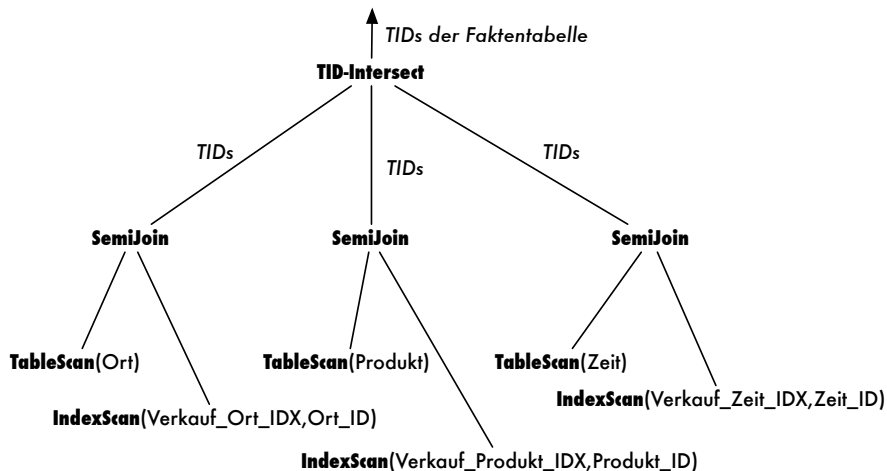
- Berechnung des Kreuzprodukts für die Dimensionstabellen nur bei ausreichend restriktiven Selektionsbedingungen für Dimensionen sinnvoll
- Vermeidung der vollständigen Berechnung des Kreuzproduktes
↪ Einsatz des **Semi-Join**

Semi-Join von Dimensionstabellen (2)

- 1 Auf Faktentabelle muss für jede Dimension ein einfacher B+-Baum als Index angelegt sein
- 2 Durch Semi-Joins mit den Dimensionstabellen werden zunächst die Mengen der Tupelidentifizier (TID) der in Frage kommenden Tupel bestimmt
- 3 Die Schnittmenge dieser TID-Mengen wird berechnet (z.B. durch effiziente Hauptspeicherverfahren):
 - ▶ Enthält alle TIDs der Tupel, die die Bedingungen für alle Dimensionen erfüllen
- 4 Danach Durchführung des „normalen“ paarweisen Joins

Nicht die ganze Faktentabelle geht in Join ein, sondern nur noch die tatsächlich relevanten Tupel! (im Beispiel: 1.000 statt 10.000.000 Tupel)

Semi-Join von Dimensionstabellen (3)



Optimierung des GROUP BY

- Besondere Berücksichtigung der Gruppierungs-/Aggregatoperationen im Rahmen der Optimierung
- Logische/Algebraische Optimierung: „Push-down“ von Gruppierungen \rightsquigarrow Reduzierung der Kardinalität der Zwischenergebnisse
 - ▶ Invariantes Gruppieren
 - ▶ Frühzeitiges Vorgruppieren
- Physische/Interne Optimierung
 - ▶ Spezielle Implementierungen für **GROUP BY**, **CUBE** und anderen OLAP-Funktionen

Invariantes Gruppieren

- Idee: Verschieben einer Gruppierungsoperation nach „unten“ (Invarianz bzgl. Position)
- Anwendbar, wenn
 - ▶ Verbundpartner nicht direkt zum Ergebnis beiträgt (implizite Selektion)
 - ▶ Gruppierungsattribute die Rolle eines Fremdschlüssels im Verbund einnehmen
- Beispiel:

```
SELECT V_Zeit_ID, V_Ort_ID, SUM(Umsatz)
FROM Verkauf, Zeit, Ort
WHERE V_Zeit_ID=Z_ID AND
      V_Ort_ID=O_ID
      AND Jahr < 2010 AND Bundesland <> 'THÜR'
GROUP BY V_Zeit_ID, V_Ort_ID
```

Invariantes Gruppieren (2)



Frühzeitiges Vorgruppieren


- Invariantes Gruppieren: restriktive Vorbedingung \rightsquigarrow selten anwendbar
- Idee: Einfügen eines zusätzlichen Gruppierungsoperators vor einen Verbund (ähnlich Projektion)
- Anwendbar, wenn
 - ▶ Gruppierungsbedingung enthält Verbundattribute
 - ▶ Aggregierte Attribute beziehen sich nicht auf Attribute des Verbundpartners

Frühzeitiges Vorgruppieren (2)

- Beispiel:

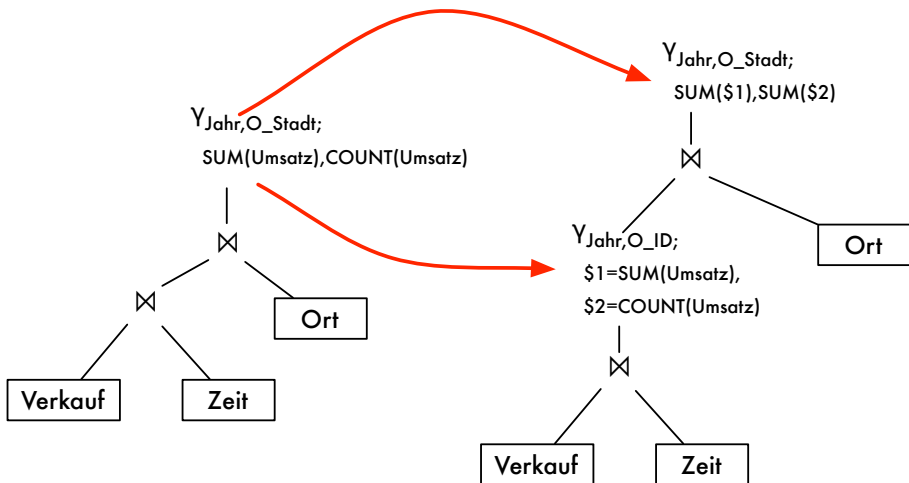
```
SELECT Jahr, O_Stadt, SUM(Umsatz), COUNT(Umsatz)
FROM Verkauf, Zeit, Ort
WHERE V_Zeit_ID = Z_ID AND
      V_O_ID = O_ID
GROUP BY Jahr, O_Stadt
```

Frühzeitiges Vorgruppieren (3)



Frühzeitiges Vorgruppieren (4)

- Außerdem notwendig: Anpassung der Aggregationsfunktionen



Implementierung des Gruppierungsoperators

- Implementierung von **GROUP BY**
- Realisierung von OLAP-Funktionen
- Berechnung von **CUBE**
- Iceberg-Cubes

GROUP BY-Implementierungen

● Sortierungsbasiert

- ▶ Vorsortierung der Relation bzw. sortiertes Lesen (Index-Scan)
- ▶ Ablauf
 - 1 Sortierung
 - 2 Durchlaufen der Tupelliste
 - 3 Aggregieren der Werte und Ausgabe des Aggregatwertes bei Gruppenwechsel

● Hashbasiert

- ▶ Hashfunktion über Gruppierungsattribute $h(G_1, \dots, G_n)$
- ▶ Ablauf
 - 1 Einordnen der Tupel in Hashtabelle mittels $h(G_1, \dots, G_n)$
 - 2 Durchlaufen der Hashtabelle
 - 3 Anwendung der Aggregatfunktionen

Realisierung von OLAP-Funktionen

- Sequenzielle Auswertung
- Für jede OLAP-Funktion:
 - ▶ Eingabedaten entsprechend **OVER()**-Klausel sortieren
 - ▶ Aggregationsfunktion anwenden
- Sortierung nach
 - ▶ Attributen der globalen Gruppierung
 - ▶ Attributen der **OVER()**-Klausel (**PARTITION BY** und **ORDER BY**)
- Bei mehreren OLAP-Funktionen in einer Anfrage
 - ▶ Sequenzielle Auswertung, d.h. eventuell wiederholtes Sortieren bei ggf. Nutzung von gemeinsamen Sortierpräfixen

Realisierung von OLAP-Funktionen (2)

globale Gruppierungsattribute $G_1 \dots G_n$,

lokale Sortierungsattribute aus **OVER**(): $O_1 \dots O_p$

Aggregatfunktion **AGG**(),

lokale Partitionierungsattribute (opt.) $P_1 \dots P_m$,

untere und obere Fenstergrenze (opt.) $W_u \dots W_o$

```
sort( $G_1, \dots, G_n, P_1, \dots, P_m, O_1, \dots, O_p$ );
```

```
while ( $t = \text{next\_tuple}()$ ) {
```

```
  if ( $t$  hat gleiche Werte bzgl.  $G_1 \dots G_n, P_1 \dots P_m$  wie letztes Tupel)
```

```
     $\text{aggrlist} := \text{concat}(\text{aggrlist}, t);$ 
```

```
  else {
```

```
    // Partitionswechsel
```

```
    for  $i := 1$  to  $\text{length}(\text{aggrlist})$  {
```

```
      // Berechne absolute Fenstergrenzen  $\text{low}, \text{high}$ 
```

```
       $\text{aggrval} := \text{AGG}(\{\text{aggrlist}[\text{low}] \dots \text{aggrlist}[\text{high}]\});$ 
```

```
       $\text{output}(G_1, \dots, G_n, P_1, \dots, P_m, O_1, \dots, O_p, \text{aggrval});$ 
```

```
    }
```

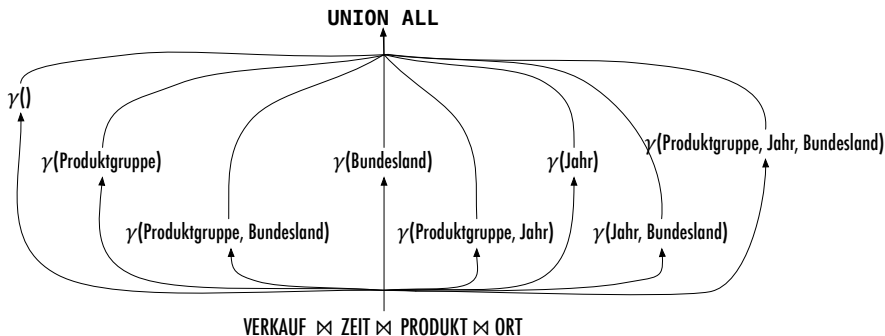
```
     $\text{aggrlist} := ();$ 
```

```
  }
```

```
}
```

Berechnung des CUBE: naiver Ansatz

- Separate Berechnung der einzelnen Gruppierungskombinationen
- Abschließende Vereinigung



CUBE und Aggregationsfunktionen

- Algebraische Funktionen ermöglichen
 - ▶ Berechnung weniger detaillierter Aggregate aus höher detaillierten Aggregaten (mehr Dimensionen)
 - ▶ Partielle Ordnung („Gitter“) der **GROUP BY**-Operationen des **CUBE**
 - ★ **Aggregationsgitter**
 - ▶ **GROUP BY** ist Kind eines anderen **GROUP BY** wenn Eltern-Operation zur Berechnung der Kind-Operation genutzt werden kann → **Ableitbarkeit**

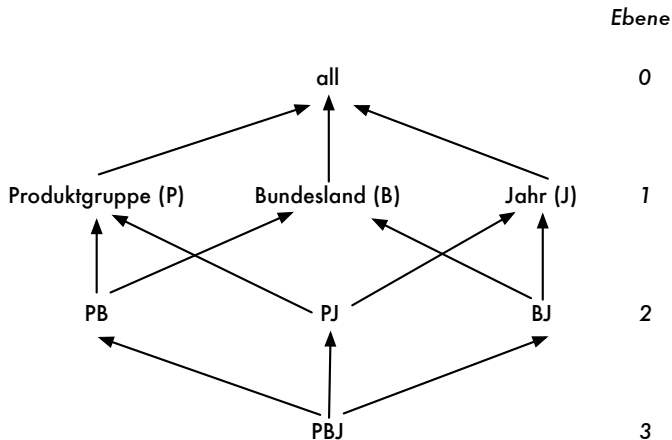
Ableitbarkeit

- Ableitbarkeit von Gruppierungskombinationen G_i
- Direkte Ableitbarkeit:
 - ▶ G_2 ist von G_1 ableitbar, wenn
 - ▶ G_2 hat genau ein Attribut weniger als G_1 : $G_2 \subset G_1$ und $|G_2| = |G_1| - 1$
 - ▶ Oder in G_1 wird genau ein Attribut A_i durch B_i ersetzt, wobei gilt:
 $A_i \rightarrow B_i$

⇒ Aggregationsgitter

- Ableitbarkeit:
 - ▶ Gruppierungskombination G_2 ist innerhalb eines Aggregationsgitters von G_1 ableitbar, wenn Pfad von G_1 nach G_2 existiert


Aggregationsgitter



Berechnung von CUBE

- Idee:
 - ▶ Nutzung der Gitter-Sicht (Ableitbarkeit)
 - ▶ GROUP-BYs mit gemeinsamen Gruppierungsattributen können Partitionen, sortierte Bereiche etc. gemeinsam nutzen
- Verfahren
 - ▶ Basierend auf Sortierung: PipeSort
 - ▶ Basierend auf Hashing: PipeHash

Optimierte Berechnung: Prinzip



Optimierungspotenzial

- Smallest-parent
 - ▶ Berechnung eines GROUP-BY auf Basis des minimalen zuvor berechneten Eltern-GROUP-BY
- Cache-results
 - ▶ Zwischenspeichern (im Hauptspeicher) der Ergebnisse eines GROUP-BY für nachfolgende GROUP-BY (Bsp.: $ABC \rightarrow AB$)
- Amortize-scans
 - ▶ Gemeinsames Berechnen mehrerer GROUP-BY in einem Scan (Bsp.: ABC, ACD, ABD, BCD aus $ABCD$)
- Share-sorts
 - ▶ Für Sortier-basierte Verfahren: Zwischenspeichern und gemeinsames Nutzen von sortiertem Bereichen
- Share-partitions
 - ▶ Für Hash-basierte Verfahren: Zwischenspeichern und gemeinsames Nutzen von Partitionen

Bedeutung der Sortierreihenfolge

- Annahme: Gruppierung auf Basis von Sortierung
 - ▶ erfordert u.U. Umsortierung
- Beispiel:

Produkt	Jahr	Region	Verkauf
Rotwein	2009	SANH	230
Rotwein	2009	THÜR	210
Rotwein	2010	SANH	200
...
Bier	2009	SANH	568

- ▶ Umsortierung für Gruppierung (Produkt, Region)
- Berücksichtigung der Sortierkosten in einem Kostenmodell


Kostenmodell

- Kostenarten
 - ▶ *S-Kosten* (Still to sort): Berechnung von GROUP-BY j aus GROUP-BY i , wenn i noch nicht sortiert ist
 - ▶ *A-Kosten* (Already sorted): Berechnung von GROUP-BY j aus GROUP-BY i , wenn i bereits sortiert ist
- Abschätzung auf Basis der Datenverteilung, Systemparameter etc.


PipeSort

- Eingabe: Suchgitter
 - ▶ Graph mit Knoten zur Repräsentation von GROUP-BY (Aggregationsgitter)
 - ▶ Gerichtete Kante verbindet GROUP-BY i mit GROUP-BY j
 - ★ i ist Elternknoten von j
 - ★ j kann generiert werden aus i
 - ★ j hat genau ein Attribut weniger als i
 - ▶ Ebene k bezeichnet alle GROUP-BYs mit k Attributen
- Annotation von Kanten e_{ij} mit A- und S-Kosten
- Ausgabe: Subgraph des Suchgitters
 - ▶ Jeder Knoten ist mit einem einzigen Elternknoten verbunden
 - ▶ Bestimmt Sortierreihenfolge bei Erhalt des Pipelining
 - ★ Spezieller aufspannender Baum
- Ziel: derartiger Subgraph mit minimaler Summe der Kantenkosten

PipeSort: Beispiel



→ Pipeline → Sortierung




PipeSort: Algorithmus

- **Zurückführen auf bekannten Graphen-Algorithmus**
- Ebenenweises Vorgehen: $k = 0..N - 1$ (N : Anzahl der Attribute)
- Transformation der Ebene $k + 1$ durch k Kopien jedes Knoten
- Jeder kopierte Knoten hat Verbindungen mit den gleichen Knoten wie Original
- Kantenkosten für Originalknoten: $A(e_{ij})$, sonst: $S(e_{ij})$
- Graph mit minimalen Kosten suchen
 - ▶ Paarbildung und Minimierung der Gesamtkosten („ungarische“ Methode – *weighted bipartite matching problem*)

PipeSort: Sortierreihenfolge

- Jeder Knoten h in Ebene k ist verbunden mit einem Knoten g in Ebene $k + 1$
- $h \rightarrow g$ über $A()$ -Kante: h bestimmt Attributreihenfolge für Sortierung von g
- $h \rightarrow g$ über $S()$ -Kante: g wird neu sortiert für Berechnung von h

PipeSort: Sortierplan



Relation

→ Pipeline

→ Sortierung


Iceberg-Cubes

- Idee: Ausnutzung der Monotonie von Aggregationen

Falls eine Aggregationsgruppe die **COUNT**-Bedingung nicht erfüllt, dann wird diese auch nicht durch Gruppen mit zusätzlichen Attributen erfüllt.

- Ansatz: Bottom-Up-Konstruktion eines Cubes und Minimal-Support-Pruning (ähnlich Apriori)

Iceberg Cube bottom up



Iceberg-Cube: Berechnung

```
BottomUpCube(input, dim):
  aggregate(input);
  write(outputRec);
  for (d:=dim; d<numDims; d++) {
    C := cardinality[d]; /* Kardinalität der Dimension */
    Partition(input, d, C, dataCount[d]);
    k := 0;
    for (i:=0; i < C; i++) {
      c := dataCount[d][i]; /* Größe der Partition */
      if (c >= minsup) {
        outputRec.dim[d] := input[k].dim[d];
        BottomUpCube(input[k...k+c], d+1);
      }
      k += c;
    }
    outputRec.dim[d] = ALL;
  }
```

Zusammenfassung

- Spezielle Charakteristika von DW-Anfragen erfordern spezifische Optimierungsmaßnahmen
- Rewriting-Techniken:
 - ▶ Verbundreihenfolge beim Star-Join
 - ▶ Push-down von Gruppierungen
- Operator-Implementierungen
 - ▶ CUBE und Iceberg-CUBE
 - ▶ OLAP-Funktionen