Ludwig Maximilians Universität München
Institut für Informatik
Lehr- und Forschungseinheit für Datenbanksysteme

Skript zur Vorlesung

Datenbanksysteme I

Wintersemester 2011/2012

Kapitel 5: Sortieren, Gruppieren und Views in SQL

Vorlesung: Prof. Dr. Christian Böhm
Übungen: Andreas Züfle, Sebastian Goebl

http://www.dbs.ifi.lmu.de/cms/Datenbanksysteme_I

Sortieren

- In SQL mit ORDER BY A_1, A_2, ...
- Bei mehreren Attributen: Lexikographisch

A	B
1	1
3	1
2	2
4	1
3	3

order by A, B

A	B
1	1
2	2
3	1
3	3
4	1

order by B, A

A	B
1	1
3	1
4	1
2	2
3	3

- Steht am Schluß der Anfrage
- Nach Attribut kann man ASC für aufsteigend (Default) oder DESC für absteigend angeben
- Nur Attribute der SELECT-Klausel verwendbar

Beispiel

- Gegeben:
  - MagicNumbers (Name: String, Wert: Int)
  - Primzahlen (Zahl: Int)
- Anfrage: Alle MagicNumbers, die prim sind, sortiert nach dem Wert beginnend mit größtem

```
select * from MagicNumbers where Wert in
 (select Zahl from Primzahlen)
  order by Wert desc
```

- Nicht möglich:

~~**select** Name **from** MagicNumbers **order by** Wert~~

Aggregation

- Berechnet Eigenschaften ganzer Tupel-Mengen
- Arbeitet also Tupel-übergreifend
- Aggregations-Funktionen in SQL:
  - **count** Anzahl der Tupel bzw. Werte
  - **sum** Summe der Werte einer Spalte
  - **avg** Durchschnitt der Werte einer Spalte
  - **max** größter vorkommender Wert der Spalte
  - **min** kleinster vorkommender Wert
- Aggregierungen können sich erstrecken:
  - auf das gesamte Anfrageergebnis
  - auf einzelne Teilgruppen von Tupeln (siehe später)

Aggregation

- Aggregationsfunktionen stehen in der Select-Klausel
- Beispiel:
  Gesamtzahl und Durchschnitt der Einwohnerzahl aller Länder, die mit ‘B‘ beginnen:

```
select sum (Einw), avg (Einw)
from länder
where LName like ‘B%‘
```

- Ergebnis ist immer ein einzelnes Tupel:
  Keine Mischung aggregierte/nicht aggregierte Attribute
- Aggregations-Funktionen wie **min** oder **max** sind ein einfaches Mittel, um Eindeutigkeit bei Subqueries herzustellen (vgl. Kapitel 4, Folie 43).

Aggregation

- NULL-Werte werden ignoriert (auch bei **count**)
- Eine Duplikatelimination kann erzwungen werden
  - **count** (**distinct** KName) zählt verschiedene Kunden
  - **count** (**all** KName) zählt alle Einträge (außer **NULL**)
  - **count** (KName) ist identisch mit **count** (**all** KName)
  - **count** (*) zählt die Tupel des Anfrageergebnisses (macht nur bei NULL-Werten einen Unterschied)
- Beispiel:
  Produkt (PName, Preis, ...)
  Alle Produkte, mit unterdurchschnittlichem Preis:

```
select *
from Produkt
where Preis < (select avg (Preis) from Produkt)
```

Gruppierung

- Aufteilung der Ergebnis-Tupel in Gruppen
- Ziel: Aggregationen
- Beispiel:
  Gesamtgehalt und Anzahl Mitarbeiter pro Abteilung

Mitarbeiter — Aggregationen:

PNr	Name	Vorname	Abteilung	Gehalt	Σ Gehalt	COUNT
001	Huber	Erwin	01	2000		
002	Mayer	Hugo	01	2500	6300	3
003	Müller	Anton	01	1800		
004	Schulz	Egon	02	2500	4200	2
005	Bauer	Gustav	02	1700		

- Beachte: So in SQL nicht möglich!
  Anfrage-Ergebnis soll wieder eine Relation sein

Gruppierung

Mitarbeiter

PNr	Name	Vorname	Abteilung	Gehalt
001	Huber	Erwin	01	2000
002	Mayer	Hugo	01	2500
003	Müller	Anton	01	1800
004	Schulz	Egon	02	2500
005	Bauer	Gustav	02	1700

- In SQL:
  select Abteilung, **sum** (Gehalt), **count** (*)
  from Mitarbeiter
  group by Abteilung

Abteilung	sum (Gehalt)	count (*)
01	6300	3
02	4200	2

Gruppierung

- Syntax in SQL:

```
select      ...          ← siehe unten
from        ...
[where      ...]
[group by   A1, A2, ...
  [having   ...]]        ← siehe Seite 13ff.
[order by   ...]
```

- Wegen Relationen-Eigenschaft des Ergebnisses Einschränkung der **select**-Klausel. Erlaubt sind:
  - Attribute aus der Gruppierungsklausel (incl. arithmetischer Ausdrücke etc.)
  - Aggregationsfunktionen auch über andere Attribute, z.B. **count (*)**
  - in der Regel **select** * **from**...**group by**… nicht erlaubt

Gruppierung

- Beispiel: Nicht möglich!!!

Mitarbeiter

PNr	Name	Vorname	Abteilung	Gehalt
001	Huber	Erwin	01	2000
002	Mayer	Hugo	01	2500
003	Müller	Anton	01	1800
004	Schulz	Egon	02	2500
005	Bauer	Gustav	02	1700

- **select** ~~PNr,~~ Abteilung, **sum** (Gehalt)
  from Mitarbeiter
  group by Abteilung

~~„PNr“~~	Abteilung	Gehalt
~~„001,002,003“~~	01	6300
~~„004,005“~~	02	4200

Gruppierung mehrerer Attribute

- Etwa sinnvoll in folgender Situation:

PNr	Name	Vorname	Abteilung	Einheit	Gehalt
001	Huber	Erwin	01	01	2000
002	Mayer	Hugo	01	02	2500
003	Müller	Anton	01	02	1800
004	Schulz	Egon	02	01	2500
005	Bauer	Gustav	02	01	1700

Debitoren
Kreditoren
Fernsehgeräte
Buchhaltung
Produktion

Gesamtgehalt in jeder Gruppe:

select Abteilung, Einheit,
sum(Gehalt)
from Mitarbeiter
group by Abteilung, Einheit

Abt.	Ei.	Σ Geh.
01	01	2000
01	02	4300
02	01	4200

Gruppierung mehrerer Attribute

Oft künstlich wegen **select**-Einschränkung:

Mitarbeiter ⋈ Abteilungen

PNr	Name	Vorname	ANr	AName	Gehalt
001	Huber	Erwin	01	Buchhaltung	2000
002	Mayer	Hugo	01	Buchhaltung	2500
003	Müller	Anton	01	Buchhaltung	1800
004	Schulz	Egon	02	Produktion	2500
005	Bauer	Gustav	02	Produktion	1700

- Nicht möglich, obwohl AName von ANr funktional abh.:
  ~~**select** ANr, AName, sum(Gehalt) **from** ... **where** ... **group by** ANr~~
- Aber wegen der funktionalen Abhängigkeit identisch mit:
  select ANr, AName, sum(...) **from** ... **where** ... **group by** ANr, AName
- Weitere Möglichkeit (ebenfalls wegen Abhängigkeit):
  select ANr, **max** (AName), sum(...) **from** ... **where** ... **group by** ANr

Die Having-Klausel

- Motivation:
  Ermittle das Gesamt-Einkommen in jeder Abteilung, die mindestens 5 Mitarbeiter hat
- In SQL nicht möglich:

```
select    ANr, sum (Gehalt)
from      Mitarbeiter
where     count (*) >= 5        GEHT NICHT !
group by  ANr                   STATT DESSEN:
having    count (*) >= 5
```

- Grund: Gruppierung wird erst nach SELECT-FROM-WHERE-Operationen ausgeführt

Auswertung der Gruppierung

An folgendem Beispiel:

```
select A, sum(D)
from ... where ...
group by A, B
having sum (D) < 10 and max (C) = 4
```

1. Schritt:
from/where

A	B	C	D
1	2	3	4
1	2	4	5
2	3	3	4
3	3	4	5
3	3	6	7

2. Schritt:
Gruppenbildung

A	B	C	D
1	2	3	4
		4	5
2	3	3	4
3	3	4	5
		6	7

3. Schritt:
Aggregation

A	B	sum(D)	max(C)
1	2	9	4
2	3	4	3
3	3	12	6

temporäre „nested relation“

Auswertung der Gruppierung

An folgendem Beispiel:

select A, **sum**(D)
from ... **where** ...
group by A, B
having sum (D) < 10 **and max** (C) = 4

3. Schritt:

Aggregation

A	B	sum(D)	max(C)
1	2	9	4
2	3	4	3
3	3	12	6

4. Schritt:

having (=Selektion)

A	B	sum(D)	max(C)
1	2	9	4

5. Schritt:

Projektion

A	sum(D)
1	9

Architektur eines DBS

Drei-Ebenen-Architektur zur Realisierung von
- **physischer**
- **und logischer**

Datenunabhängigkeit (nach ANSI/SPARC)

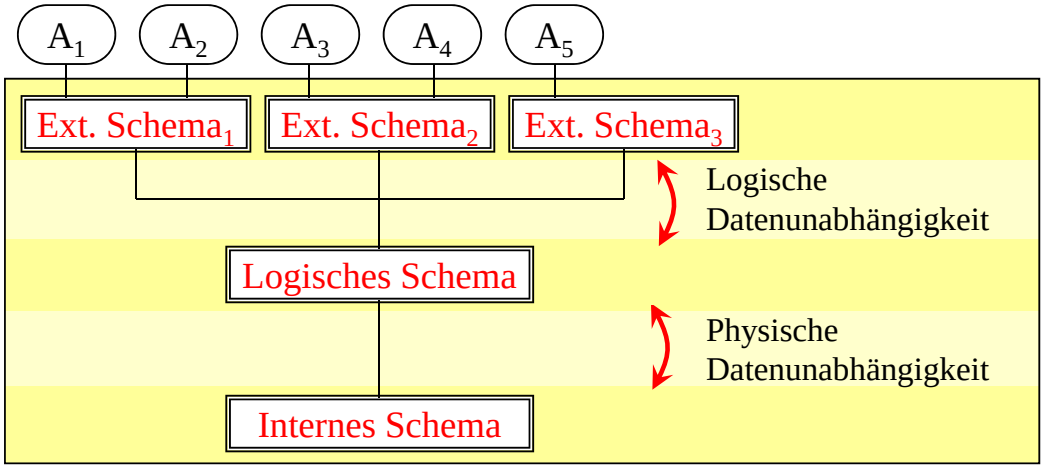

Externe Ebene

- Gesamt-Datenbestand ist angepasst, so dass jede Anwendungsgruppe nur die Daten sieht, die sie...
  - sehen will (Übersichtlichkeit)
  - sehen soll (Datenschutz)
- Logische Datenunabhängigkeit

- In SQL:
  Realisiert mit dem Konzept der Sicht (View)

Was ist eine Sicht (View)?

- Virtuelle Relation
- Was bedeutet virtuell?
  - Die View sieht für den Benutzer aus wie eine Relation:
    - **select** ... **from** $View_1$, $Relation_2$, ... **where** ...
    - mit Einschränkung auch: **insert, delete** und **update**
  - Aber die Relation ist nicht real existent/gespeichert; Inhalt ergibt sich durch Berechnung aus anderen Relationen
- Besteht aus zwei Teilen:
  - Relationenschema für die View (nur rudimentär)
  - Berechnungsvorschrift, die den Inhalt festlegt: SQL-Anfrage mit **select** ... **from** ... **where**

Viewdefinition in SQL

- Das folgende DDL-Kommando erzeugt eine View
  create [**or replace**] **view** *VName* [(A_1, A_2, ...)]* **as select** ...
- Beispiel: Eine virtuelle Relation Buchhalter, nur mit den Mitarbeitern der Buchhaltungsabteilung:
  create view Buchhalter **as**
  select PNr,Name,Gehalt **from** Mitarbeiter **where** ANr=01
- Die View *Buchhalter* wird erzeugt:

Mitarbeiter

PNr	Name	Vorname	ANr	Gehalt
001	Huber	Erwin	01	2000
002	Mayer	Hugo	01	2500
003	Müller	Anton	01	1800
004	Schulz	Egon	02	2500
005	Bauer	Gustav	02	1700

Buchhalter

PNr	Name	Gehalt
001	Huber	2000
002	Mayer	2500
003	Müller	1800

*relativ unüblich

Konsequenzen

- Automatisch sind in dieser View alle Tupel der Basisrelation, die die Selektionsbedingung erfüllen
- An diese können beliebige Anfragen gestellt werden, auch in Kombination mit anderen Tabellen (Join) etc:
  select * from Buchhalter where Name like ‘B%‘
- In Wirklichkeit wird lediglich die View-Definition in die Anfrage eingesetzt und dann ausgewertet:

Buchhalter:
select PNr,Name,Gehalt
from Mitarbeiter **where** ANr=01

select * from Buchhalter where Name like ‘B%‘
select * from (select PNr, Name, Gehalt
from Mitarbeiter where ANr=01)
where Name like ‘B%‘

Konsequenzen

- Bei Updates in der Basisrelation (Mitarbeiter) ändert sich auch die virtuelle Relation (Buchhalter)
- Umgekehrt können (mit Einschränkungen) auch Änderungen an der View durchgeführt werden, die sich dann auf die Basisrelation auswirken
- Eine View kann selbst wieder Basisrelation einer neuen View sein (View-Hierarchie)
- Views sind ein wichtiges Strukturierungsmittel für Anfragen und die gesamte Datenbank

Löschen einer View:

drop view *VName*

In Views erlaubte Konstrukte

- Folgende Konstrukte sind in Views erlaubt:
  - Selektion und Projektion (incl. Umbenennung von Attributen, Arithmetik)
  - Kreuzprodukt und Join
  - Vereinigung, Differenz, Schnitt
  - Gruppierung und Aggregation
  - Die verschiedenen Arten von Subqueries
- Nicht erlaubt:
  - Sortieren

Insert/Delete/Update auf Views

- Logische Datenunabhängigkeit:
  - Die einzelnen Benutzer-/Anwendungsgruppen sollen ausschließlich über das externe Schema (d.h. Views) auf die Datenbank zugreifen (Übersicht, Datenschutz)
  - Insert, Delete und Update auf Views erforderlich
- Effekt-Konformität
  - View soll sich verhalten wie gewöhnliche Relation
  - z.B. nach dem Einfügen eines Tupels muß das Tupel in der View auch wieder zu finden sein, usw.
- Mächtigkeit des View-Mechanismus
  - Join, Aggregation, Gruppierung usw.
  - Bei komplexen Views Effekt-Konformität unmöglich

Insert/Delete/Update auf Views

- Wir untersuchen die wichtigsten Operationen in der View-Definition auf diese Effekt-Konformität
  - Projektion
  - Selektion
  - Join
  - Aggregation und Gruppierung
- Wir sprechen von Projektions-Sichten usw.
  - Änderung auf Projektionssicht muß in Änderung der Basisrelation(en) transformiert werden
- Laufendes Beispiel:
  - MGA (Mitarbeiter, Gehalt, Abteilung)
  - AL (Abteilung, Leiter)

Projektionssichten

- Beispiel:

```
create view MA as
select Mitarbeiter, Abteilung
from MGA
```

- Keine Probleme beim Löschen und Update:

  delete from MA **where** Mitarbeiter = ...
  → **delete from** MGA **where** Mitarbeiter = ...

- Bei Insert müssen wegprojizierte Attribute durch NULL-Werte oder bei der Tabellendefinition festgelegte Default-Werte belegt werden:

  insert into MA **values** (‘Weber‘, 001)
  → **insert into** MGA **values** (‘Weber‘, NULL, 001)

Projektionssichten

- Problem bei Duplikatelimination (**select distinct**): Keine eindeutige Zuordnung zwischen Tupeln der View und der Basisrelation:
- Bei Arithmetik in der Select-Klausel: Rückrechnung wäre erforderlich:
  create view P **as select** 3*x*x*x+2*x*x+x+1 **as** y **from** A
- Der folgende Update wäre z.B. problematisch:
  insert into P **set** y = 0 **where** ...
- womit müsste x besetzt werden?
  Mit der Nullstelle des Polynoms $f(x) = 3x^3 + 2x^2 + x + 1$
  Nullstellensuche kein triviales mathematisches Problem

Kein **insert/delete/update** bei **distinct**/Arithmetik

Selektionssichten

- Beispiel:

```
create view MG as
select * from MGA
where Gehalt >= 20
```

- Beim Ändern (und Einfügen) kann es passieren, dass ein Tupel aus der View verschwindet, weil es die Selektionsbedingung nicht mehr erfüllt:
  update MG **set** Gehalt = 19 **where** Mitarbeiter = ‘Huber‘
- Huber ist danach nicht mehr in MG
- Dies bezeichnet man als Tupel-Migration:
  Tupel verschwindet, taucht aber vielleicht dafür in anderer View auf

Selektionssichten

- Dies ist manchmal erwünscht
  - Mitarbeiter wechselt den zuständigen Sachbearbeiter, jeder Sachbearbeiter arbeitet mit „seiner“ View
- Manchmal unerwünscht
  - Datenschutz
- Deshalb in SQL folgende Möglichkeit:

```
create view MG as
select * from MGA
where Gehalt >= 20
with check option
```

- Die Tupel-Migration wird dann unterbunden
  Fehlermeldung bei: **update** MG **set** Gehalt = 19 **where** ...

Join-Views

- Beispiel:

```
create view MGAL as
select Mitarbeiter, Gehalt, MGA.Abteilung, Leiter
from MGA, AL
where MGA.Abteilung = AL.Abteilung
```

- Insert in diese View nicht eindeutig übersetzbar:
  insert into MGAL **values** (‘Schuster‘, 30, 001, ‘Boss‘)
  → **insert into** MGA **values** (‘Schuster‘, 30, 001)
  wenn kein Tupel (001, ‘Boss‘) in AL existiert:
  → **insert into** AL **values** (001, ‘Boss‘)
  → **update** AL **set** Leiter=‘Boss‘ **where** Abteilung=001
  oder Fehlermeldung ?
- Daher: Join-View in SQL nicht updatable

Aggregation, group by, Subquery

- Auch bei Aggregation und Gruppierung ist es nicht möglich, eindeutig auf die Änderung in der Basisrelation zu schließen
- Subqueries sind unproblematisch, sofern sie keinen Selbstbezug aufweisen (Tabelle in from-Klausel der View wird nochmals in Subquery verwendet)

Eine View, die keiner der angesprochenen Problemklassen angehört, heisst **Updatable View**.
Insert, delete und update sind möglich.

Materialisierte View

Hier nur Begriffserklärung:

- Eine sog. materialisierte View ist keine virtuelle Relation sondern eine real gespeicherte
- Der Inhalt der Relation wurde aber durch eine Anfrage an andere Relationen und Views ermittelt
- In Standard-SQL gibt es keine Sprachkonstrukte, um materialisierte Views zu verwalten
- In SQL einfach erreichbar durch Anlage einer Tabelle *MVName* und Einfügen der Tupel mit:

  insert into *MVName* (**select ... from ... where**)
- Bei Änderungen an den Basisrelationen keine automatische Änderung in *MVName* und umgekehrt
- DBS bieten spezielle Werkzeuge zur Aktualisierung

Wenn wir von einer *View* sprechen, ist dies nicht gemeint.

Rechtevergabe

- Basiert in SQL auf Relationen bzw. Views
- Syntax:

  grant *Rechteliste*
  on *Relation* bzw. *View*
  to *Benutzerliste*
  [**with grant option**]
- *Rechteliste*:
  - all [privileges]
  - select, insert, delete (mit Kommas sep.)
  - update (optional in Klammern: Attributnamen)

Rechtevergabe

- *Benutzerliste*:
  - Benutzernamen*
  - **to public** (an alle)
- Grant Option:
  Recht, das entsprechende Privileg selbst weiterzugeben
- Rücknahme von Rechten:
  revoke *Rechteliste*
  on *Relation*
  from *Benutzerliste*
  [**restrict**] *Abbruch, falls Recht bereits weitergegeben*
  [**cascade**] *ggf. Propagierung der Revoke-Anweisung*

*Die Datenbanksysteme bieten meist eine eigene Benutzerverwaltung mit Authentifizierung durch Benutzername und Passwort an.