

Datenbankadministration

12. Datenbankobjekte und analytische Funktionen

AG DBIS University of Kaiserslautern, Germany

Karsten Schmidt kschmidt@informatik.uni-kl.de
(Vorlage TU-Dresden)

Wintersemester 2008/2009



- **Tabelle** (*table*)
 - logisches Konstrukt aus Spalten verschiedenen Datentyps zur Speicherung von Daten
 - Informationen zu Tabellen
 - `LIST TABLES [FOR {ALL | SCHEMA <schemaname>}]`
 - `DESCRIBE TABLE <tablename>`
- **Tabellenpartitionierung** (*table (range) partitioning*)
 - Ziel: Performanzsteigerung
 - Tupel einer Tabelle auf mehrere Tabellenbereiche verteilen → Parallelität
 - selten benötigte Daten auf Tertiärspeicher auslagern → schnellerer Zugriff auf kleinere Tabellen
 - Partitionierung nach Partitionierungsspalte
 - auch mehrere Spalten und generierte Spalte möglich
 - keine XML-, LOB- oder LONG VARCHAR-Spalten

- **Tabellenpartitionierung (Fortsetzung)**

- Bereiche definieren und auf Tabellenbereiche verteilen

```
CREATE TABLE bsptable (id int, ...)
PARTITION BY RANGE (id)
(
  [PARTITION p0] STARTING FROM (0) ENDING (10) IN tbspc1,
  [PARTITION p1] ENDING (20) IN tbspc2, ...
)
```

- Kurzschreibweise, Reihum-Zuweisung auf Tabellenbereiche

```
CREATE TABLE bsptable (id int, ...)
IN tbspc1, tbspc2, ...
PARTITION BY RANGE (id)
(STARTING FROM (0) ENDING (80) EVERY (10))
```

- Bereich abtrennen

```
ALTER TABLE <tblname>
DETACH PARTITION <partitionname> INTO TABLE <tblname>
```

- Bereich hinzufügen

```
ALTER TABLE <tblname>
ATTACH PARTITION STARTING <start> ENDING <end>
FROM TABLE <tblname>
```

- **Datenzeilenkomprimierung** (*table compression*)
 - Ziel: Einsparungen bei Plattenplatz und E/A-Operationen
 - Ersetzen von sich wiederholenden Mustern (auch über mehrere Spalten) einer Zeile durch kurzes Symbol
 - Datenzeilenkomprimierung aktivieren
 - `CREATE TABLE <table_name> ... COMPRESS YES`
 - `ALTER TABLE <table_name> COMPRESS YES`
 - Datenzeilenkomprimierung durchführen, Komprimierungswörterverzeichnis erstellen
 - `REORG TABLE <table_name> {RESETDICTIONARY | KEEPDICTIONARY}`
- **Einschränkung**
 - nicht für LONG-, LOB- und XML-Spalten

- **Sicht** (*view*)
 - virtuelle Relation zur Vereinfachung von Anfragen bzw. nutzerspezifische Datendarstellung
 - auch Datenschutz durch Ausblenden von Tupeln / Attributen
 - Spezifikation des Inhaltes durch SQL-Anfrage
 - Sicht ungültig, wenn zugrunde liegende Sicht oder Tabelle gelöscht wird (`SYSCAT.VIEWS: VALID = X`)
 - je nach Spezifikation *updatable* oder *read-only*:
 - *updatable*: wenn Spalten der Sicht auf die der Tabelle abgebildet werden können
 - *read-only*: sonst (`VALUES`, `DISTINCT`, Verbund, ...)
 - `SYSCAT.VIEWS: READONLY=Y/N`

- **Aktualisierung auf Sichten**

- Einschränkung durch **WITH CHECK OPTION**
 - nur solche Aktualisierungen möglich, die mit Sichtdefinition konform sind
- Sicht auf Sicht (*nested view*)
 - **WITH CASCADED CHECK OPTION: WITH CHECK OPTION** für alle zugrunde liegenden Sichten anwenden
 - **WITH LOCAL CHECK OPTION: WITH CHECK OPTION** nur für aktuelle Sicht anwenden

- **Integritätsbedingung** (*constraint*)

- Regel, die vom Datenbankmanagementsystem erzwungen wird
- Typen
 - Primärschlüssel/Disjunktheit (*primary key/unique key constraint*)
 - Eindeutigkeit über eine oder mehr Spalten
 - nur für **NOT NULL**-Spalten möglich
 - erzwingt Unique-Index auf betroffenen Spalten
 - wertebasiert (*check constraint*)
 - Vorgabe gültiger Werte
 - Informationale Constraint
 - Regeln, die vom Optimierer verwendet werden können
 - Achtung: werden nicht erzwungen!
 - Fremdschlüssel (*foreign key constraint*)
 - Wertegleichheit von Attributen
 - beschreibt Beziehung zwischen oder innerhalb Tabellen

● Fremdschlüssel

- Verhalten bei Änderungen der Daten
 - Einfügen in abhängige Tabelle
 - Wert des Fremdschlüsselattributs muss in Elterntabelle existieren
 - Löschen aus Elterntabelle
 - **RESTRICT/NO ACTION**: nicht möglich, wenn abhängige Tupel vorhanden
 - **CASCADE**: abhängige Tupel aus abhängiger Tabelle löschen
 - **SET NULL**: Fremdschlüsselwert abhängiger Tupel NULL setzen
 - Ändern in Elterntabelle
 - **RESTRICT**: nicht möglich, wenn abhängige Tupel vorhanden
 - **NO ACTION**: nicht möglich, wenn nach Update abhängige Tupel ohne Elterntupel existieren

- **Index**

- Einsatzgebiete
 - schneller Zugriff auf Daten
 - Erzwingen von Eindeutigkeit
- Nachteile
 - zusätzlicher Aufwand für Indexaktualisierung notwendig
 - zusätzlicher Speicherplatz

- **Schema**

- logische Klassifikation von Datenbankobjekten
- erlaubt gleiche Tabellennamen in verschiedenen Schemata

- **Trigger**

- Menge von Aktionen, die angestoßen werden, falls bestimmte Ereignisse eintreten
- Ziel: Validierung, Datenaufbereitung, Integritätssicherung

Verwaltung

- **Instanzverwaltung**

- Instanz erzeugen: `db2icrt <instance_name>`
- Instanz löschen: `db2idrop -f <instance_name>`
- Instanz auflisten: `db2ilist`

- **Registrierdatenbankvariablen** (*profile registries*)

- DB2-spezifische Variablen für Verwaltung, Konfiguration und Performanz
- nach Änderung Neustart der Instanz erforderlich
- alle unterstützten Variablen auflisten: `db2set -lr`
- alle gesetzten Registrierdatenbankvariablen auflisten: `db2set -all`
- setzen: `db2set <reg_variable>=<value>` (ohne Leerzeichen!)

- **Umgebungsvariablen**

- vom System verwaltete DB2-Umgebungsvariablen (z.B. `DB2INSTANCE`)

- **Verbundene Anwendungen**

- Anwendungen auflisten: `list applications`
- alle Anwendungen trennen: `force application {all | <appl_handle>}`
- alle Anwendungen trennen und Instanz stoppen: `db2stop force`

Analytische Funktionen

- **Grundlagen**

- Skalarfunktionen (tupellokal): z.B. $+ - * /$
- Gruppierung: **GROUP BY**
 - Zusammenfassen mehrerer Tupel mit gleichen Ausprägungen (Verdichtung)
- Aggregationsfunktionen: z.B. **SUM, COUNT, AVG**
 - Berechnung einer Kennzahl aus mehreren Einzelwerten
- Gruppierung und Aggregation treten oft zusammen auf

- **OLAP-Funktionen** (*analytic functions*)

- Trennung von Aggregation und Verdichtung
 - Aggregation auf Ergebnis einer Anfrage
 - keine weitere Verdichtung
- Kernkonstrukt: **OVER**-Klausel
- Umfasst
 - Attributlokale Partitionierung (Bildung dynamischer Fenster)
 - Ranking / Numbering

- **OVER-Klausel**

- u.a. Berechnung von Aggregationsfunktionen ohne weitere Verdichtung
- **OVER** () entspricht Aggregation über alle Tupel

R		
Jahr	Quartal	Umsatz
2004	1	10
2004	2	20
2004	3	10
2004	4	20
2005	1	30

```
SELECT Jahr, Quartal,  
       Umsatz,  
       SUM(Umsatz) OVER ()  
FROM R
```

R			
Jahr	Quartal	Umsatz	Gesamtumsatz
2004	1	10	90
2004	2	20	90
2004	3	10	90
2004	4	20	90
2005	1	30	90

● Attributlokale Partitionierung

- Auswahl der zu aggregierenden Tupel abhängig vom Kontext
- **PARTITION BY** <attribute-list>
 - Aggregation aller Tupel, die in den angegebenen Attributen mit dem aktuellen Tupel übereinstimmen


R		
Jahr	Quartal	Umsatz
2004	1	10
2004	2	20
2004	3	10
2004	4	20
2005	1	30

```
SELECT Jahr, Quartal,
       Umsatz,
       SUM(Umsatz) OVER (
         PARTITION BY Jahr
       )
FROM R
```

R			
Jahr	Quartal	Umsatz	Jahresumsatz
2004	1	10	60
2004	2	20	60
2004	3	10	60
2004	4	20	60
2005	1	30	30

● Bildung dynamischer Fenster

- erfordert Sortierung der Tupel (lokal, in der **OVER**-Klausel angegeben)
- **OVER** (**ORDER BY** <attribute-list> [<window-spec>])
- Aggregation über benachbarte Tupel (=Fenster)
 - **ROWS**-Klausel = Anzahl vorhergehender / nachfolgender Tupel
 - **RANGE**-Klausel = Wertebereich (z.B. ± 5 Tage)



- Kombination mit **PARTITION BY**-Klausel möglich

- **Beispiel: gleitendes Mittel**

```
SELECT Jahr, Quartal,  
       Umsatz,  
       AVG(Umsatz) OVER (  
         ORDER BY Jahr, Quartal  
         ROWS BETWEEN 1 PRECEDING AND CURRENT ROW  
       )  
FROM R
```

R		
Jahr	Quartal	Umsatz
2004	1	10
2004	2	20
2004	3	10
2004	4	20
2005	1	30

→

R			
Jahr	Quartal	Umsatz	Gleit- umsatz
2004	1	10	10
2004	2	20	15
2004	3	10	15
2004	4	20	15
2005	1	30	25

● Ranking

- Bestimmung der Position eines Tupels in der Ergebnismenge
- erfordert Sortierung innerhalb der **OVER**-Klausel
- Werte mit identischer Ausprägung erhalten denselben Rang
- **RANK()** (mit Lücken) vs. **DENSE_RANK()** (ohne Lücken)
- Spezialfall: Top-k-Anfragen (mit **FETCH FIRST n ROWS ONLY**)
- mit **PARTITION BY**-Klausel kombinierbar

```
SELECT Jahr, Quartal, Umsatz
       RANK() OVER ( ORDER BY Umsatz DESC),
       DENSE_RANK() OVER ( ORDER BY Umsatz DESC)
FROM R
```

R		
Jahr	Quartal	Umsatz
2004	1	10
2004	2	20
2004	3	10
2004	4	20
2005	1	30

→

R				
Jahr	Quartal	Umsatz	Rang	Rang (dicht)
2004	1	10	4	3
2004	2	20	2	2
2004	3	10	4	3
2004	4	20	2	2
2005	1	30	1	1

- **Datenbankobjekte**

- Tabelle
- Sicht
- Integritätsbedingung
- Index
- Schema
- Trigger

- **Verwaltung**

- Instanzverwaltung
- DB2-spezifische Parameter

- **Analytische Funktionen**

- attributlokale Partitionierung
- Ranking