Datenbanken und SQL

Kapitel 7

Performance in Datenbanken

Performance in Datenbanken

- Datenbankenoptimizer und Ausführungsplan
- Index
- Partitionierung
- Materialisierte Sichten
- Optimierungen im Select-Befehl
- Stored Procedures
- Weitere Optimierungen

Abfrageoptimierung

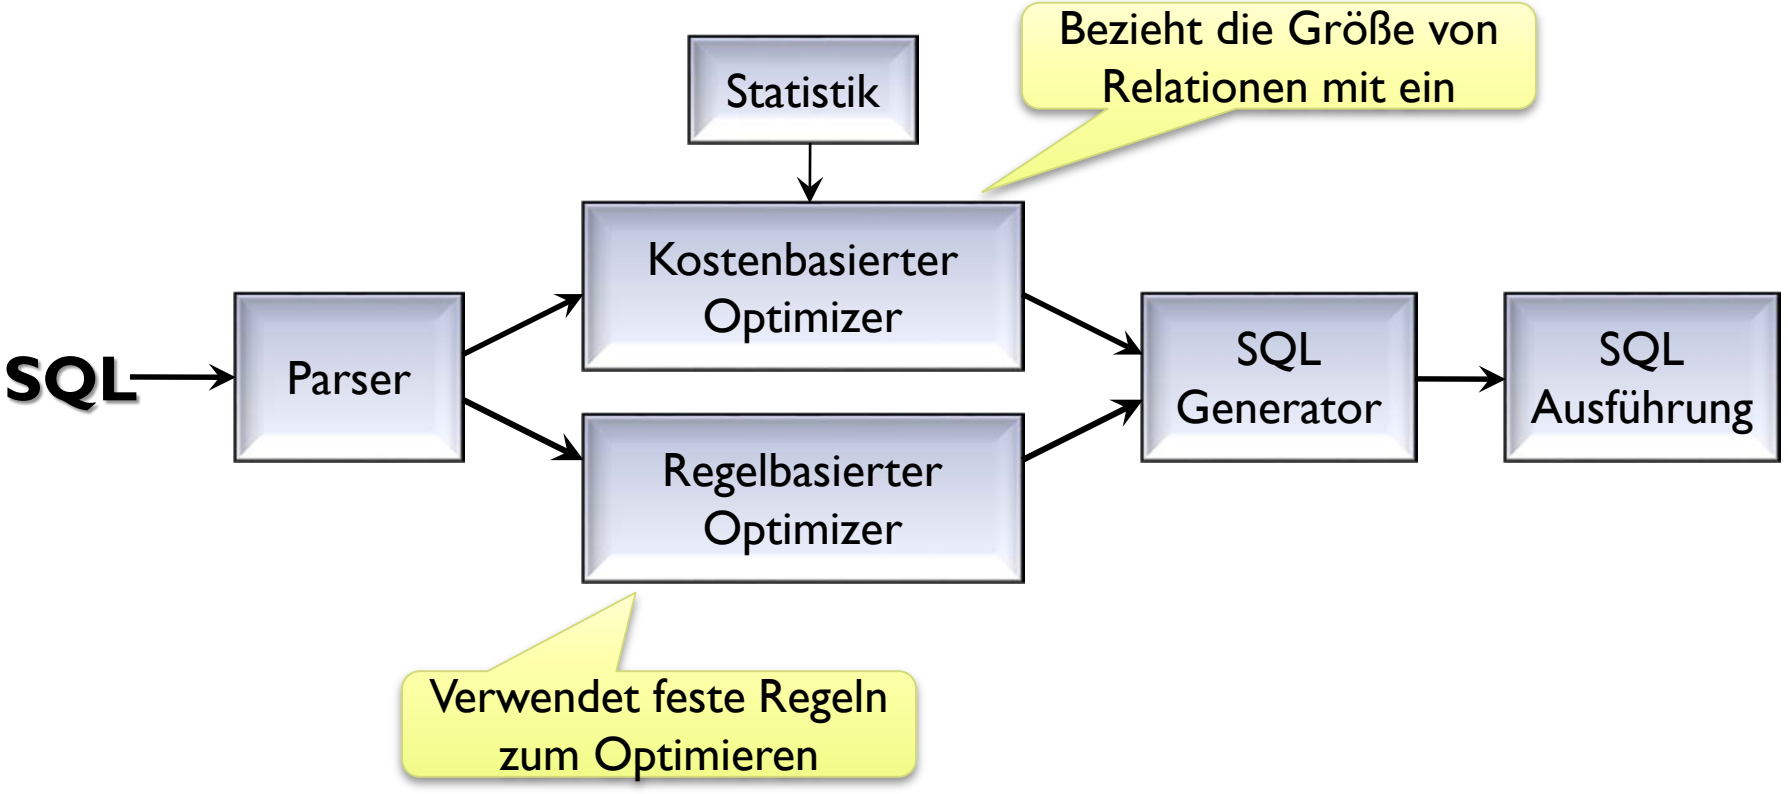

Optimizer

- **Regelbasierte Optimierung**
  - Optimierung nach vorgegebenen Regeln. Beispiele:
    - Verwende einen Index, falls vorhanden
    - Führe erst Projektion durch, dann einen Verbund
    - Führe erst Restriktion durch, dann einen Verbund
    - Verwende Merge Join, wenn Relationen bereits sortiert sind
- **Kostenbasierte Optimierung**
  - Optimierung zusätzlich in Abhängigkeit von den Kosten
  - Berücksichtigung der Größe (und des Inhalt) der Relationen
    - Beispiel: Verwende im Verbund erst die kleinere Relation

Beispiel zur Optimierung

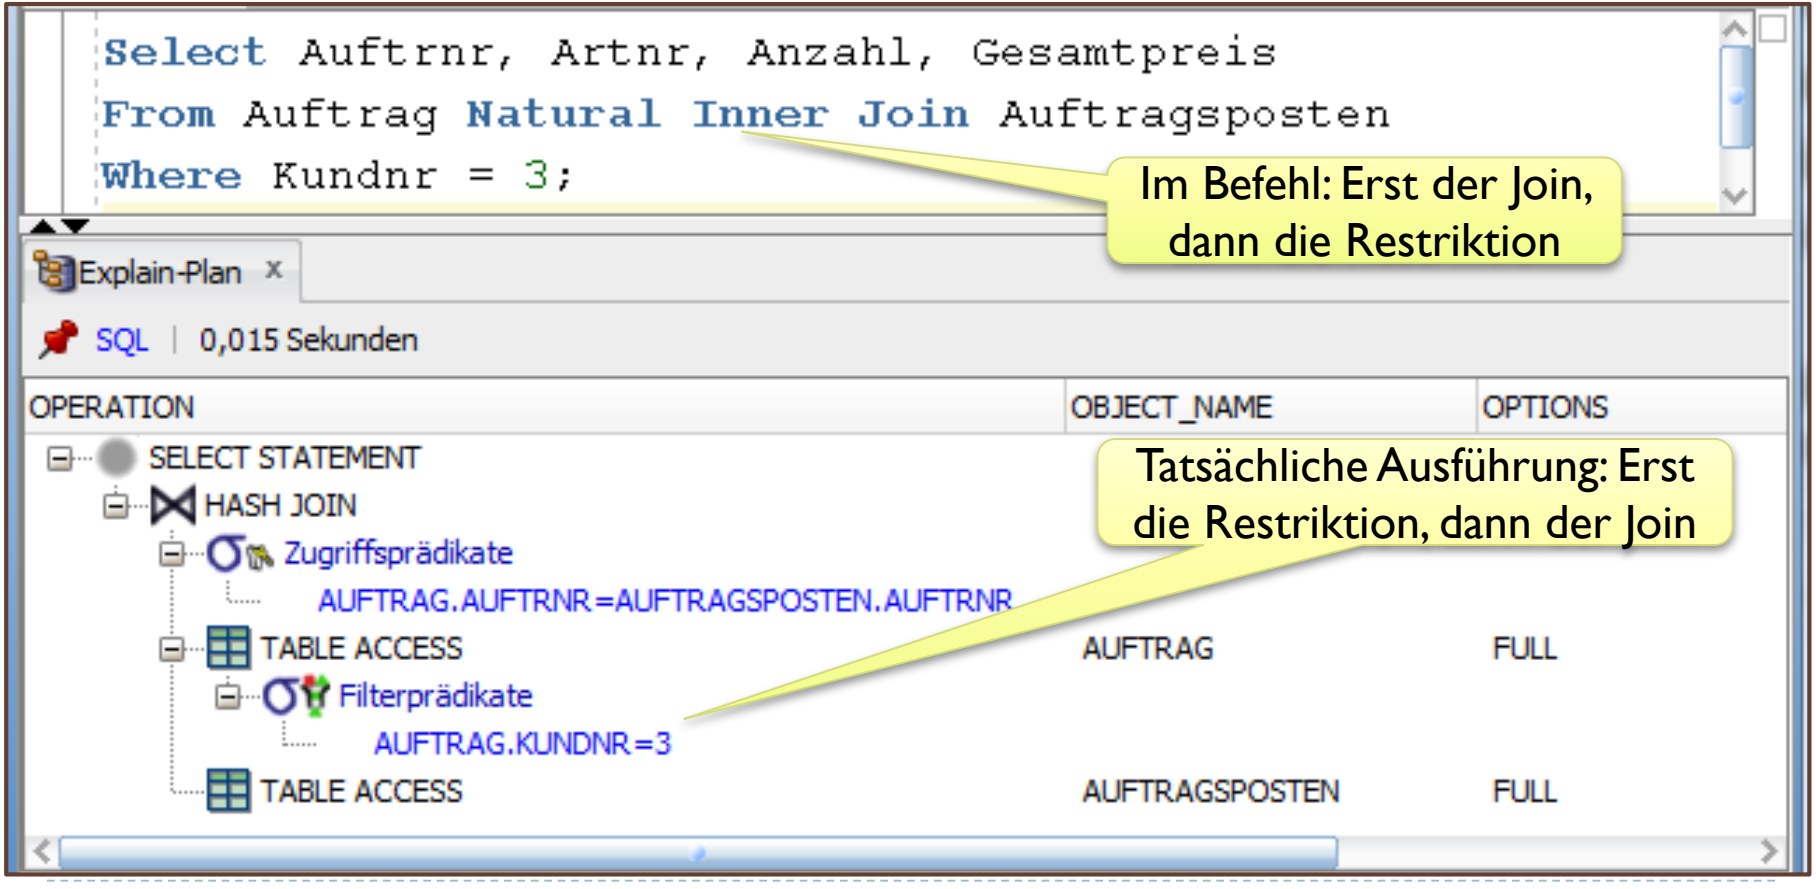

Regelbasiert versus kostenbasiert

- Regelbasierter Optimizer
  - \+ Relativ einfach implementierbar
  - – Ungenau, da nicht an die reale Tabelle angepasst
- Kostenbasierter Optimizer
  - \+ Berücksichtigt den Aufbau einer Tabelle
  - \+ Liefert deshalb sehr genaue Ergebnisse
  - – Benötigt zusätzliche Statistiken
  - – Relativ komplex und umfangreich
- Fazit:
  - Kostenbasierter Optimizer ist der Standard

Abfrageoptimierung

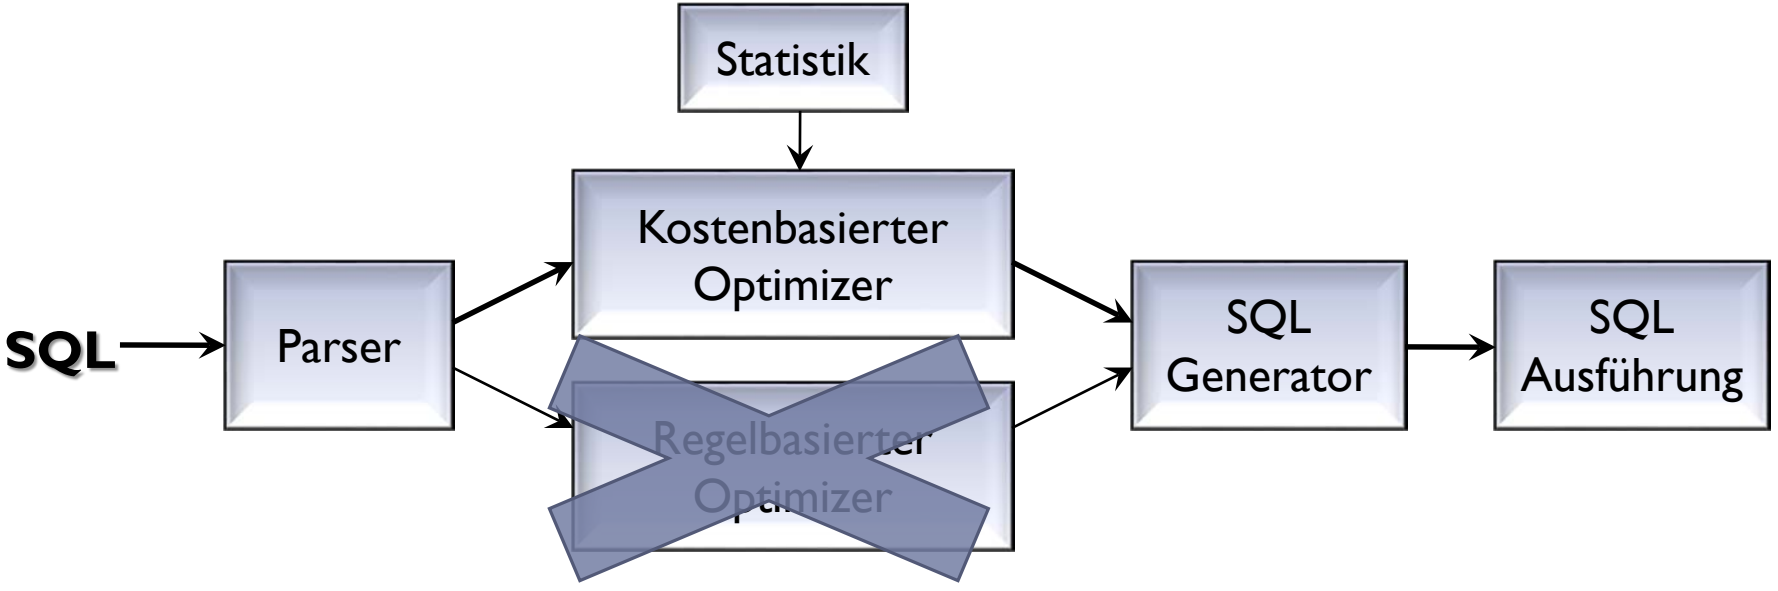

Kostenbasierter Optimizer: Aufgaben

- Analyse des Select-Befehls
- Überprüfen der Umgebung nach
  - vorhandenen Indexen
  - Aufteilung von Relationen in Partitionen
  - internen Strukturen (z.B. Aufteilung auf Festplatten)
- Auswertung der Statistiken
- Optimierung des Select-Befehls
  - unter Verwendung der obigen Gesichtspunkte
- Weiterleitung an den SQL-Generator

Statistiken

- Jede Datenbank sammelt umfangreiche Statistiken
- Notwendig für den kostenbasierten Optimizer
- Wichtige Statistiken:
  - Anzahl der Zeilen jeder Relation
  - Anzahl unterschiedlicher Einträge je Attribut und Relation
  - Zusätzlich: Histogramme zu jedem Attribut
- In der Praxis wichtig:
  - Selektivität eines Attributs → nächste Folie

Selektivität

- **Definition (Selektivität eines Attributs):**

  Die Selektivität eines Attributs sel ist der Kehrwert zur Anzahl der unterschiedlichen Attributswerte.

- Beispiele:
  - Primärschlüssel: sel = 1 / Anzahl der Zeilen
  - Geschlecht (m/f): sel = 0,5
  - Wochentage: sel = 0,14
- Die Selektivität wird benötigt:
  - bei Restriktionen: zur Abschätzung der Größe der Restrelation
  - ebenso bei Gruppierungen

Selektivität (2)

- Die Selektivität sel ist ein Mittelwert
  - Sind die Attributswerte ungleich verteilt, so sollten zusätzlich Histogramme verwendet werden
- Die Selektivität mehrerer Attribute kann einfach aus den Einzelattributen berechnet werden. Es gilt:

sel(Attr1 AND Attr2) = sel(Attr1) * sel(Attr2)

sel(Attr1 OR Attr2) = sel(Attr1) + sel(Attr2) – sel(Attr1)*sel(Attr2)

sel(NOT Attr1) = 1 – sel(Attr1)

  - Diese Gleichungen gelten exakt nur bei Gleichverteilungen

Optimierung in Oracle

Systemtabellen	Wichtige Attribute
USER_TABLES	Table_Name, Num_Rows, Avg_Row_Len
USER_TAB_STATISTICS	Table_Name, Num_Rows, Avg_Row_Len
USER_TAB_COLUMNS	Table_Name, Column_Name, Num_Distinct, Density, Num_Nulls, Avg_Col_Len, Histogram
USER_TAB_COL_STATISTICS	Table_Name, Column_Name, Num_Distinct, Density, Num_Nulls, Avg_Col_Len, Histogram

Anzahl Zeilen

entspricht Selektivität

für manche Anfragen sehr wichtig

Anzahl unterschiedliche Einträge

Statistiken in Oracle

- **Automatische Aktualisierung der Statistiken mit:**

  DBMS_AUTO_TASK_ADMIN.ENABLE

  Administratorrechte!

- **Manuelle Aktualisierung der Statistiken:**
  - Statistikpaket DBMS_STATS
  - Beispiele:

  Aktualisierung einzelner Tabellen

```
EXECUTE DBMS_STATS.GATHER_TABLE_STATS( 'Schema', 'Tabelle' );
EXECUTE DBMS_STATS.GATHER_SCHEMA_STATS( 'Schema' );
```

Aktualisierung im gesamten Schema

Achtung! Performance!

Ausführungsplan in Oracle

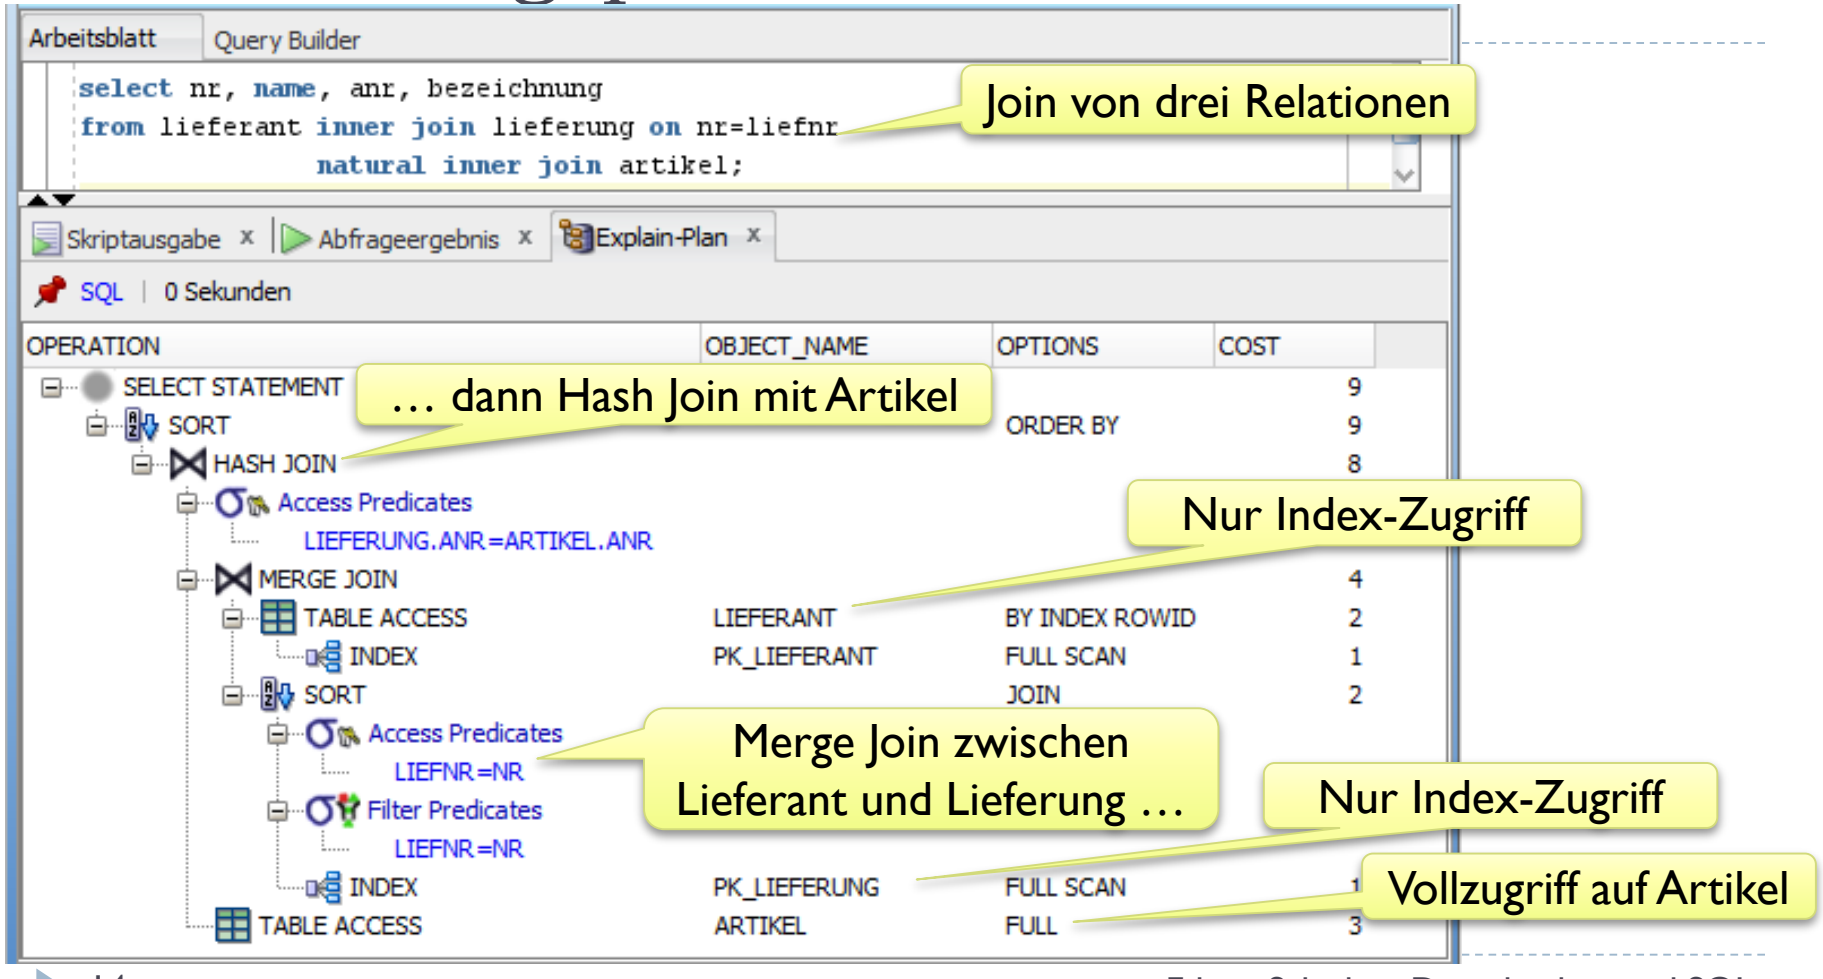

Optimierung in SQL Server

- SQL Server erzeugt zu jedem Schlüssel einen Index
- SQL Server führt Statistiken zu allen Indexen
- Ansehen von Statistiken:
  - DBCC SHOW_STATISTICS(Relation, Index);
  - oder komfortabel mit SQL Server Management Studio
- Statistiken anlegen, aktualisieren:

10% der Daten sind Basis für Hochrechnung

```
CREATE STATISTICS Statistikname ON Tabelle (Spalte) WITH FULLSCAN;
CREATE STATISTICS Statistikname ON Tabelle (Spalte) WITH SAMPLE 10 PERCENT;
ALTER DATABASE Datenbank SET AUTO_CREATE_STATISTICS ON;
ALTER DATABASE Datenbank SET AUTO_UPDATE_STATISTICS ON;
```

Automatisches Erzeugen bzw. Ändern

Beispiel einer Statistik (im SSMS)

Tabellenname: dbo.Personal

Statistikname: PK_Personal

```
Statistiken für INDEX 'PK_Personal'.
------------------------------------------------------------------

Name                                Updated
------------------------------------------------------------------
PK_Personal                         Feb  5 2013  9:00PM

All Density                         Average Length
------------------------------------------------------------------
0.1111111                           4

Histogram Steps
RANGE_HI_KEY                        RANGE_ROWS
------------------------------------------------------------------
1                                   0
3                                   1
5                                   1
7                                   1
9                                   1
```

= 1/9, da 9 Einträge (Selektivität)

Einfaches Histogramm

Ausführungsplan in SQL SErver

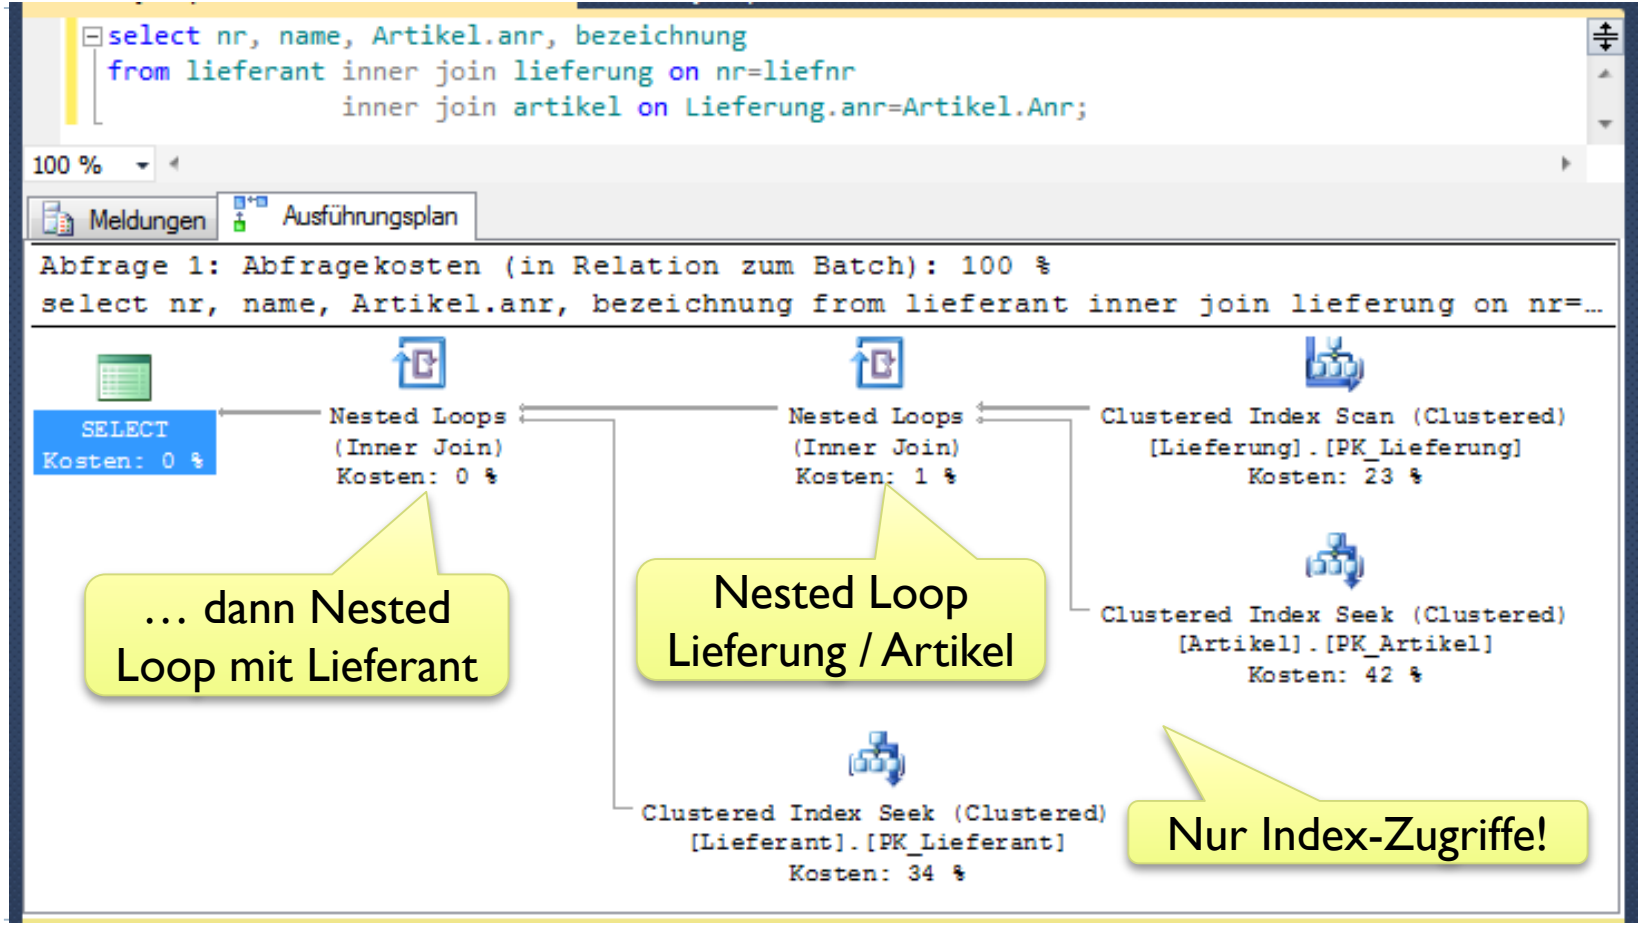

Optimierung in MySQL

- Statistiken werden automatisch angelegt für
  - Primärschlüssel
  - Alternative Schlüssel
  - Fremdschlüssel
- Statistiken stehen in:
  - Information_Schema.Statistics
- Statistiken enthalten keine Selektivität und keine Histogramme

Index

- **Definition (Index)**:

  Ein Index in einer Datenbank ist eine Struktur zur Beschleunigung von Suchvorgängen, in der Daten auf- oder absteigend sortiert angelegt werden.

- Ein Index in einer relationalen Datenbank wird in der Regel intern als eine eigenständige sortierte Tabelle angelegt, auf den mittels eines B*-Baums zugegriffen wird.

Index in SQL-1

Falls eindeutig

Index über mehrere Spalten möglich

```
CREATE [UNIQUE] INDEX Name ON
    Tabellenname ( { Spalte [ ASC | DESC ] } [ , ... ] )
```

aufsteigend (Standard)

absteigend

```
DROP INDEX Name
```

Seit SQL-2 nicht mehr normiert, aber immer noch üblich!

Systemtabellen und Indexe

Hersteller	Systemtabelle / Befehl	Inhalt
Oracle	USER_INDEXES	alle Indexe der Benutzerrelationen
Oracle	USER_IND_COLUMNS	alle Attribute mit gesetzten Indexen
SQL Server	SYS.INDEXES	alle Indexe
MySQL	SHOW INDEX FROM Tabelle	alle Indexe der Tabelle

Achtung:
nicht in INFORMATION_SCHEMA,
da Indexe nicht normiert!

Realisierung von Indexen: B*-Baum

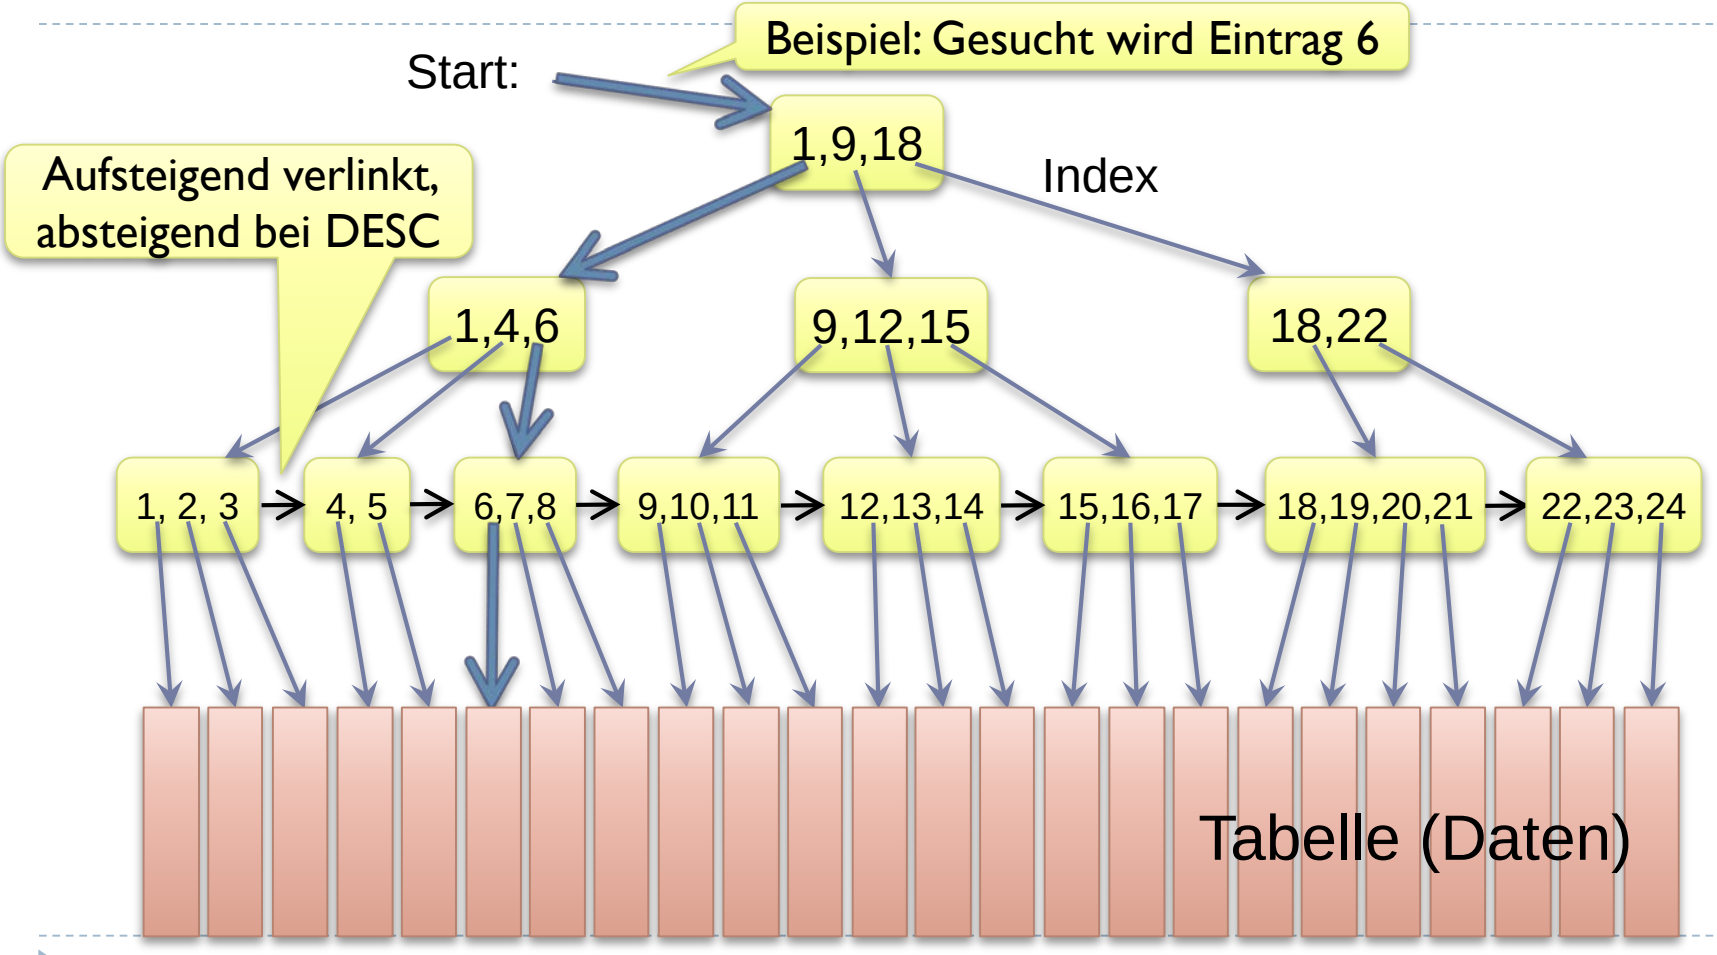

Beispiel zu Indexen: Relation Umfrage

Name	Wert
NUM_ROWS	800000
BLOCKS	6409
AVG_ROW_LEN	51
SAMPLE_SIZE	800000
LAST_ANALYZED	08.06.13
LAST_ANALYZED_SINCE	08.06.13

800000 Einträge

Spaltenstatistik

Aktualisieren: 0

Selektivität

OWNER	TABLE_NAME	COLUMN_NAME	NUM_DISTINCT	...	...	DENSITY	NUM_NULLS
BIKE	UMFRAGE	NR	800000	...		0,00000125	0
BIKE	UMFRAGE	GESCHLECHT	2	...		0,5	0
BIKE	UMFRAGE	FAMILIENSTAND	4	...		0,25	160000
BIKE	UMFRAGE	GEBURTSJAHR	50	...		0,02	0
BIKE	UMFRAGE	AUTOMARKE	1000	...		0,001	0
BIKE	UMFRAGE	WOHNORT	49548	...		0,0000201824493...	0

50000 Orte

Zugriff auf Relation Umfrage

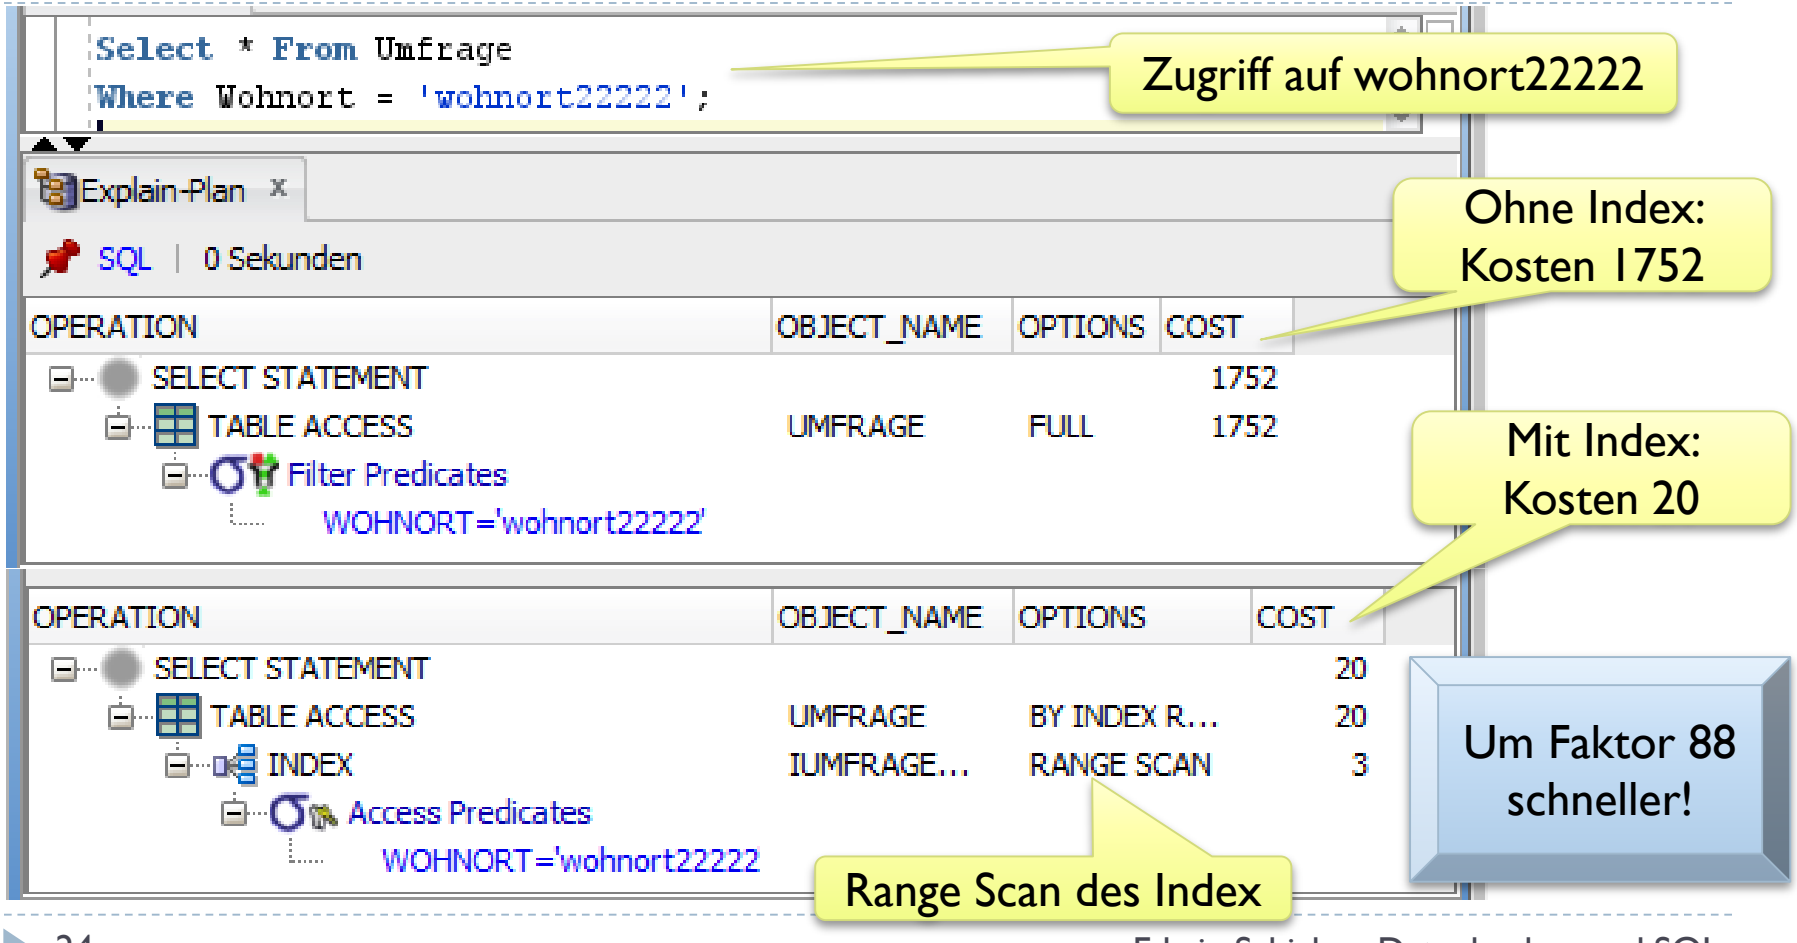

Ergebnis

- Das Setzen und Entfernen des Index erfolgte mit:

  ```
  CREATE INDEX IUmfrageWohnort ON Umfrage(Wohnort);
  DROP INDEX IUmfrageWohnort;
  ```

- Das Erzeugen eines Index erfordert etwas Zeit und benötigt Speicherplatz
- Der lesende Zugriff wird erheblich beschleunigt
- Der schreibende Zugriff wird langsamer, da Index immer mit aktualisiert werden muss
- Folgerung: So viele Indexe wie nötig, so wenige wie möglich

Partitionierung

- Nachteil sehr großer Relationen
  - Keine Parallelzugriffe, da nur ein Medium
  - Bei Suche ohne Index: Komplette Relation durchsuchen
- Zerlegen in viele kleine Teilrelationen
  - Vorteil:
    - Obige Nachteile fallen weg
  - Nachteil:
    - Anwender muss Strukturen kennen
    - Neue Teile sind den Anwendungsprogrammen nicht bekannt, daher inflexibel
- Lösung: Partitionen

Definition: Partitionierung

- **Definition:**
  - Unter einer Partitionierung verstehen wir eine horizontale, vollständige und transparente Aufteilung einer Relation in disjunkte Teilrelationen.
  - Diese Teilrelationen bezeichnen wir als Partitionen.

- **Begriffe:**
  - Horizontal: zeilenweise (nicht spaltenweise)
  - Vollständig: 
  - Transparent: Nicht sichtbar für den Anwender
  - Disjunkt: Keine redundante Aufteilung

Partitionierung am Beispiel

Gegeben: Relation Produktion, partitioniert nach Monaten

Zugriff

Produktion

Zugriff wird durchgereicht

Prod_Jan

Prod_Feb

...

Prod_Dez

In Wirklichkeit: Monatspartitionen

Anwender kennt nur die Relation Produktion

Unterstützung der Partitionierung

Hersteller	Partitionierungstypen
Oracle	Bereichs-Partitionierung List-Partitionierung Hash-Partitionierung Intervall-Partitionierung Referenz-Partitionierung Virtuelle spaltenbasierte Partitionierung
SQL Server	Bereichs-Partitionierung Index-Partitionierung
MySQL	Bereichs-Partitionierung List-Partitionierung Hash-Partitionierung Schlüssel-Partitionierung

Bereichspartitionierung am Beispiel

- **Bereichspartionierung (Range-Partitioning) in Oracle:**

Nach außen sichtbar

```
CREATE TABLE Auftrag (
    Auftrnr    INT       PRIMARY KEY,
    Datum      DATE      NOT NULL,
    Kundnr     INT       NOT NULL REFERENCES Kunde,
    Persnr     INT       REFERENCES Personal     )
 PARTITION BY RANGE (Datum)
 (  PARTITION Auftrag2010 VALUES LESS THAN DATE '2011-01-01',
    PARTITION Auftrag2011 VALUES LESS THAN DATE '2012-01-01',
    PARTITION Auftrag2012 VALUES LESS THAN DATE '2013-01-01',
    PARTITION Auftrag2013 VALUES LESS THAN DATE '2014-01-01'       );
```

Relation Auftrag wird nach Jahren partitioniert

Intern real existent

Partitionierungsarten (1)

- **Bereichspartitionierung:**
  - Einteilung in disjunkte Bereiche (meist nach Datum/Zeit)
  - Sehr häufig eingesetzt
  - In allen Datenbanken implementiert
- **List-Partitionierung**
  - Einteilung nach Listen
  - Beispiel: Einteilung nach Verkaufsländern (Liste aller Länder)
- **Hash-Partitionierung**
  - Datenbank übernimmt die Einteilung nach Hash-Codes
  - Nur interessant, wenn es sonst keine sinnvolle Einteilung gibt

z.B. eine Partition für Deutschland, eine Partition für Österreich und Schweiz gemeinsam usw.

Partitionierungsarten (2)

- Intervall-Partitionierung
  - Spezielle Bereichspartitionierung
  - Partitionierungsintervalle werden vorgegeben
  - Beispiel: Monatsintervall → Jeden Monat wird automatisch neue Partition erzeugt
- Virtuelle spaltenbasierte Partitionierung
  - In Oracle gibt es virtuelle Spalten (aus realen abgeleitet)
  - Partitionierung mit Hilfe dieser virtuellen Spalten
- Index-Partitionierung
  - In SQL Server: Index kann mit Relation partitioniert werden

Partitionierungsarten (3)

- Schlüsselpartitionierung
  - Spezielle Hashpartitionierung
  - Primär- oder alternativer Schlüssel dienen als Hash-Code
- Referenzpartitionierung → nächste Folie

- Viele Kombinationen sind möglich
  - Range – List (erst Rangepartitionierung, dann Listpart.)
  - Range – Hash
  - List – Hash usw.

Referenzpartitionierung

- Auftrag ist nach Jahren partitioniert (siehe oben)
- Auftragsposten enthält kein Datum, soll aber ebenso aufgeteilt werden → Referenzpartitionierung

```
CREATE TABLE Auftragsposten (
    Posnr          INT       PRIMARY KEY
    Auftrnr        INT       NOT NULL,
    Teilenr        INT       NOT NULL,
    Gesamtpreis    NUMERIC(8,2),
    Anzahl         INT,
    CONSTRAINT Auftrpos_FK FOREIGN KEY(Auftrnr)
                                    REFERENCES Auftrag      )
  PARTITION BY REFERENCE( Auftrpos_FK )      ;
```

Partitionierung wie Auftrag!

Partitionierung: Zusammenfassung

- Partitionierung bei sehr großen Relationen wichtig
- Vorteile:
  - Transparenz: nicht sichtbar für Anwender
  - Parallele Verarbeitung möglich
  - Gezielter Zugriff auf nur eine oder wenige Partitionen statt auf gesamte Relation
- Folgerung:
  - Teils erhebliche Performancesteigerung

Materialisierte Sichten (Problem)

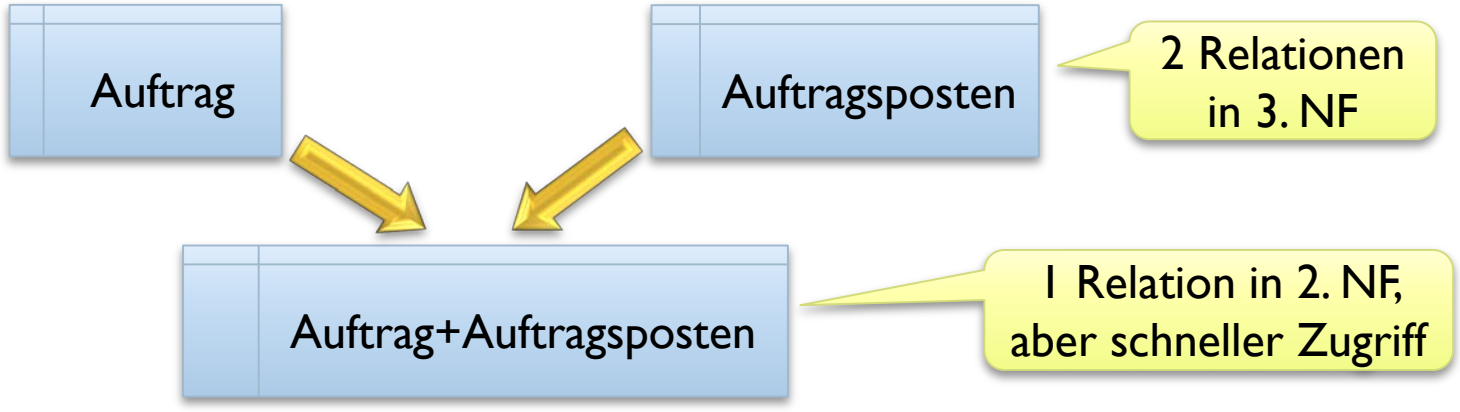

- Zusammenfassung von Auftrag und Auftragsposten?
  - Kein Join → Schnellere Zugriffe → Bessere Performance
  - Redundanz → Mehr Speicher → Gefahr von Inkonsistenz

Relation AuftragKomplett

Auftrag JOIN Auftragsposten

Posnr	Auftrnr	Datum	Kundnr	Persnr	Artnr	Anzahl	Gesamtpreis
101	1	04.01.2013	1	2	200002	2	800,00
201	2	06.01.2013	3	5	100002	3	1.950,00
202	2	06.01.2013	3	5	200001	1	400,00
301	3	07.01.2013	4	2	100001	1	700,00
302	3	07.01.2013	4	2	500002	2	100,00
401	4	18.01.2013	6	5	100001	1	700,00
402	4	18.01.2013	6	5	500001	4	30,00
403	4	18.01.2013	6	5	500008	1	94,00
501	5	03.02.2013	1	2	500010	1	40,00
502	5	03.02.2013	1	2	500013	1	30,00

Materialisierte Sichten (Idee)

- Sicht anlegen (Join zwischen Auftrag und Auftragsposten)
- Sicht physisch speichern!
- Vorteile:
  - Schnelle Zugriffe über (physische) Sicht
  - 3. NF der Basisrelationen bleibt erhalten
- Nachteile:
  - Es gibt jetzt Basisrelationen und (physische) Sicht parallel
  - Also: Redundanz und Gefahr der Inkonsistenz
- Wunsch:
  - Datenbank muss Datenabgleich intern übernehmen

Materialisierte Sicht AuftragKomplett

```
CREATE MATERIALIZED VIEW AuftragKomplett
    REFRESH FAST ON COMMIT
AS SELECT  Posnr, AuftrNr, Datum, Kundnr, Persnr,
           Artnr, Anzahl, Gesamtpreis
    FROM   Auftrag NATURAL INNER JOIN Auftragsposten ;
```

Analog zu Create View

- Refresh Fast / Refresh Complete [On Commit]

Nur Änderungen nachvollziehen

Alternativ: Inhalt komplett neu erzeugen

Beim Commit aktualisieren

Alternative: Zu bestimmten Zeitpunkten aktualisieren: START NEXT …

Materialisierte Sichten: Resümee

- Bei selten geänderten Relationen hervorragend geeignet
- Reduziert aufwändige Joins
- Allerdings:
  - Hoher interner Aufwand der Aktualisierung
  - Bei Refresh Fast wird ein Logbuch benötigt:

    CREATE MATERIALIZED VIEW LOG …

- Entfernen einer materialisierten Sicht:

  DROP MATERIALIZED VIEW MV_Name

Optimierung von Select-Befehlen

- Optimizer arbeitet nicht immer optimal
- Beispiel:
  - Frauenverband mit wenigen männlichen Mitgliedern
  - Suche aller männlichen Mitglieder
  - Optimizer:
    - Selektivität für Geschlecht ist 0,5
    - Index lohnt nicht, da sowieso jedes 2. Mitglied gesucht wird
  - Realität:
    - Suche der wenigen männlichen Mitglieder über Index wäre effektiv
- Folgerung:
  - Wir beschäftigen uns ein wenig mit Optimierung

Vorteil des Optimizers

- Optimizer kennt alle Regeln der Relationalen Algebra!
- Wichtig sind insbesondere:

Vertauschung von Restriktion und Verbund

(1) $\sigma_{Bedingung}(R1 \bowtie R2) = \sigma_{Bedingung}(R1) \bowtie \sigma_{Bedingung}(R2)$

Spezialfall von (1)

(2) $\sigma_{Bedingung\_an\_R2}(R1 \bowtie R2) = R1 \bowtie \sigma_{Bedingung\_an\_R2}(R2)$

Vertauschung von Projektion und Restriktion

(3) $\pi_{Auswahl}(\sigma_{Bedingung}(R)) = \sigma_{Bedingung}(\pi_{Auswahl}(R))$

Vertauschung von Projektion und Verbund

(4) $\pi_{Auswahl}(R1 \bowtie R2) = \pi_{Auswahl}(R1) \bowtie \pi_{Auswahl}(R2)$

Achtung: Projektion muss verbindende Attribute enthalten!

Wichtige Regeln (1)

- Ein Verbund (und ein Produkt) zweier Relationen ist aufwändig
- Ziel: Beide Relationen vorher verkleinern
- Regel:
  - Erst Restriktion und Projektion
  - Dann Gruppierung
  - Und dann erst Verbund (Produkt)
- Der Optimizer kennt diese Regeln

Restriktion ist besonders effektiv, da dann meist weniger Daten eingelesen werden müssen

Beispiel zur Optimierung (Wiederholung)

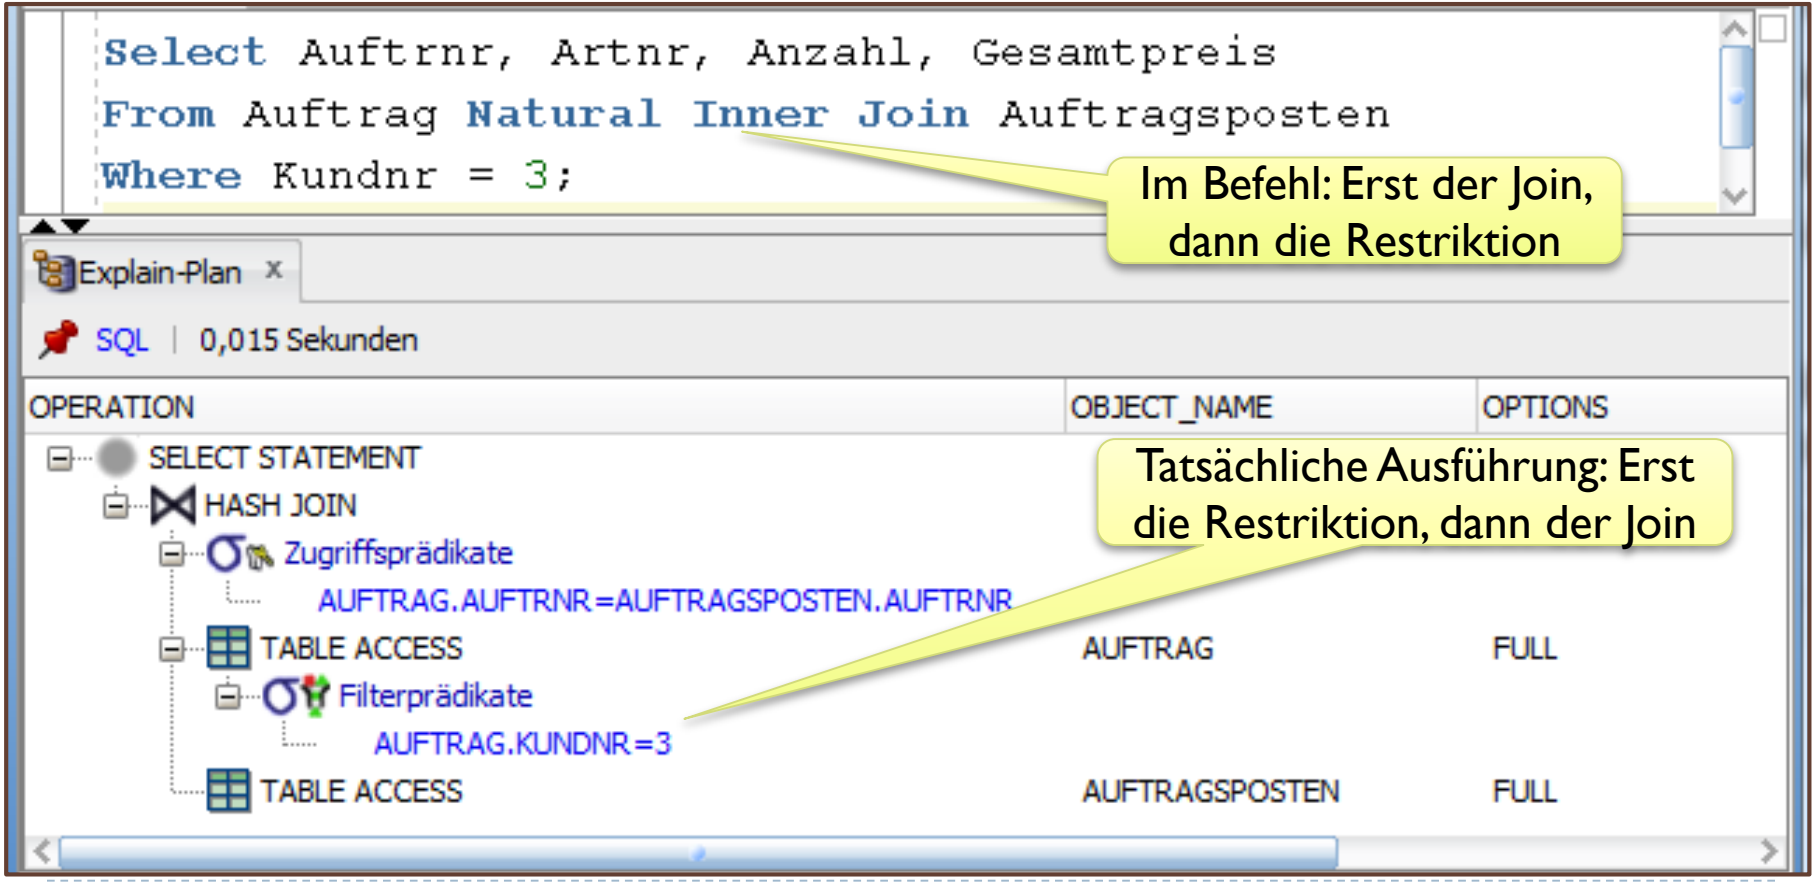

Sicht VAuftrag (Wiederholung)

AuftrNr	Datum	Kundname	Persname	Summe
1	04.01.2013	Fahrrad Shop	Anna Kraus	800
2	06.01.2013	Maier Ingrid	Johanna Köster	2350
3	07.01.2013	Rafa – Seger KG	Anna Kraus	800
4	18.01.2013	Fahrräder Hammerl	Johanna Köster	824
5	06.02.2013	Fahrrad Shop	Anna Kraus	70

- Verbund aus Auftrag, Kunde, Personal und Auftragsposten

Beispiel zu den Grenzen des Optimizers

- **Select-Befehl zur Sicht VAuftrag:**

```
SELECT    AuftrNr, Datum, Kunde.Name, Personal.Name,
          SUM (Gesamtpreis)
FROM      Auftrag    JOIN Kunde  ON Kunde.Nr = Auftrag.Kundnr
                     JOIN Personal  USING (Persnr)
                     JOIN Auftragsposten USING (Auftrnr)
GROUP BY Auftrnr, Datum, Kunde.Name, Personal.Name ;
```

- **Schwäche:**
  - Group By kommt nach JOIN
  - Group By bezieht sich aber nur auf Auftragsposten

Woher soll das der Optimizer wissen?

Ausführungsplan

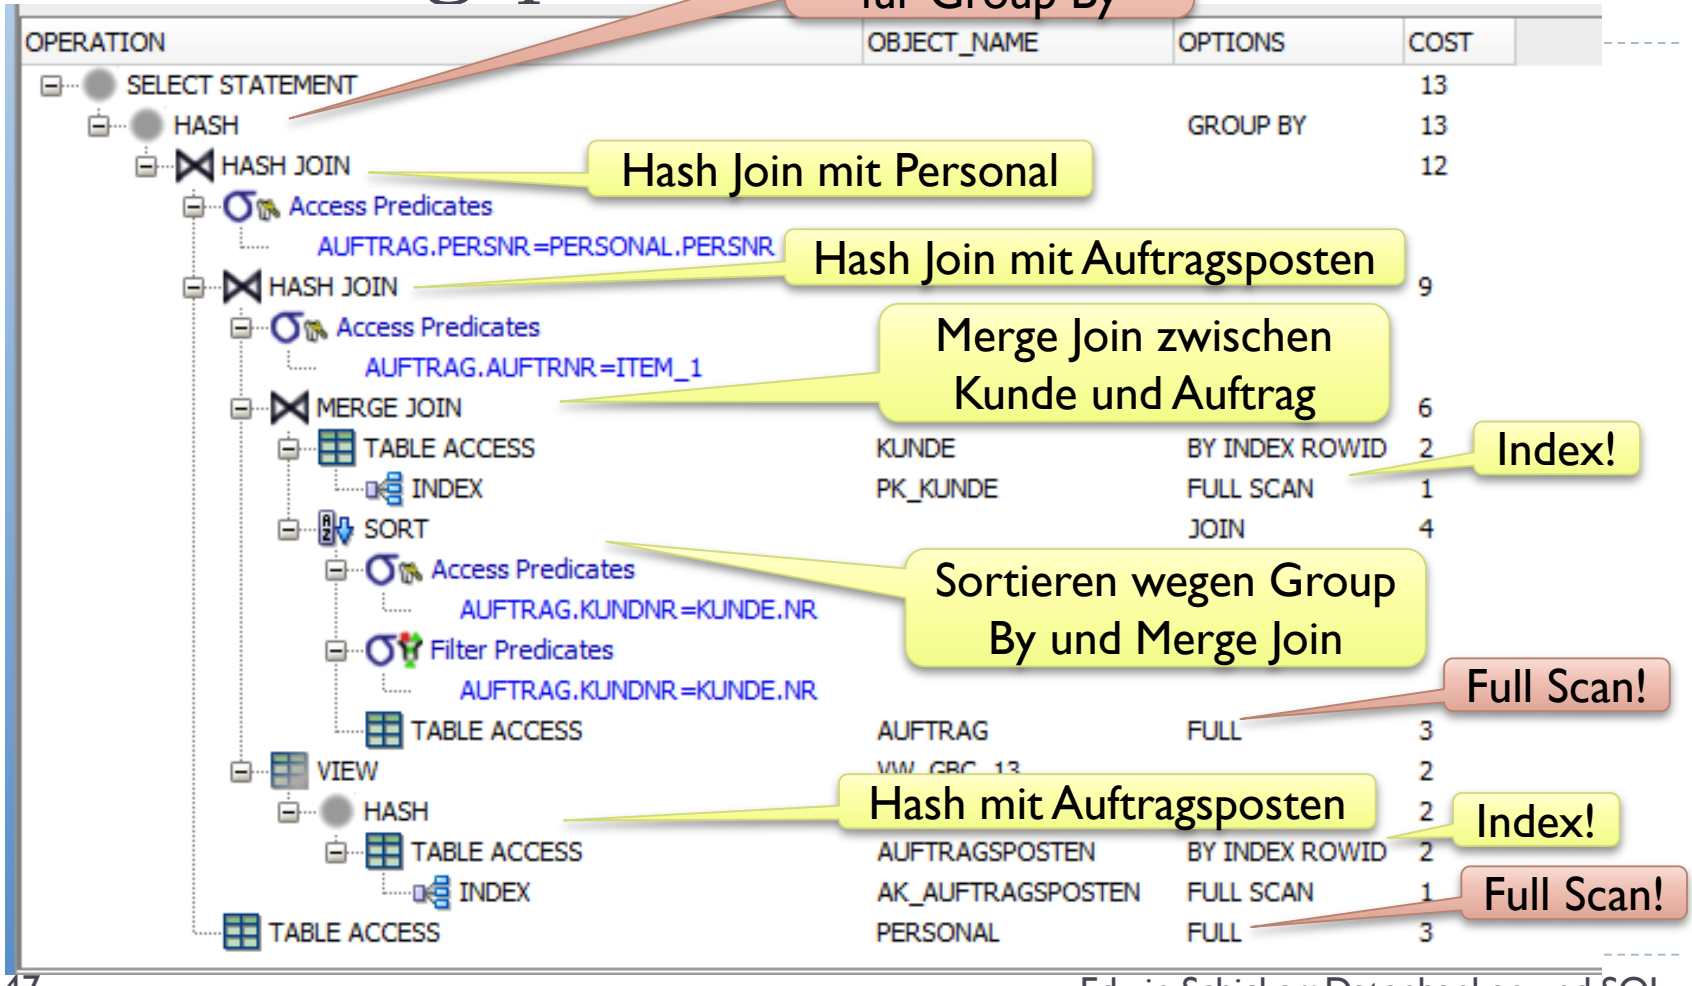

OPERATION	OBJECT_NAME	OPTIONS	COST
SELECT STATEMENT			13
HASH		GROUP BY	13
HASH JOIN			12
Access Predicates			
AUTFRAG.PERSNR=PERSONAL.PERSNR			
HASH JOIN			9
Access Predicates			
AUFTRAG.AUFTRNR=ITEM_1			
MERGE JOIN			6
TABLE ACCESS	KUNDE	BY INDEX ROWID	2
INDEX	PK_KUNDE	FULL SCAN	1
SORT		JOIN	4
Access Predicates			
AUFTRAG.KUNDNR=KUNDE.NR			
Filter Predicates			
AUFTRAG.KUNDNR=KUNDE.NR			
TABLE ACCESS	AUFTRAG	FULL	3
VIEW	VW_GBC_13		2
HASH			2
TABLE ACCESS	AUFTRAGSPOSTEN	BY INDEX ROWID	2
INDEX	AK_AUFTRAGSPOSTEN	FULL SCAN	1
TABLE ACCESS	PERSONAL	FULL	3

Gruppierung vor Verbund

- **Der Select-Befehl lautet jetzt:**

```
SELECT  AuftrNr, Datum, K.Name, P.Name, AP.Summe
FROM    Auftrag JOIN
        (Select Nr, Name From Kunde) K ON K.Nr = Auftrag.Kundnr
        JOIN (Select Persnr, Name From Personal) P USING (Persnr)
        JOIN (  Select Auftrnr, Sum(Gesamtpreis) As Summe
                From Auftragsposten
                Group By Auftrnr      ) AP     USING (Auftrnr)
```

Ausführungsplan nach Vertauschung

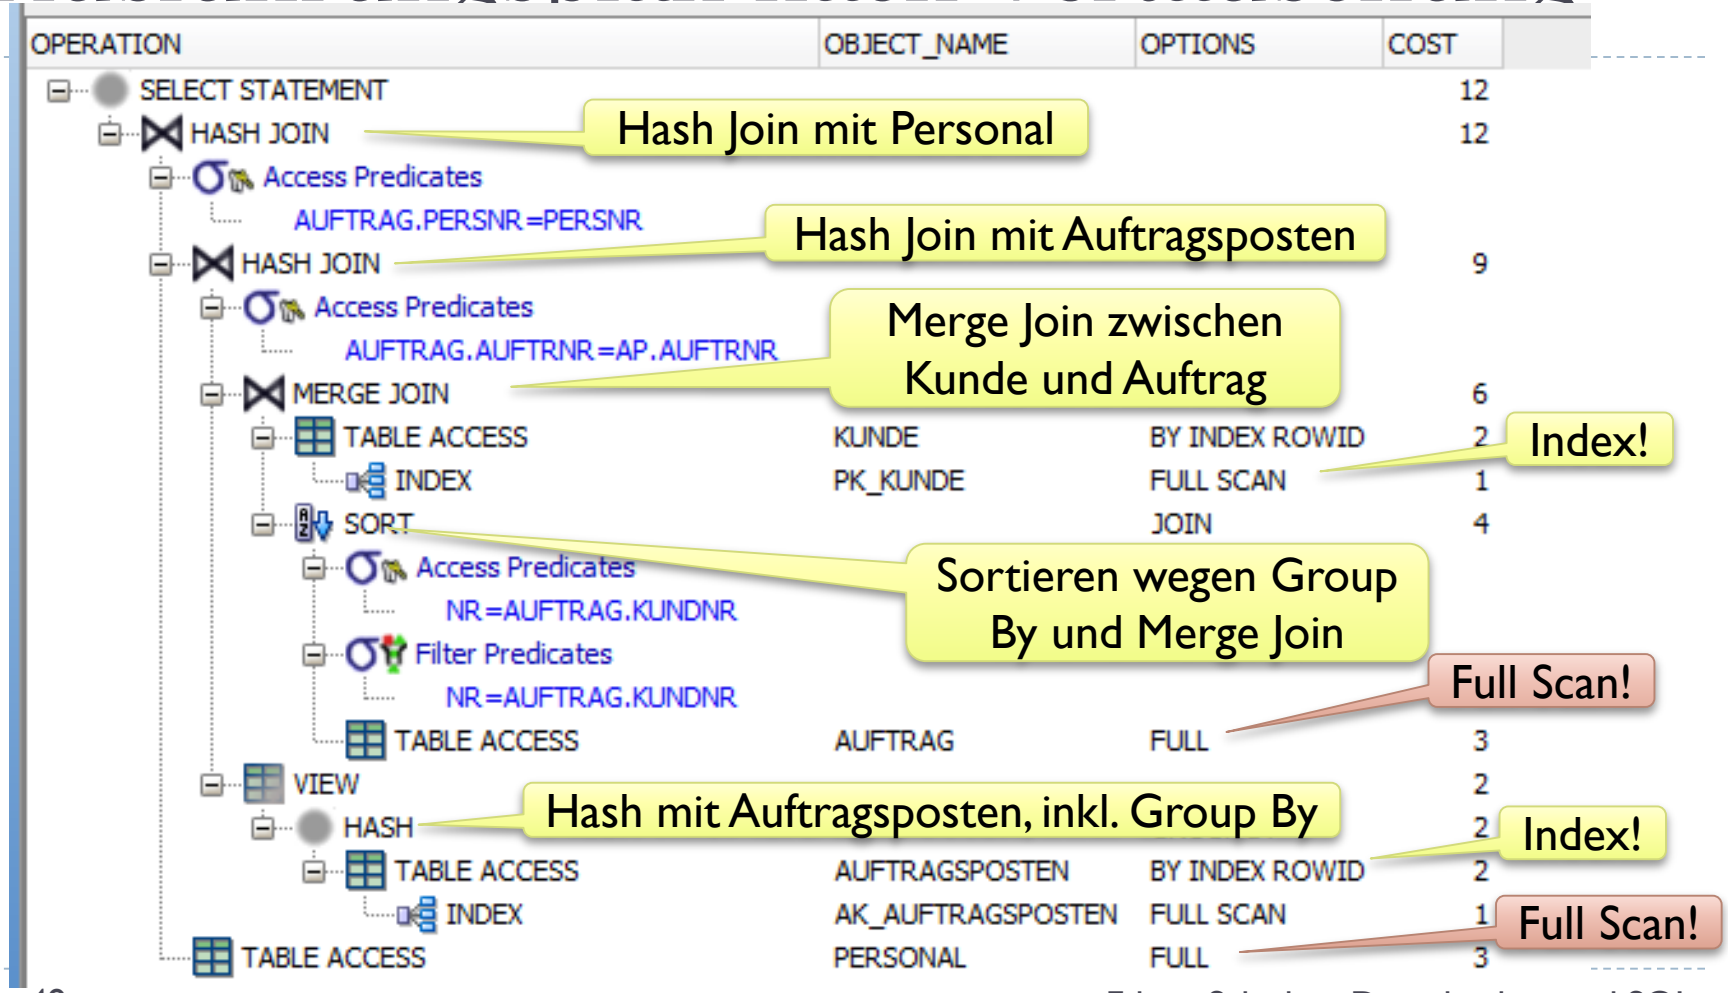

Wichtige Regeln (2)

- Sortieren ist in großen Relationen extrem aufwändig
- Sortieren steckt indirekt in vielen Operationen
- Wir versuchen daher einige Operationen zu vermeiden:
  - Kein Union (stattdessen: Union All)
  - Kein Order By
  - Kein Select Distinct
  - Kein Group By

Union entfernt gleiche Einträge, aufwändig! Union All tut dies nicht!

Sortiert! Alternative: Limit, Rownum

Entfernt gleiche Einträge, aufwändig!

Gruppieren heißt: Gleiche Einträge suchen!

Der Verbund (JOIN)

- Der Verbund wird sehr oft benötigt
- Der Verbund ist aufwändig
- Regel:
  - Die kleinere Relation steht links vom Join-Operator
  - Eine vorherige Restriktion wird dabei berücksichtigt!
- Wichtige (interne) Verbund-Operationen:
  - Nested Loop Join
  - Hash Join
  - Merge Join

Der Optimizer kennt diese Regel

Geschachtelte Schleife: Äußere Schleife über die linke Relation

Mit Hashtabellen

Erfordert vorheriges Sortieren der beiden Relationen

Nested Loop Join (R1 ⋈ R2)

- **Schleife (grob):**

  foreach (linke Relation R1 as row1)

  foreach (rechte Relation R2 as row2)

  vergleiche row1 mit row2

- **Optimierung:**
  - Vergleiche datenblockweise, nicht zeilenweise
  - Dies optimiert die Einlesevorgänge
- **Aufwand:**
  - R1 wird komplett eingelesen
  - Ist Hauptspeicher knapp, so wird R2 bis zu |R1|-mal gelesen
  - In Summe: |R1| + |R1|*|R2| (|R| = Anzahl der Blöcke von R)

Wenn R1 kleiner als R2, dann |R1|<|R2|
Also: kleinere Relation steht links!

Hash Join (R1 ⋈ R2)

- Aufbau einer Hash-Tabelle zu R1 und R2
- Aufwand
  - Lesen von R1 und R2 wegen Hash-Tabelle
  - Lesen von R1 und R2 wegen des Verbindens
  - Lesen von R1 und R2 wegen abschließenden Mischens
- Bei extrem knappem Speicher gilt für den max. Aufwand:

  3 * (|R1| + |R2|) (|R| = Anzahl der Blöcke von R)
- Ohne Beweis:
  - Bei knappem Speicher hat Hash große Vorteile, wenn die linke Relation kleiner ist!

Merge Join (R1 ⋈ R2)

- Idee:
  - Sortieren von R1
  - Sortieren von R2
  - Zusammenmischen der beiden Relationen
- Aufwand:
  - Das Sortieren erfordert c*n*log(n) Schritte, n=Anzahl, c=const
- Problem:
  - Bei knappem Speicher können sortierte Relationen nicht im Arbeitsspeicher gehalten werden.
  - Daher: Aufwand vergleichbar mit Hash und Nested Loop

Vergleich der drei Joins

- Je nach Anwendung kann jeder Join der beste sein
- Grob gilt:
  - Merge Join kommt mit wenig Arbeitsspeicher aus
  - Nested Loop Join benötigt viel Arbeitsspeicher, ist dann schnell
  - Hash Join ist optimal, wenn eine Relation relativ klein
- Die kleinere Relation als erste Relation hat Vorteile
  - bei Nested Loop Join
  - bei Hash Join

Index und Select-Befehl

- Index zu einem Attribut kann nur verwendet werden, wenn direkt dieses Attribut im Select verwendet wird!
- Negatives Beispiel:
  - Suche nach einem Namen, der indiziert ist
  - Verwendet wird: … Where Trim(Name) Like …
  - Index kann nicht mehr verwendet werden, da auch führende Leerzeichen entfernt werden!
  - Hervorragende Alternative:
    - … Where RTrim(Name) Like …

Das noch verbleibende rechtsseitige Trimmen stört den Index nicht

Index und Oracle

- Standard: Setzen von Indexen auf Attribute
- Oracle: Zusätzlich Setzen von Indexen auf Ausdrücke!
- Beispiel:

```
CREATE INDEX IUmfrageWohnort
                                ON Umfrage(Upper(Wohnort)) ;
```

- Der Index wird auf die Großbuchstaben angewendet
- Nur bei Verwendung von Upper(Wohnort) ist die Suche jetzt schnell

Vergleich zwischen In und Exists

- Trugschluss:
  - Der Exists-Operator ist in der Regel nicht langsamer als der In-Operator!
  - Das Gleiche gilt für Not Exists und Not In
- Beispiel:
  - Ausgabe aller Mitarbeiter, die weniger als Mitarbeiter 3 verdienen, siehe Kapitel 5
    - Lösung mit Vergleichsoperator
    - Lösung mit Verbund
    - Lösung mit Exists-Operator

Ausführungsplan mit Vergleich

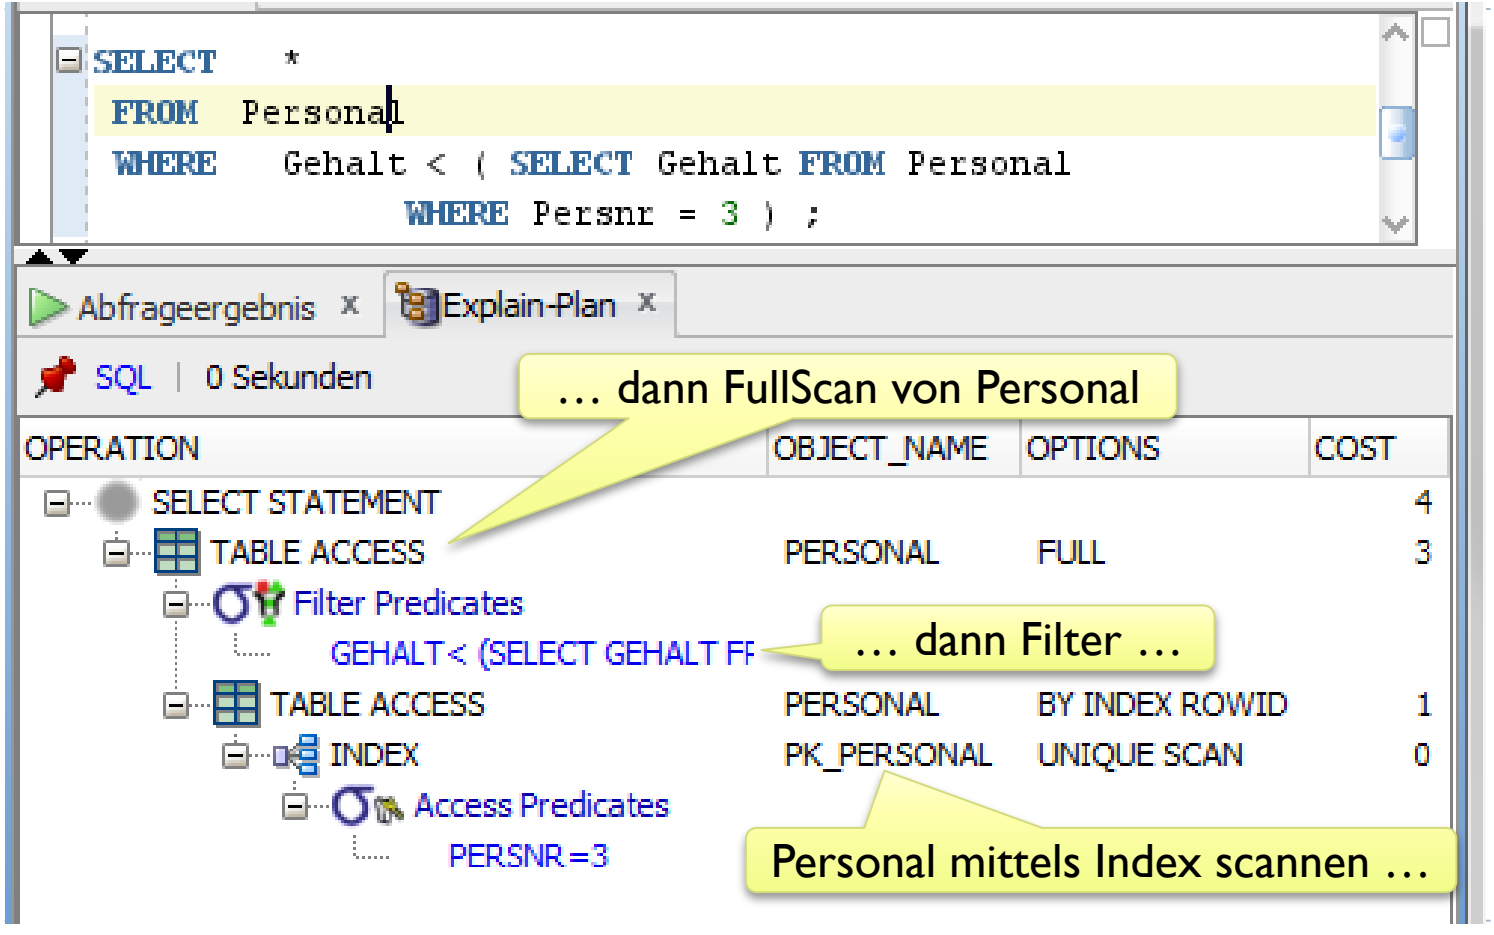

Ausführungsplan mit Exists

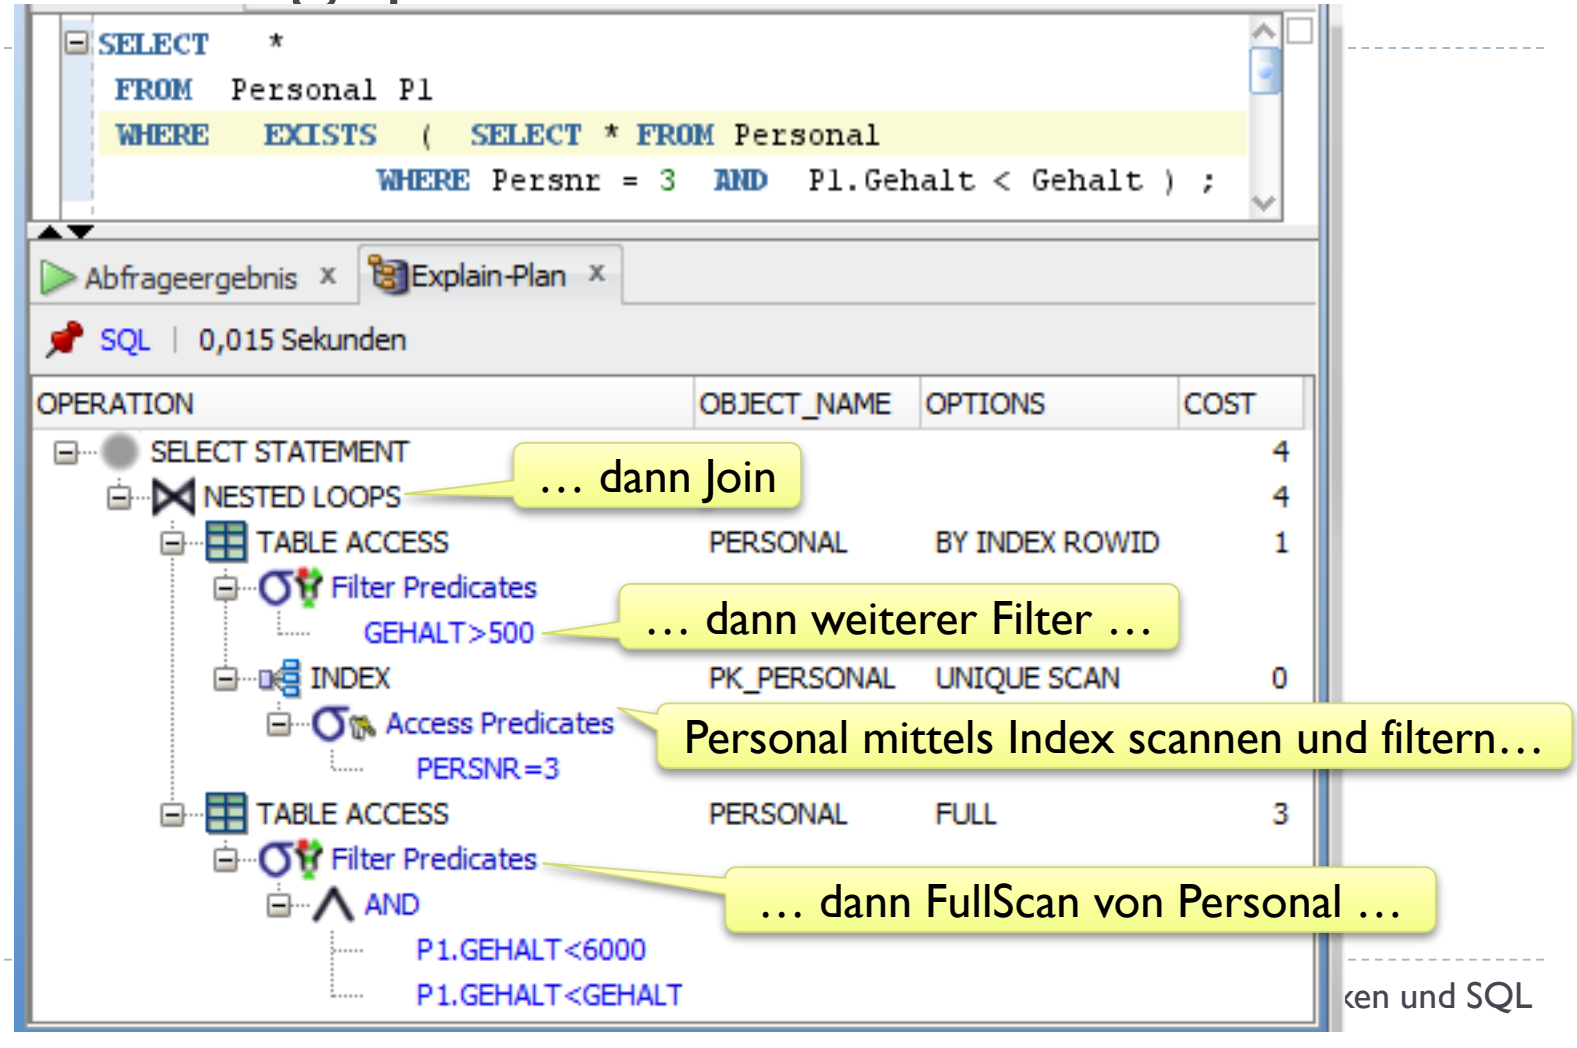

Hinweise (HINTS)

- Nicht immer kennt der Optimizer die Daten optimal
- Dem Optimizer können daher Hinweise gegeben werden
- Beispiel:
  - Wir wollen, dass bei der Abfrage auf den Wohnort in der Relation Umfrage kein Index verwendet wird
  - Lösung in Oracle:

    Quasi als Kommentar

    Select /*+ NO_INDEX(Umfrage) */ * From Umfrage Where …
  - Lösung in SQL Server:

    Erzwingt das Scanner der Tabelle

    Select * From Umfrage With (FORCESCAN) Where …
  - Lösung in MySQL:

    Select * From Umfrage Ignore Index(IUmfrageWohnort) Where …

Stored Procedures

- Eine Stored Procedure
  - ist eine Prozedur (procedure)
  - wird in der Datenbank abgespeichert (stored)
- Eine Stored Procedure enthält
  - SQL Befehle
  - Variablen-Deklarationen
  - Anweisungen
- Stored Procedure sind normiert mit
  - SQL 3 (SQL 1999)
  - SQL 2003

z.B. Select, Insert, Update, Delete, Create Index

z.B.: DECLARE nummer INT;

z.B.: SET nummer = 3;

Stored Procedure versus Trigger

- Gemeinsam:
  - Prozeduren
  - In Datenbank gespeichert
- Unterschiede:
  - Trigger werden bei Ereignissen automatisch aufgerufen
  - Stored Procedures werden explizit aufgerufen
- Syntax:
  - CREATE TRIGGER
  - CREATE PROCEDURE

Beispiel

- Prozedur RABATT:
  - Parameter:
    - ARTNR: Artikelnummer, auf den Rabatt gewährt wird
    - NACHLASS: Der Preisnachlass für den Artikel
  - Idee:
    - Wenn der Nachlass unter 50% des eingetragenen Preises liegt, so wird der angegebenen Nachlass vom Preis des angegebenen Artikels abgezogen. Der neue Preis wird in der Relation eingetragen.
    - Sonst wird genau ein Nachlass von 50% gewährt. Der neue Preis wird entsprechend eingetragen.
  - Realisierung:
    - CREATE PROCEDURE Rabatt

Prozedur RABATT in Oracle

nicht NUMERIC(8,2)

```
CREATE OR REPLACE PROCEDURE Rabatt ( artnr INT , nachlass NUMERIC ) AS
    altPreis  NUMERIC(8,2);
    neuPreis  NUMERIC(8,2);
BEGIN
    SELECT Preis     INTO altPreis
    FROM Artikel     WHERE anr = artnr;

    neuPreis := altPreis - nachlass;
    IF neuPreis < 0.5 * altPreis     THEN neuPreis := 0.5 * altPreis;   END IF;

    UPDATE Artikel
    SET  Preis = neuPreis, Netto = Netto * neuPreis / altPreis, Steuer = Steuer * neuPreis / altPreis
    WHERE Anr = artnr ;
EXCEPTION WHEN OTHERS THEN
    DBMS_OUTPUT.PUT_LINE ('Fehler beim Ausfuehren der Prozedur Rabatt');
END;
/
```

kein: DECLARE … (gemäß Norm)

speichert Attribut Preis in Variable altPreis

kein: SET var = … (gemäß Norm)

IF: normkonform!

Ausnahmebehandlung in Oracle
WHEN OTHERS: alle sonstigen Ausnahmen

Begrenzer in Oracle

gibt Zeile aus

Prozedur RABATT in SQL Server

Keine Klammern!

```
CREATE PROCEDURE Rabatt @artnr INT, @nachlass NUMERIC(8,2) AS
DECLARE @altPreis NUMERIC(8,2), @neuPreis NUMERIC(8,2);
BEGIN TRY
    SELECT @altPreis = Preis
    FROM Artikel     WHERE anr = @artnr;

    SET @neuPreis := @altPreis - @nachlass;
    IF @neuPreis < 0.5 * @altPreis     SET @neuPreis := 0.5 * @altPreis;

    UPDATE Artikel
    SET Preis = @neuPreis, Netto = Netto * @neuPreis / @altPreis,
                                                    Steuer = Steuer * @neuPreis / @altPreis
    WHERE Anr = @artnr ;
END TRY
BEGIN CATCH
    SELECT 'Fehler beim Ausfuehren der Prozedur Rabatt';
END CATCH
GO
```

Variablen beginnen mit @

speichert Attribut Preis in Variable altPreis

IF: nicht normkonform!

TRY - CATCH

Begrenzer in SQL SERVER

Prozedur RABATT in MySQL

```
DELIMITER //

CREATE PROCEDURE Rabatt ( artnr INT , nachlass NUMERIC(8,2) )
BEGIN
    DECLARE   altPreis NUMERIC(8,2);
    DECLARE   neuPreis NUMERIC(8,2);

    SELECT Preis     INTO altPreis
    FROM Artikel     WHERE anr = artnr;

    SET neuPreis = altPreis - nachlass;
    IF neuPreis < 0.5 * altPreis    THEN SET neuPreis = 0.5 * altPreis;  END IF;

    UPDATE Artikel
    SET Preis = neuPreis, Netto = Netto * neuPreis / altPreis, Steuer = Steuer * neuPreis / altPreis
    WHERE Anr = artnr ;
END;
//
```

Definition eines Begrenzers

DECLARE-Teil

speichert Attribut Preis in Variable altPreis

normgemäß

Aufruf von Prozeduren

- Aufruf erfolgt in Oberfläche (Oracle, SQL Server)
- Aufruf erfolgt in Kommandozeile:
  - Oracle: `execute rabatt ( 100002, 50 )`
  - SQL Server: `execute rabatt 100002, 50`
  - MySQL `call rabatt ( 100002, 50 )`
- Damit wird Artikel 100002 um 50 Euro günstiger

Optimierung: Transaktionsbetrieb

- In MySQL
  - Abschalten von Autocommit
  - SET Autocommit = 0
    - oder
  - START TRANSACTION … COMMIT

Optimierung: bindParam

- Oft werden Befehle mit modifizierten Parametern mehrfach aufgerufen
- Dann: Arbeiten mit bindParam (prepare + execute, statt query)

```
$sql = "Select Auftrnr, Artnr, Anzahl, Gesamtpreis
        From Auftragsposten  Where Auftrnr = ?" ;
$stmt = $conn->prepare($sql);

$stmt->bindParam( 1, 1 ) ;
$stmt->execute( ) ;
$stmt->bindParam( 1, 2 ) ;
$stmt->execute( ) ;
$stmt->bindParam( 1, 4 ) ;
$stmt->execute( ) ;
```

variabel

Nur einmal geparst und aufbereitet!

Ersetzt 1. Fragezeichen durch den Wert 1

Ersetzt 1. Fragezeichen durch den Wert 2

Ersetzt 1. Fragezeichen durch den Wert 4

Mehrfach ausgeführt

Zusammenfassung

- Eine Datenbank führt selbst Optimierungen durch
- Eine Datenbank stellt viele Werkzeuge zur Optimierung zur Verfügung:
  - Indexe
  - Partitionierungen
  - Materialisierte Sichten
  - Stored Procedures
- Der Anwender und der Systemverwalter setzen diese Werkzeuge gezielt ein
- Der Anwender optimiert zusätzlich