# Datenbanksysteme II
# Optimierung
(Kapitel 16)

19.6.2008

Felix Naumann

# Wdh: Anfragebearbeitung – Grundproblem

Hasso Plattner Institut



- Anfragen sind deklarativ.
  - SQL, Relationale Algebra
- Anfragen müssen in ausführbare (prozedurale) Form transformiert werden.
- Ziele
  - „QEP" – prozeduraler Query Execution Plan
  - Effizienz
    - Schnell
    - Wenig Ressourcenverbrauch (CPU, I/O, RAM, Bandbreite)

# Wdh: Ablauf der Anfragebearbeitung



1. Parsing
   - Parsen der Anfrage (Syntax)
   - Überprüfen der Elemente („Semantik")
   - Parsebaum
2. Wahl des logischen Anfrageplans
   - Baum mit logischen Operatoren
   - Potentiell exponentiell viele
   - Wahl des optimalen Plans
     - Logische Optimierung
     - Regelbasierter Optimierer
     - Kostenbasierter Optimierer
3. Wahl des physischen Anfrageplans
   - Ausführbar
   - Programm mit physischen Operatoren
     - Algorithmen
     - Scan Operatoren
   - Wahl des optimalen Plans
     - physische Optimierung

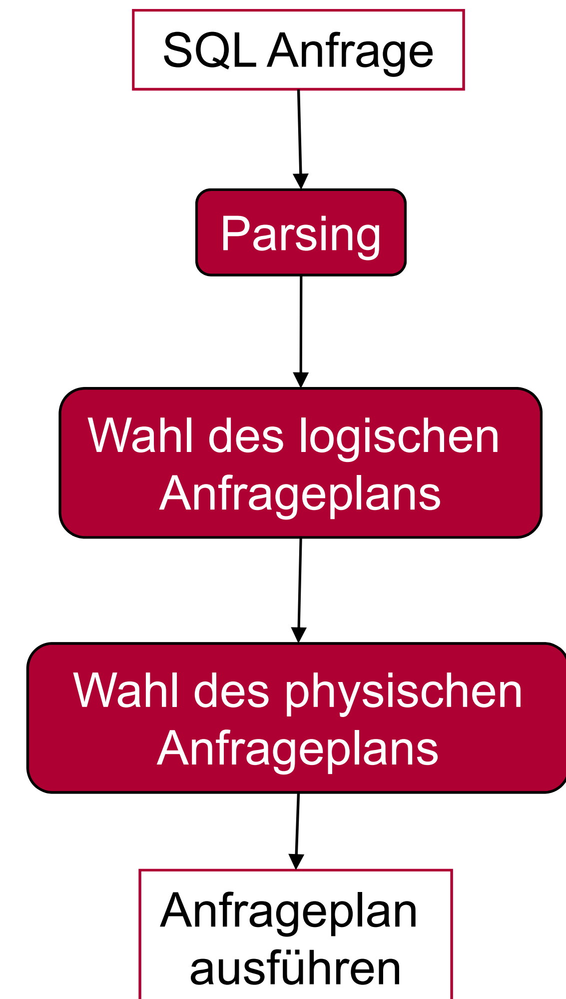

# Überblick

Hasso Plattner Institut

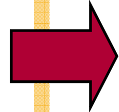

- (Parsing)
- (Algebraische Transformationsregeln)
- (Logische Anfragepläne)
- Kostenmodell
- Kostenbasierte Optimierung
- Joinreihenfolge
  - Dynamische Programmierung
- Physische Anfragepläne

# Ablauf der Anfragebearbeitung



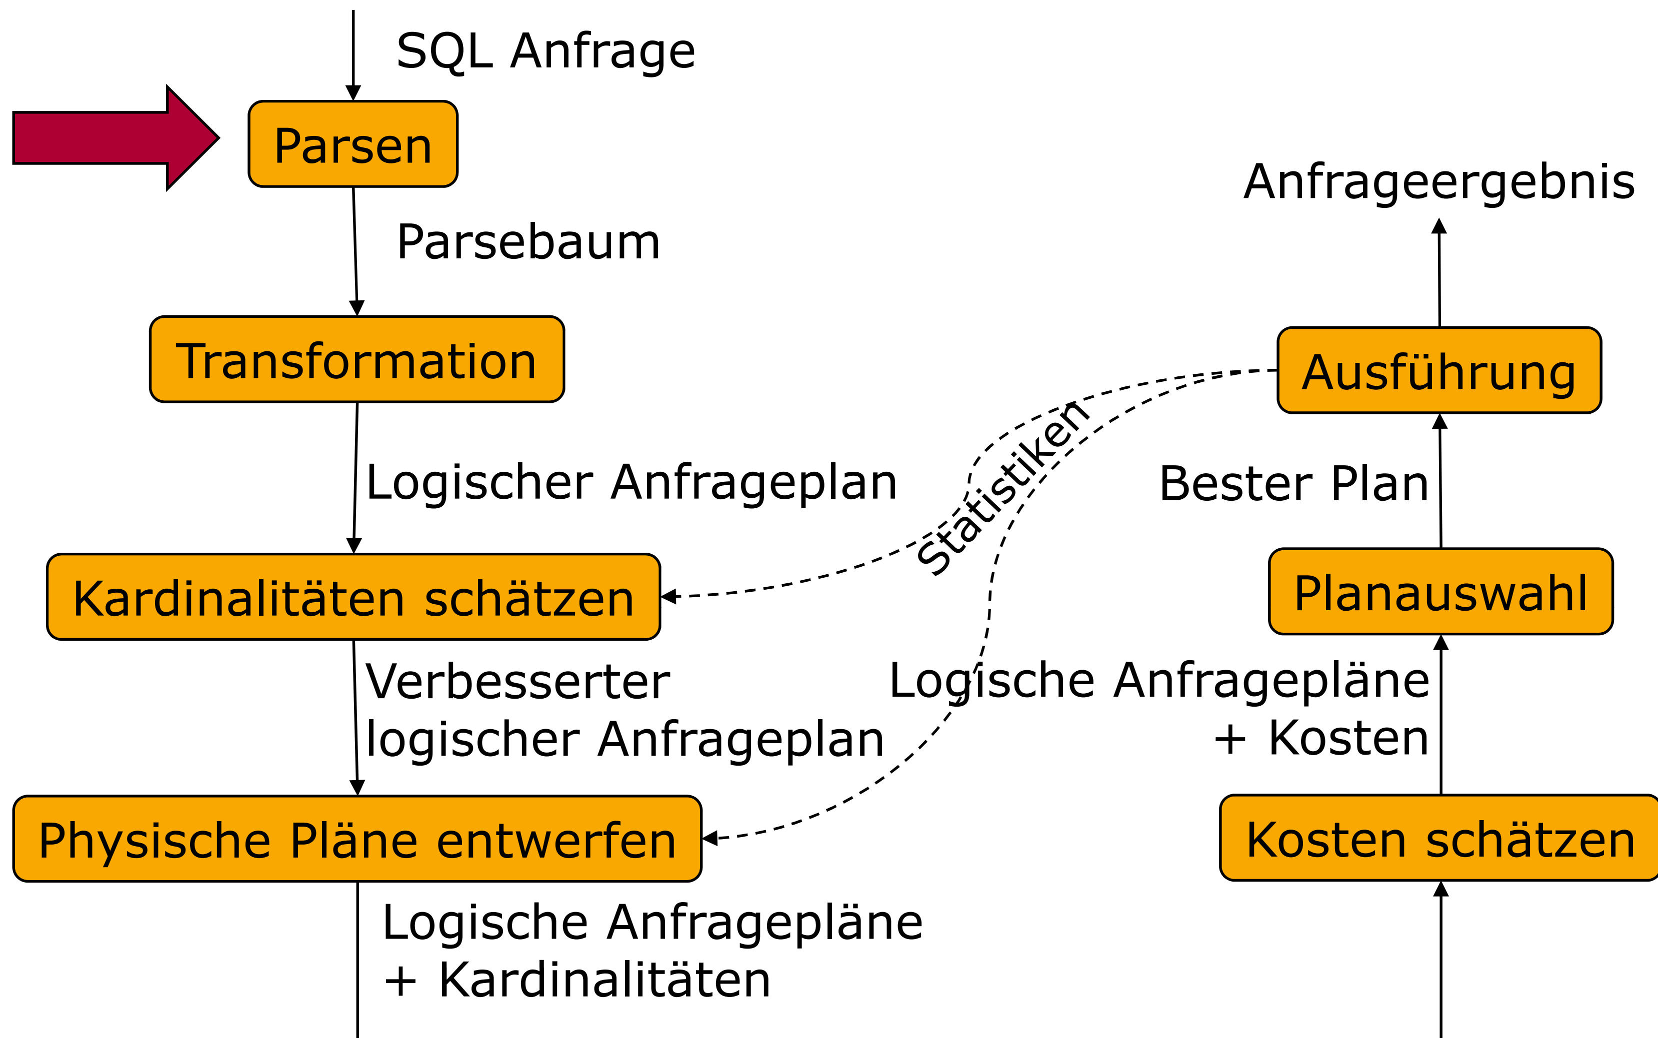

# Eine Grammatik für einen Teil von SQL



- Anfragen
  - **<Anfrage> :: = <SFW>**
  - **<Anfrage> :: = ( <SFW> )**
  - Mengenoperatoren fehlen
- SFWs
  - **<SFW> ::= SELECT <SelListe> FROM <FromListe> WHERE <Bedingung>**
  - Gruppierung, Sortierung etc. fehlen
- Listen
  - **<SelListe> ::= <Attribut>, <SelListe>**
  - **<SelListe> ::= <Attribut>**
  - **<FromListe> ::= <Relation>, <FromListe>**
  - **<FromListe> ::= <Relation>**
- Bedingungen (Beispiele)
  - **<Bedingung> ::= <Bedingung> AND <Bedingung>**
  - **<Bedingung> ::= <Tupel> IN <Anfrage>**
  - **<Bedingung> ::= <Attribut> = <Attribut>**
  - **<Bedingung> ::= <Attribut> LIKE <Muster>**
- **<Tupel>, <Attribut>, <Relation>, <Muster>** nicht durch grammatische Regel definiert
- Vollständig z.B. hier: http://docs.openlinksw.com/virtuoso/GRAMMAR.html

# Prüfung der Semantik

Hasso Plattner Institut



- Während der Übersetzung semantische Korrektheit prüfen
  - Existieren die Relationen und Sichten der FROM Klausel?
  - Existieren die Attribute in den genannten Relationen?
    - Sind sie eindeutig?
  - Korrekte Typen für Vergleiche?
  - Aggregation korrekt?
  - ...

# Überblick

HPI Hasso Plattner Institut

- (Parsing)
- (Algebraische Transformationsregeln)
- (Logische Anfragepläne)
- Kostenmodell
- Kostenbasierte Optimierung
- Joinreihenfolge
  - Dynamische Programmierung
- Physische Anfragepläne

# Ablauf der Anfragebearbeitung



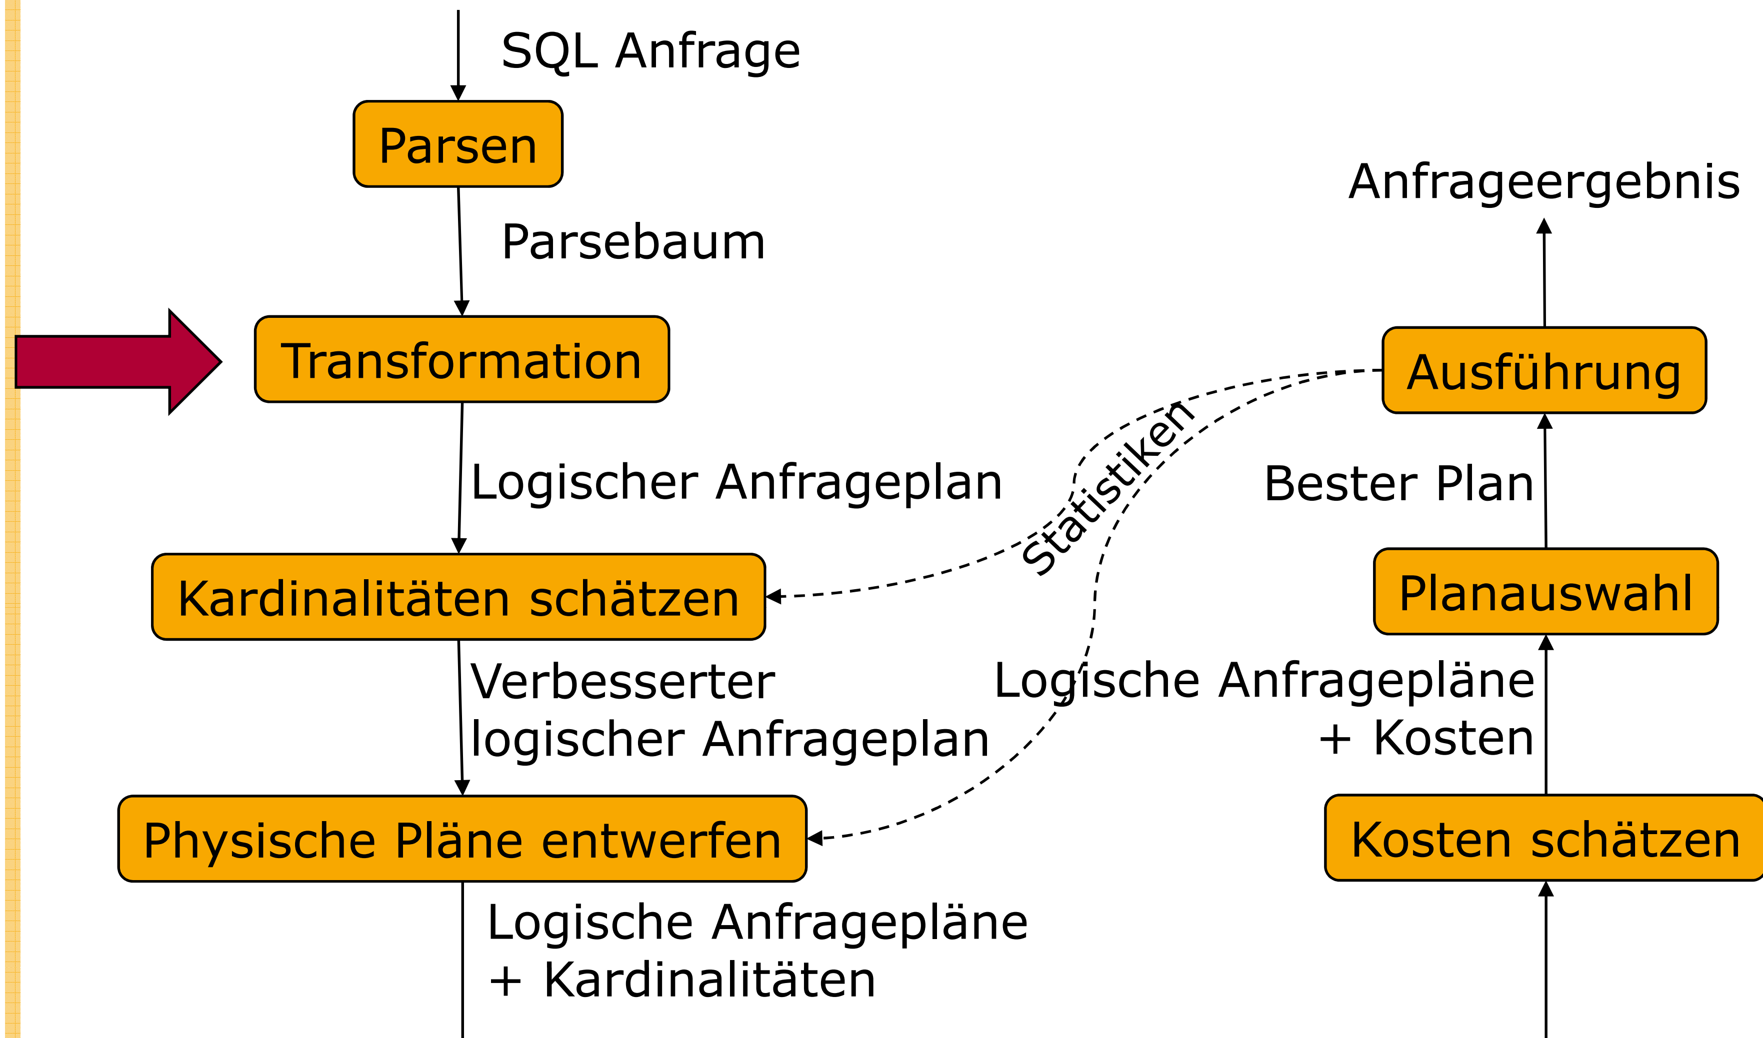

# Anfragebearbeitung – Transformationsregeln



- Transformation der internen Darstellung
  - Ohne Semantik zu verändern
  - Zur effizienteren Ausführung
    - Insbesondere: Kleine Zwischenergebnisse
- Äquivalente Ausdrücke
  - Zwei Ausdrücke der relationalen Algebra heißen äquivalent, falls
    - Gleiche Operanden (= Relationen)
    - Stets gleiche Antwortrelation
      - Stets?

Stets = Für jede mögliche Instanz der Datenbank

# Kommutativität und Assoziativität



- $\times$ ist kommutativ und assoziativ
  - $R \times S = S \times R$
  - $(R \times S) \times T = R \times (S \times T)$
- $\cup$ ist kommutativ und assoziativ
  - $R \cup S = S \cup R$
  - $(R \cup S) \cup T = R \cup (S \cup T)$
- $\cap$ ist kommutativ und assoziativ
  - $R \cap S = S \cap R$
  - $(R \cap S) \cap T = R \cap (S \cap T)$
- $\bowtie$ ist kommutativ und assoziativ
  - $R \bowtie S = S \bowtie R$
  - $(R \bowtie S) \bowtie T = R \bowtie (S \bowtie T)$

Gilt jeweils für Mengen und Multimengen

Ausdrücke können in beide Richtungen verwendet werden.

# Weitere Regeln



## Selektion

- $\sigma_{c1 \text{ AND } c2}(R) = \sigma_{c1}(\sigma_{c2}(R))$
- $\sigma_{c1 \text{ OR } c2}(R) = \sigma_{c1}(R) \cup \sigma_{c2}(R)$
  - Nicht bei Multimengen
- $\sigma_{c1}(\sigma_{c2}(R)) = \sigma_{c2}(\sigma_{c1}(R))$
- $\sigma_{c}(R \,\Phi\, S) \equiv (\sigma_{c}(R)) \,\Phi\, (\sigma_{c}(S))$
  - $\Phi \in \{\cup, \cap, -, \bowtie\}$
- $\sigma_{c}(R \bowtie S) \equiv (\sigma_{c}(R)) \bowtie S$

## Projektion

- $\pi_L(R \bowtie S) = \pi_L(\pi_M(R) \bowtie \pi_N(S))$
- $\pi_L(R \times S) = \pi_L(\pi_M(R) \times \pi_N(S))$
- $\pi_L\sigma_C(R)) = \pi_L(\sigma_C(\pi_M(R)))$

# Überblick



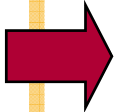

- (Parsing)
- (Algebraische Transformationsregeln)
- (Logische Anfragepläne)
- Kostenmodell
- Kostenbasierte Optimierung
- Joinreihenfolge
  - Dynamische Programmierung
- Physische Anfragepläne

# Ablauf der Anfragebearbeitung



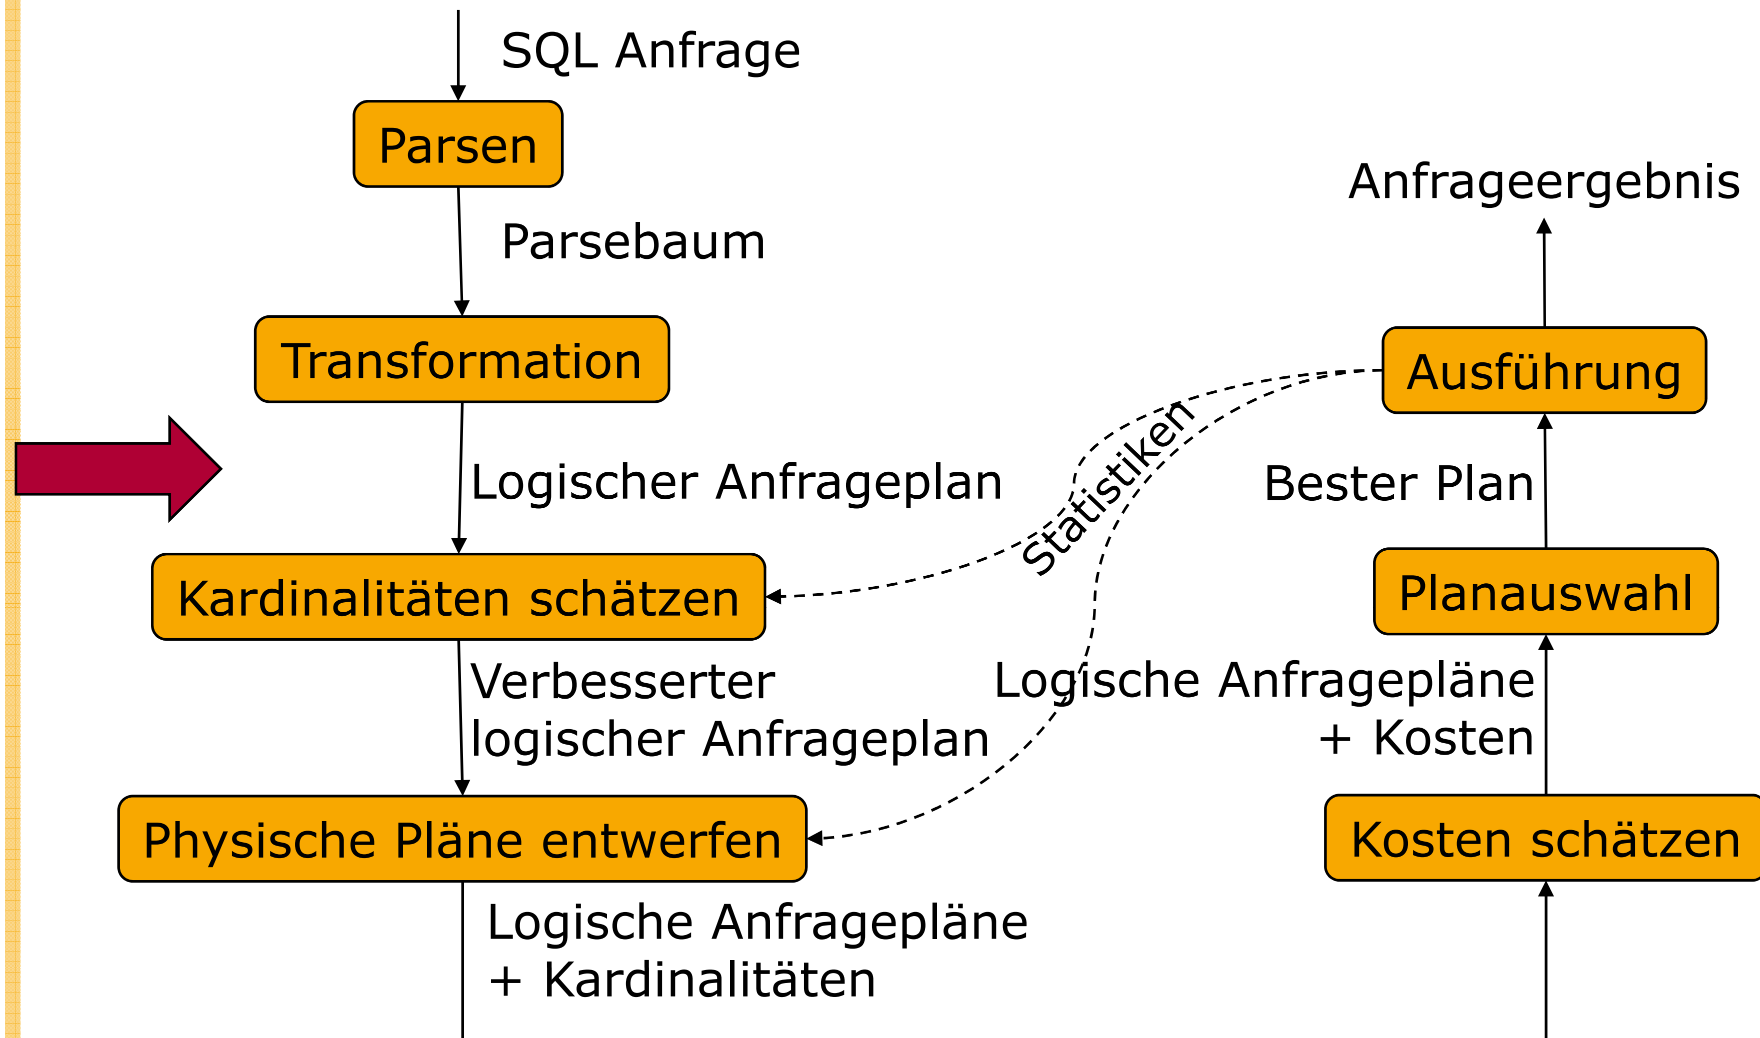

# Zwei Schritte



- Schritt 1
  - Parsebaum in Ausdruck der relationalen Algebra übersetzen
  - Darstellung als Baum
  - U.a.: Subanfrage auflösen (nicht hier)
- Schritt 2
  - Umformung des Baums gemäß Transformationregeln
  - „Voroptimierung" (Heuristiken)
    - Selektionen pushen
    - Projektionen pushen (und einbauen)
    - Duplikateliminierung verschieben
    - Selektion + Kreuzprodukt = Join
    - Gruppierung von Vereinigung und Joinoperatoren

# Anfragebearbeitung – Beispiel



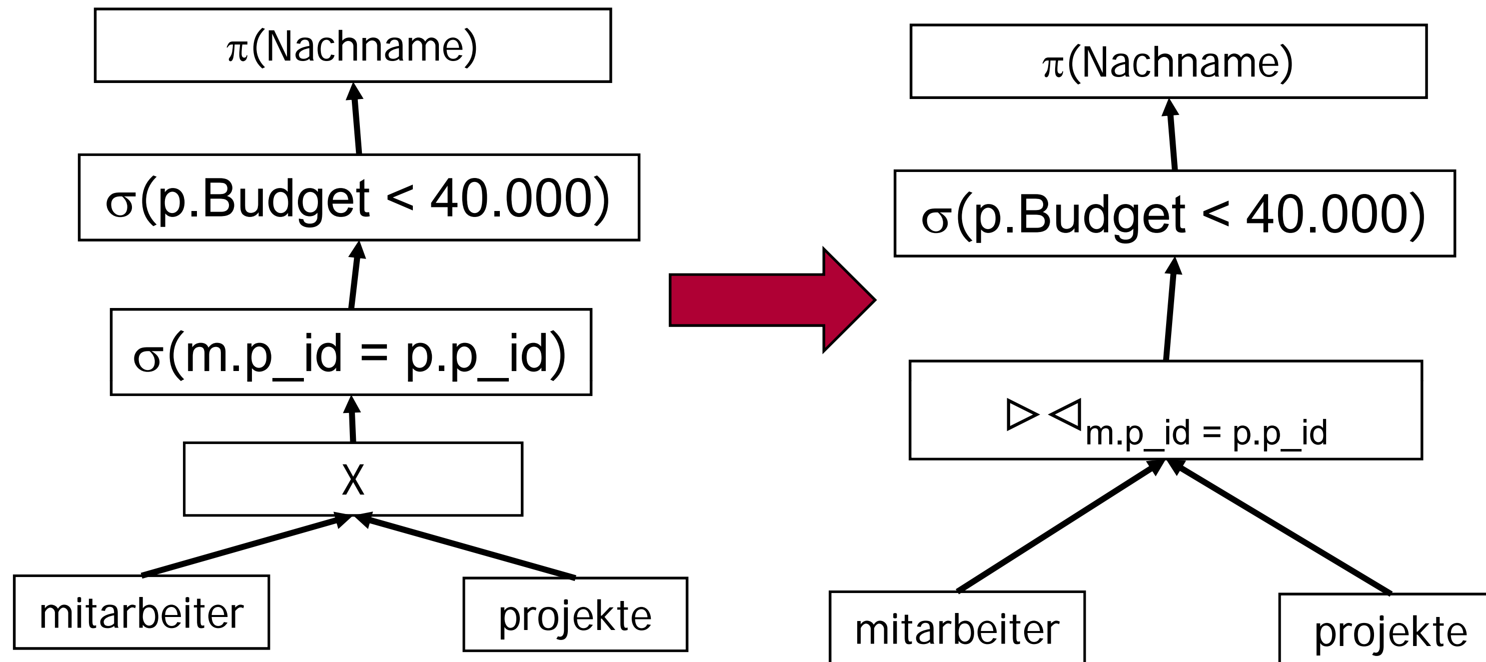

# Anfragebearbeitung – Beispiel



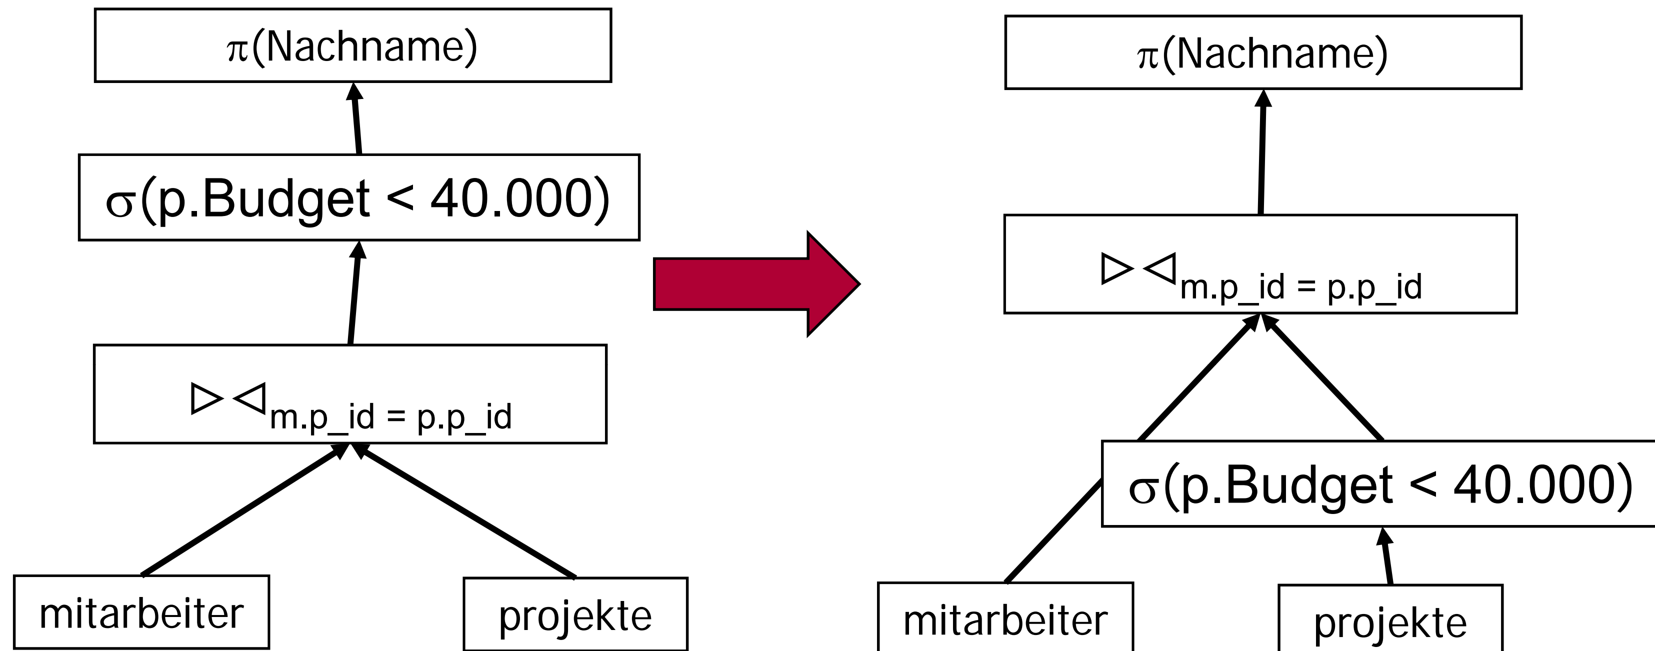

# Übergang zum Physischen Anfrageplan

Hasso Plattner Institut



Diverse Freiheitsgrade

1. Reihenfolge und Gruppierung von assoziativen und kommutativen Operatoren
   - Joins, Vereinigung, Schnittmenge
2. Wahl eines Algorithmus für jeden Operator
   - Siehe voriger Foliensatz
3. Zusätzliche Operatoren, die im logischen Plan nicht auftauchen
   - Scan, Sort
4. Modus des Datentransports zwischen Operatoren
   - Temporäre Tabelle, Pipeline mit Iterator

- Dafür zunächst: Kostenabschätzung

# Überblick



- (Parsing)
- (Algebraische Transformationsregeln)
- (Logische Anfragepläne)
- Kostenmodell
- Kostenbasierte Optimierung
- Joinreihenfolge
  - Dynamische Programmierung
- Physische Anfragepläne

# Ablauf der Anfragebearbeitung

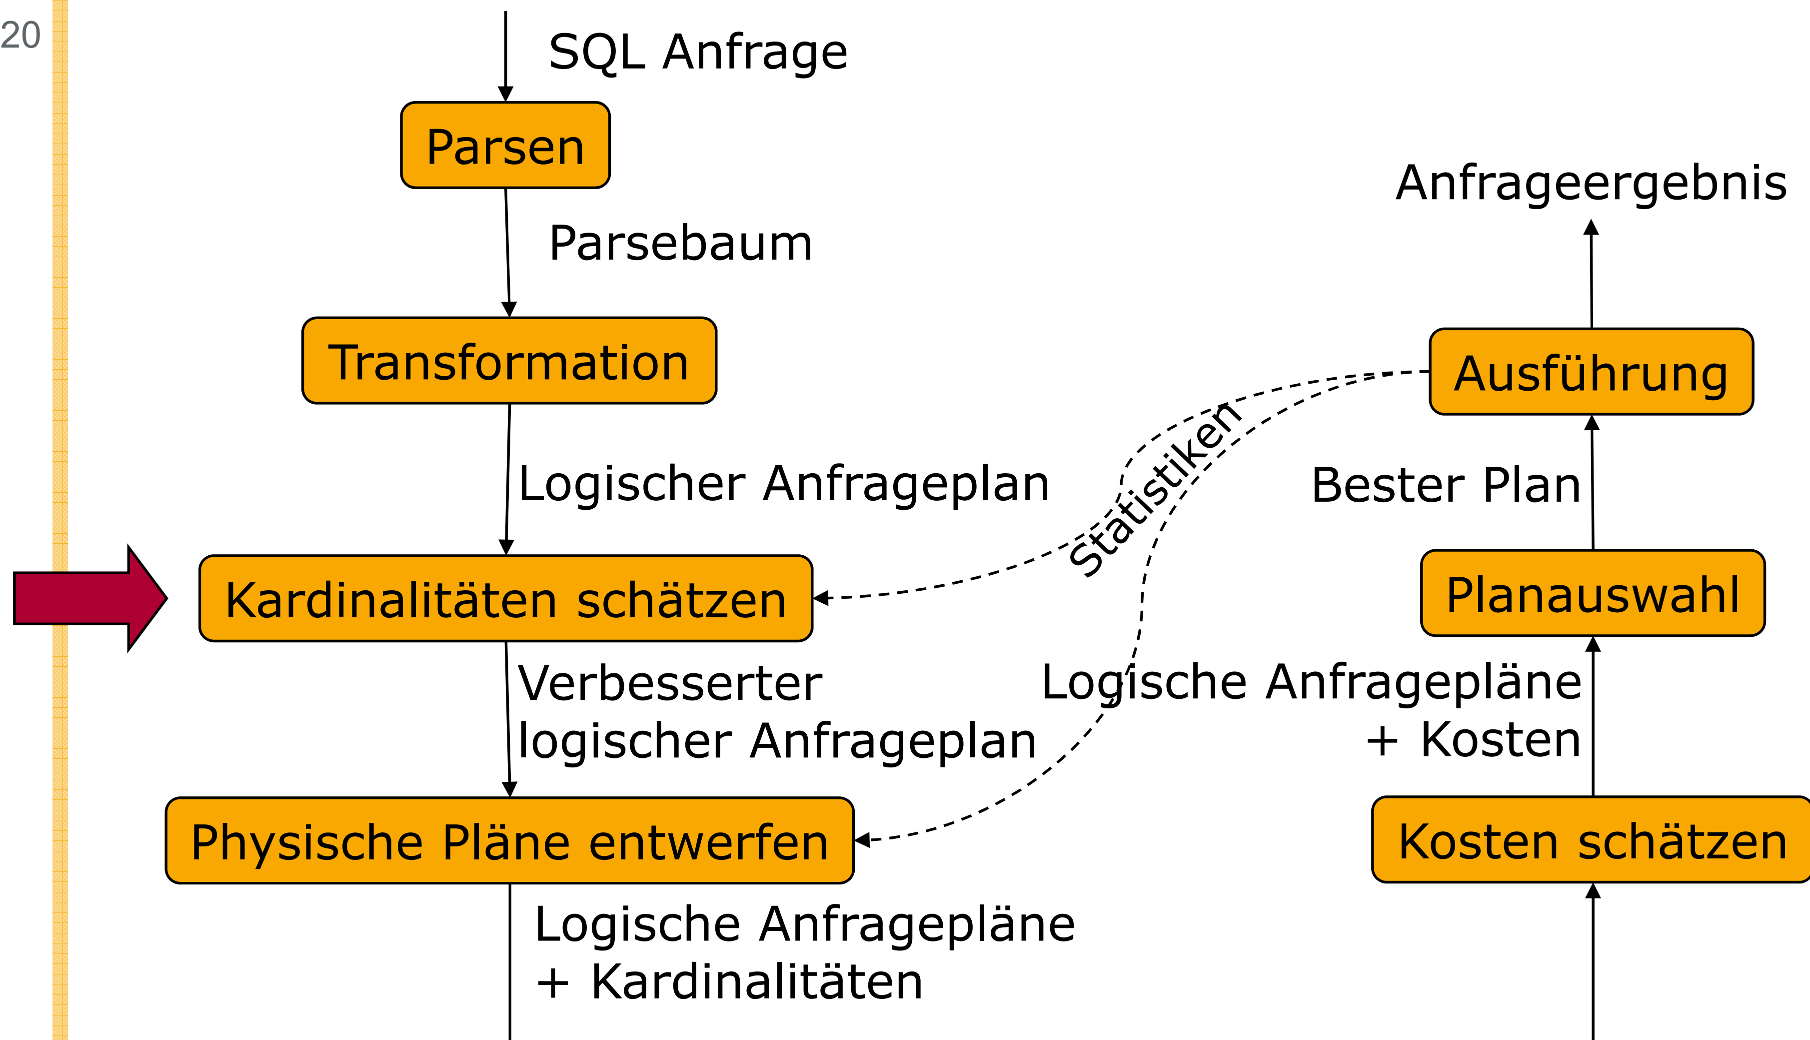

# Kostenbasierte Optimierung



- Konzeptionell: Generiere alle denkbaren Anfrageausführungspläne
- Bewerte deren Kosten anhand eines Kostenmodells
  - Statistiken und Histogramme
  - Kalibrierung gemäß verwendeter Rechner
  - Abhängig vom verfügbaren Speicher
  - Aufwands-Kostenmodell
    - Durchsatz-maximierend
    - Nicht Antwortzeit-minimierend
- Führe billigsten Plan aus

Achtung: Nicht zu lange optimieren!

# Problemgröße (Suchraum)



- Konzeptionell: Generiere alle denkbaren Anfrageausführungspläne
- Anzahl Bushy-Pläne mit n Tabellen

$$\frac{(2(n-1))!}{(n-1)!}$$

| $n$ | $2^n$ | $(2(n-1))!/(n-1)!$ |
|---|---|---|
| 2 | 4 | 2 |
| 5 | 32 | 1.680 |
| 10 | 1.024 | $1{,}76 * 10^{10}$ |
| 20 | 1.048.576 | $4{,}3 * 10^{27}$ |

- Plankosten unterscheiden sich um viele Größenordnungen.
- Optimierungsproblem ist NP-hart



*Folie: Prof. Alfons Kemper, TU München*

# Kostenmodell



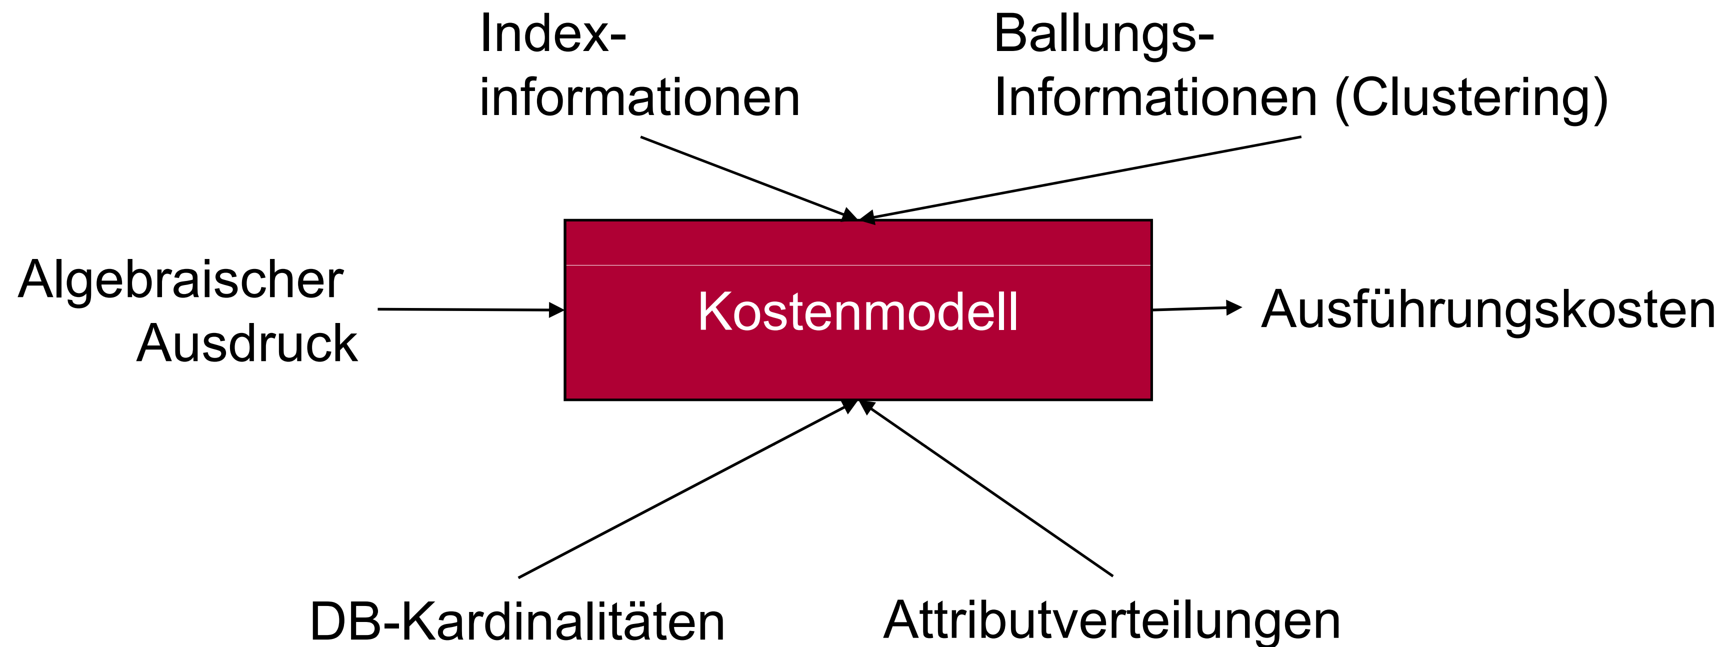


*Folie nach Prof. Alfons Kemper, TU München*

# Statistiken



- Zu jeder Basisrelation
  - Anzahl der Tupel
  - Tupelgröße
- Zu (jedem) Attribut
  - Min / Max
  - Werteverteilung (Histogramm)
  - Anzahl der distinct Werte
- Zum System
  - Speichergröße
  - Bandbreite
  - I/O Zeiten
  - CPU Zeiten
- Problem: Erstellung und Update der Statistiken
  - Deshalb meist nur explizit/manuell zu initiieren
  - **`runstats()`**

# Kosten von Operationen - Zwischenergebnisse

Hasso Plattner Institut



- Wesentliches Kostenmerkmal: Anzahl der Tupel im Input
  - Insbesondere: Passt die Relation in den Hauptspeicher?
  - Selektion, Projektion, Sortierung, Join
- Output ist Input des nächsten Operators.
- Deshalb: Ein Kostenmodel schätzt u.a. für jede Operation die Anzahl der Ausgabetupel.
  - „Selektivität" in Bezug auf Inputgröße
  - #Ausgabetupel = #Eingabetupel x Selektivität
  - Auch „Selektivitätsfaktor" (*selectivity factor, sf*)

# Kostenschätzung – Projektion



- Größe des Zwischenergebnisses kann exakt ausgerechnet werden
- Beispiele
  - Relation R(A integer(4), B integer(4), C varchar(100))
  - Tupelheader: 12 Byte
    - => 120 Byte pro Tupel
  - Block: 1024 Byte mit 24 Byte header
    - => 8 Tupel pro Block
  - T(R)= 10,000 => B(R) = 1250
  - S = $\pi_{A+B,C}$(R) => 116 Byte pro Tupel
    - => 8 Tupel pro Block: B(S) = 1250
  - T = $\pi_{A,B}$(R) => 20 Byte pro Tupel
    - => 50 Tupel pro Block und B(T) = 200

# Kostenschätzung – Selektion

Hasso Plattner Institut

- Anzahl Tupel sinkt, Tupelgröße bleibt
- $S = \sigma_{A=c}(R)$
  - $T(S) = T(R)/V(R,A)$
    - Reminder: $V(R,A)$ = Anzahl der *distinct* Werte in Attribut A
  - Annahme: Werte sind gleichverteilt
  - Annahme: *c* ist einer dieser Werte
  - Bessere Abschätzung mittels Histogramme
- $S = \sigma_{A<c}(R)$
  - Erste Abschätzung: $T(S) = T(R) / 2$
  - Typischer: $T(S) = T(R) / 3$
- $S = \sigma_{A \neq c}(R)$
  - Erste Abschätzung: $T(S) = T(R)$
  - Etwas genauer: $T(S) = T(R) \cdot (V(R,A) - 1) / V(R,A)$
- Bei Konjunktionen mehrerer Selektionsbedingungen: Multiplikation der Selektivitätsfaktoren
  - Annahme: Unabhängigkeit der Bedingungen

TABLE 1 SELECTIVITY FACTORS

```
column = value
          F = 1 / ICARD(column index) if there is an index on column
          This assumes an even distribution of tuples among the index key
          values.
          F = 1/10    otherwise

column1 = column2
          F = 1/MAX(ICARD(column1 index), ICARD(column2 index))
              if there are indexes on both column1 and column2
          This assumes that each key value in the index with the smaller
          cardinality has a matching value in the other index.
          F = 1/ICARD(column-i index) if there is only an index on column-i
          F = 1/10    otherwise

column > value (or any other open-ended comparison)
          F = (high key value - value) / (high key value - low key value)
          Linear interpolation of the value within the range of key values
          yields F if the column is an arithmetic type and value is known at
          access path selection time.
          F = 1/3 otherwise (i.e. column not arithmetic)
          There is no significance to this number, other than the fact that
          it is less selective than the guesses for equal predicates for
          which there are no indexes, and that it is less than 1/2.  We
          hypothesize that few queries use predicates that are satisfied by
          more than half the tuples.

column BETWEEN value1 AND value2
          F = (value2 - value1) / (high key value - low key value)

          A ratio of the BETWEEN value range to the entire key value range is
          used as the selectivity factor if column is arithmetic and both
          value1 and value2 are known at access path selection.
          F = 1/4 otherwise
          Again there is no significance to this choice except that it is
          between the default selectivity factors for an equal predicate and
          a range predicate.
```

Aus: Selinger et al. 1979

# Zipf-Verteilung

- Modelliert Worthäufigkeiten in Texten einer Sprache
  - Linguistik
- Sortierung nach Häufigkeit
  - *h* sei Häufigkeit des häufigsten Wertes
- *i*-ter Wert taucht $h/i^{1/2}$ mal auf
  - Frage: Wie sieht Kurve aus?
- Frage: Wie sollte Kardinalitätschätzung angepasst werden?
- Antwort: Gar nicht! Warum?
  - Durchschnittliche Antwort-kardinalität ist weiter T(R)/V(R,A)
  - Annahme: Konstanten werden gleichverteilt gewählt
  - Bei Zipf-Verteilung der Konstanten: Unterschätzung!

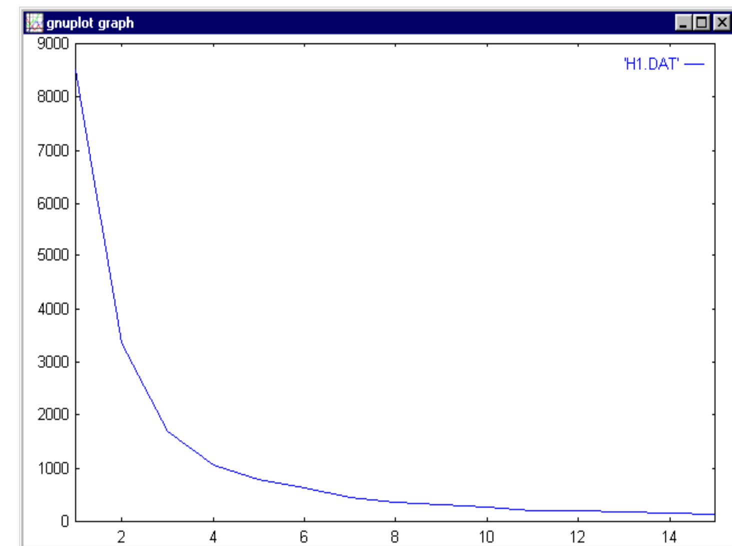

# Kostenschätzung – Selektion



Beispiel

- $S = \sigma_{A=10 \text{ AND } B < 20}(R)$
- T(R) = 10.000 und V(R,A) = 50
- => $T(S) = 10.000 \cdot 1/50 \cdot 1/3 = 67$

- $S = \sigma_{A=10 \text{ AND } A > 20}(R)$
  - => $T(S) = 10.000 \cdot 1/50 \cdot 1/3 = 67$ ?
  - Besser: T(S) = 0
  - Optimierer sollte solche Fälle erkennen

# Kostenschätzung – Selektion mit Disjunktion

Hasso Plattner Institut



- $S = \sigma_{C1\ OR\ C2}(R)$
- Idee 1: Summe der Ergebniskardinalitäten
  - Annahme: Kein Tupel erfüllt beide Bedingungen
  - Problem: T(S) > T(R)
- Idee 2: MIN[R, Summe der Ergebniskardinalitäten]
- Idee 3: Wahrscheinlichkeitstheorie
  - Annahme: C1 und C2 sind unabhängig
  - $T(R) = n$ und $T(\sigma_{C1}(R)) = m_1$ und $T(\sigma_{C2}(R)) = m_2$
  - => $T(S) = n(1-(1-\frac{m_1}{n})(1-\frac{m_2}{n}))$

Anteil Tupel, die nicht C1 entsprechen

Anteil Tupel, die nicht C2 entsprechen

# Kostenschätzung – Selektion mit Disjunktion

Hasso Plattner Institut



- Beispiel
  - $S = \sigma_{A=10 \text{ OR } B < 20}(R)$
  - $T(\sigma_{A=10}(R)) = T(R) / V(R,A) = 10.000 / 50 = 200$
  - $T(\sigma_{B < 20}(R)) = T(R) / 3 = 3.333$
  - Einfache Schätzung (Idee 1): T(S) = 200 + 3.333 = 3.533
  - Bessere Schätzung (Idee 3):

$$n(1-(1-\frac{m_1}{n})(1-\frac{m_2}{n})) = 10000(1-(1-\frac{200}{10000})(1-\frac{3333}{10000})) = 3466$$

# Kostenschätzung – Join



- Hier nur natural join
  - Equijoin analog
  - Thetajoin: „<", „>", usw: Wie zuvor: 1/3
- $R(X,Y) \bowtie S(Y,Z)$
  - Vereinfachende Annahme: Y ist nur <u>ein</u> Attribut.
- Problem: Beziehung zwischen R.Y und S.Y
  - Disjunkte Werte: $T(R \bowtie S) = 0$
  - Fremdschlüsselbeziehung (Schlüssel in S): $T(R \bowtie S) = T(R)$
  - Fast alles gleiche Werte: $T(R \bowtie S) = T(R) \cdot T(S)$
- Vereinfachende Annahmen
  - *Containment of Value Sets*: Werte eines Attributs, das in mehreren Relationen auftaucht, werden vom Beginn einer festen Liste gewählt.
    - Falls $V(R,Y) \leq V(S,Y)$ => Jeder Y-Wert in R taucht in S auf
    - Realistisch? Wann?
  - *Preservation of Value Sets*: Anzahl der distinct-Werte eines nicht-Joinattributs bleiben erhalten.
    - $V(R \bowtie S, X) = V(R, X)$
    - Realistisch? Wann?

# Kostenschätzung – Join



- Sei $V(R,Y) \leq V(S,Y)$
  - => Jedes Tupel aus R hat eine $1/V(S,Y)$ Chance, mit einem gegebenen S-Tupel zu joinen
  - => (da $T(S)$ S-Tupel): Ein Tupel aus R hat $T(S) \cdot 1/V(S,Y)$ Joinpartner in S
  - => (da $T(R)$ R-Tupel): $T(R \bowtie S) = T(R) \cdot T(S) / V(S,Y)$
- Falls $V(R,Y) \geq V(S,Y)$: $T(R \bowtie S) = T(R) \cdot T(S) / V(R,Y)$
- Allgemein: $T(R \bowtie S) = T(R) \cdot T(S) / \max[V(R,Y),V(S,Y)]$

# Kostenschätzung – Join



Beispiel

- $R(A,B) \bowtie S(B,C) \bowtie U(C,D)$
- $T(R) = 1.000; T(S) = 2.000; T(U) = 5.000$
- $V(R,B) = 20; V(S,B)= 50; V(S,C) = 100; V(U,C)=500$
- Betrachtung: $(R \bowtie S) \bowtie U$
- $T(R \bowtie S) = T(R) \cdot T(S) / \max[V(R,B),V(S,B)] = 1.000 \cdot 2.000/50 = 40.000$
- $T(R \bowtie S \bowtie U) = T(R \bowtie S) \cdot T(U) / \max[V(R \bowtie S,C),V(U,C)] = 40.000 \cdot 5.000/\max[100,500] = 400.000$
  - Warum $V(R \bowtie S, C) = 100$?
  - Preservation of Value Sets: $V(R \bowtie S,C) = V(S,C)$
    - C ist nicht-Joinattribut
- Probe: $T(R \bowtie (S \bowtie U)) = 400.000$
  - Zu Hause

# Kostenschätzung – Join

Hasso Plattner Institut

- $R(X,Y) \bowtie S(Y,Z)$
  - Y enthält mehr als ein Attribut
  - Schreibweise hier: $R(X,Y1, Y2) \bowtie S(Y1, Y2, Z)$
- $T(R \bowtie S) =$
  $T(R) \cdot T(S) / ( \max[V(R,Y1),V(S,Y1)] \cdot \max[V(R,Y2),V(S,Y2)] )$
- Allgemein
  - Ergebniskardinalität von $R \bowtie S$ entspricht dem Produkt der Kardinalitäten von R und S, dividiert durch das größere von V(R,Y) und V(S,Y) für jedes Attribut.

# Kostenschätzung – Mehrfacher Join

Hasso Plattner Institut

- Allgemeiner Fall: $S = R_1 \bowtie R_2 \bowtie \dots \bowtie R_n$
- Notation: $V(R_i, A) = v_i$
- Attribut A erscheine in k Relationen.
- Es gelte $v_1 \leq v_2 \leq \dots \leq v_k$.
- Gegeben: 1 Tupel aus jeder Relation
- Gesucht: Wahrscheinlichkeit, dass alle im A-Wert übereinstimmen
  - Containment of Value Sets: Jeder A-Wert von Tupeln aus $R_1$ taucht in den anderen Relationen auf.
  - Ein Tupel aus $R_i$ hat Wahrscheinlichkeit $1/v_i$ mit gegebenen Tupel aus $R_1$ übereinzustimmen.
  - Zusammen: $1/v_2v_3 \dots v_k$
- Gesamtvorgehen: Ausgangspunkt ist Produkt aller Kardinalitäten
  - Selektivität: Für jedes Attribut, das mehr als einmal auftaucht: Dividiere durch Produkt aller $v_i$ bis auf das kleinste.

# Kostenschätzung – Mehrfacher Join

HPI Hasso Plattner Institut

Beispielanfrage

- R(A,B,C) ⋈ S(B,C,D) ⋈ U(B,E)
- Kardinalitäten: T(R) = 1000; T(S) = 2000; T(U) = 5000
- DISTINCT Werte:
  - V(R,B): 20; V(R,C): 200; V(S,B): 50; V(S,C): 100; V(U,B): 200

Vorgehen

- Zunächst alle Kombinationen aufzählen
  - 1000 x 2000 x 5000 = 10.000.000.000
- Nun mit Wahrscheinlichkeiten für gemeinsame Attribute multiplizieren
  - Gemeinsame Attribute: B dreimal, C zweimal
  - Für B: 1/50 x 1/200
  - Für C: 1/200
  - Also: 10.000.000.000 / (50 x 200 x 200) = 10.000.000.000 / 2.000.000 = 5.000

# Kostenschätzung – Weitere Operationen



- Vereinigung ($R \cup S$)
  - Multimenge: Summe der Inputs
  - Menge: $\max[T(R), T(S)] \leq T(R \cup S) \leq T(R) + T(S)$
    - Z.B: $AVG[T(R) + T(S), \max[T(R), T(S)]]$
- Schnittmenge ($R \cap S$)
  - $0 \leq T(R \cap S) \leq \min[T(R), T(S)]$
  - Idee 1: $\min[T(R), T(S)]/2$
  - Idee 2: Als extremen Join auffassen
- Differenz
  - $T(R) - T(S) \leq T(R - S) \leq T(R)$
  - Z.B.: $T(R) - T(S)/2$

# Kostenschätzung – Weitere Operationen



- Duplikateliminierung
  - $1 \leq \delta(R) \leq T(R)$
  - $\delta(R) \leq \prod_i V(R, A_i)$
  - Z.B.: $\delta(R) = \min[T(R)/2, \prod_i V(R, A_i)]$
- Gruppierung und Aggregation
  - $1 \leq \gamma_L(R) \leq T(R)$
  - Falls nur ein Gruppierungsattribut: $T(\gamma_L(R)) = V(R,L)$
  - $\gamma_L(R) \leq \prod_i V(R, L_i)$
  - Z.B.: $\gamma_L(R) = \min[T(R)/2, \prod_i V(R, L_i)]$

# Überblick



- (Parsing)
- (Algebraische Transformationsregeln)
- (Logische Anfragepläne)
- Kostenmodell
- Kostenbasierte Optimierung
- Joinreihenfolge
  - Dynamische Programmierung
- Physische Anfragepläne

# Ablauf der Anfragebearbeitung



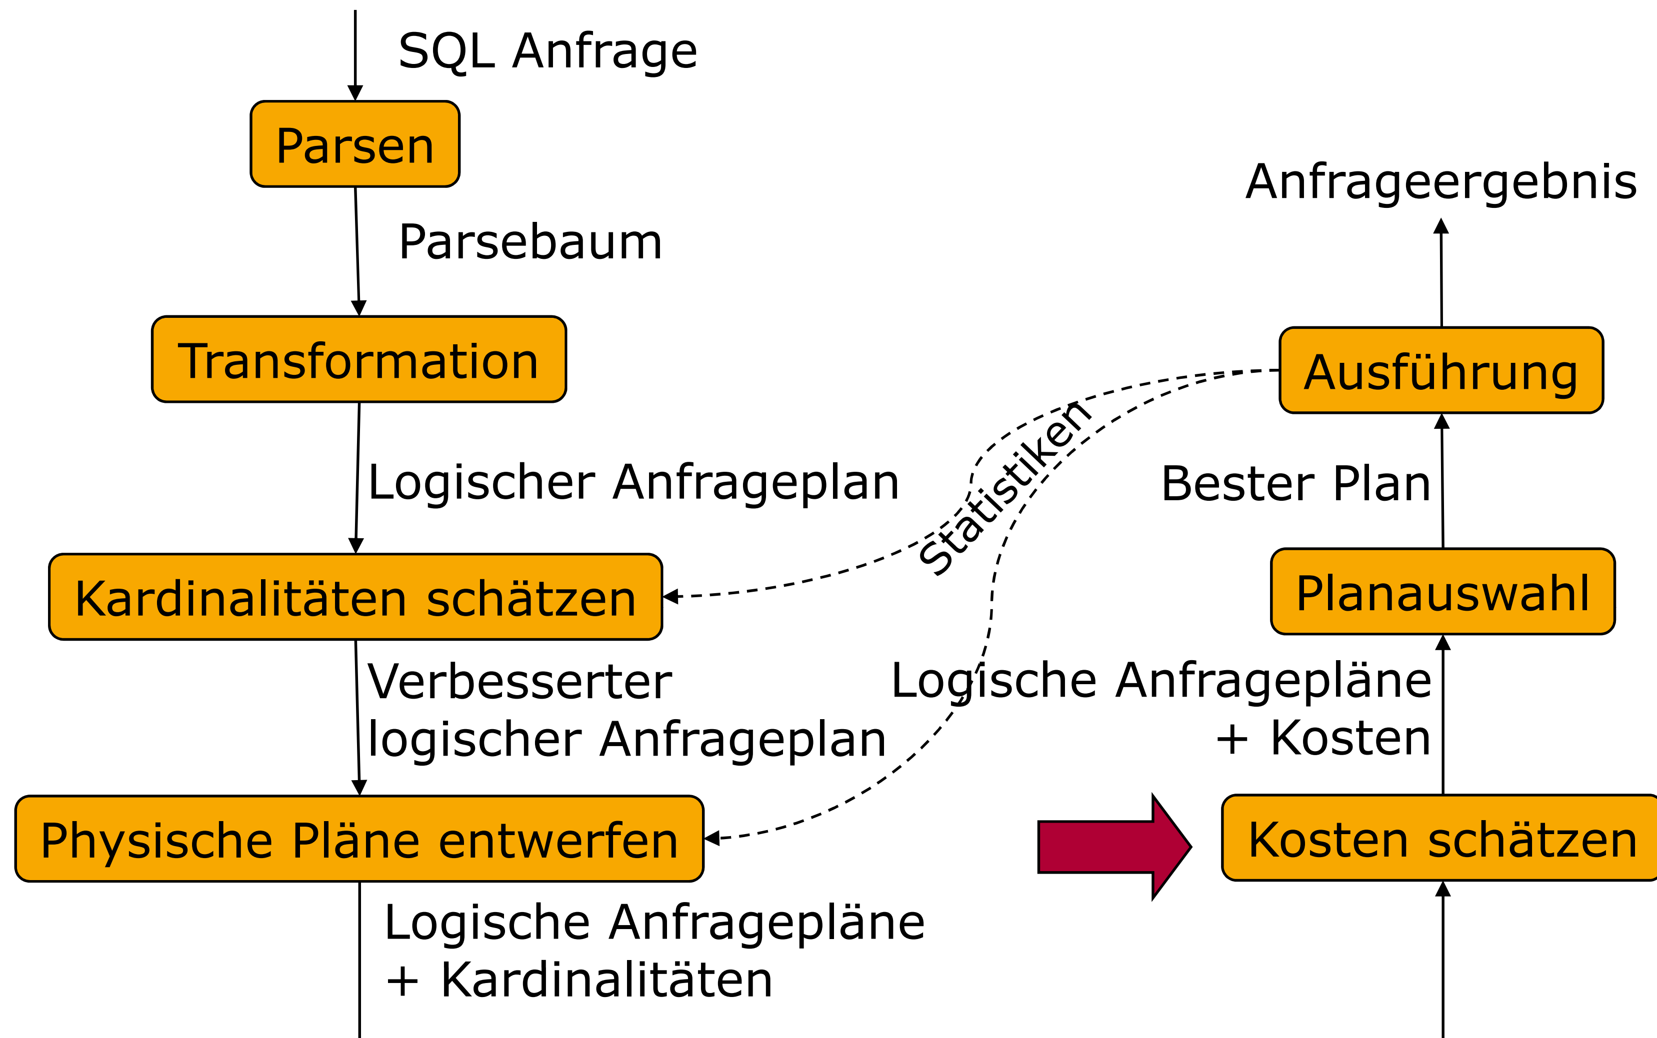

# Kosten eines Plans



Wie immer: I/O-Kosten

- Beeinflusst durch
  - Wahl der logischen Operatoren, um Anfrage umzusetzen
  - Größe der Zwischenergebnisse
  - Wahl der physischen Operatoren
  - Reihenfolge der Operatoren
    - Insbesondere Joinreihenfolge
  - Datentransport
    - Pipelining vs. blocking

# Schätzung der Statistiken

Hasso Plattner Institut

Statistiken sind notwendig, um die Größe von Zwischenergebnissen zu berechnen.

- Insbesondere T(R) und V(R,A)
- Einholen der Statistiken auf Befehl des Administrators
- T(R) mittels Scan von R
- V(R,A) mittels einer der vorigen Algorithmen
  - Ähnlich Gruppierung, separat für jedes Attribut
- B(R)
  - Zählen, falls R clustered
  - Berechnen (T(R) / Tupel pro Block) falls nicht clustered

# Schätzung der Statistiken – Histogramme



Histogramme stellen speichereffizient Werteverteilungen dar.

- Idee:
  - Fasse Gruppen von Werten (zusammenhängende Wertebereiche) in Buckets zusammen
    - Equal-width, Equal-height,
    - Idee: Speichere zusätzlich Häufigkeiten für häufigste Werte
  - Speichere pro Bucket die durchschnittliche Anzahl der Tupel pro Einzel-Wert.
    - D.h. man nimmt innerhalb des Buckets Gleichverteilung an.
- Vorteile
  - Geringere Schätzfehler, da Verteilungsannahmen nur in kleineren Bereichen
  - Geringer Speicherverbrauch durch Zusammenfassen in Gruppen
- Design und Wartung
  - Wie werden Bucketgrenzen bestimmt?
  - Was speichern wir pro Bucket?
  - Wie werden Histogramme aktuell gehalten?

# Verteilungen – Körpergewicht



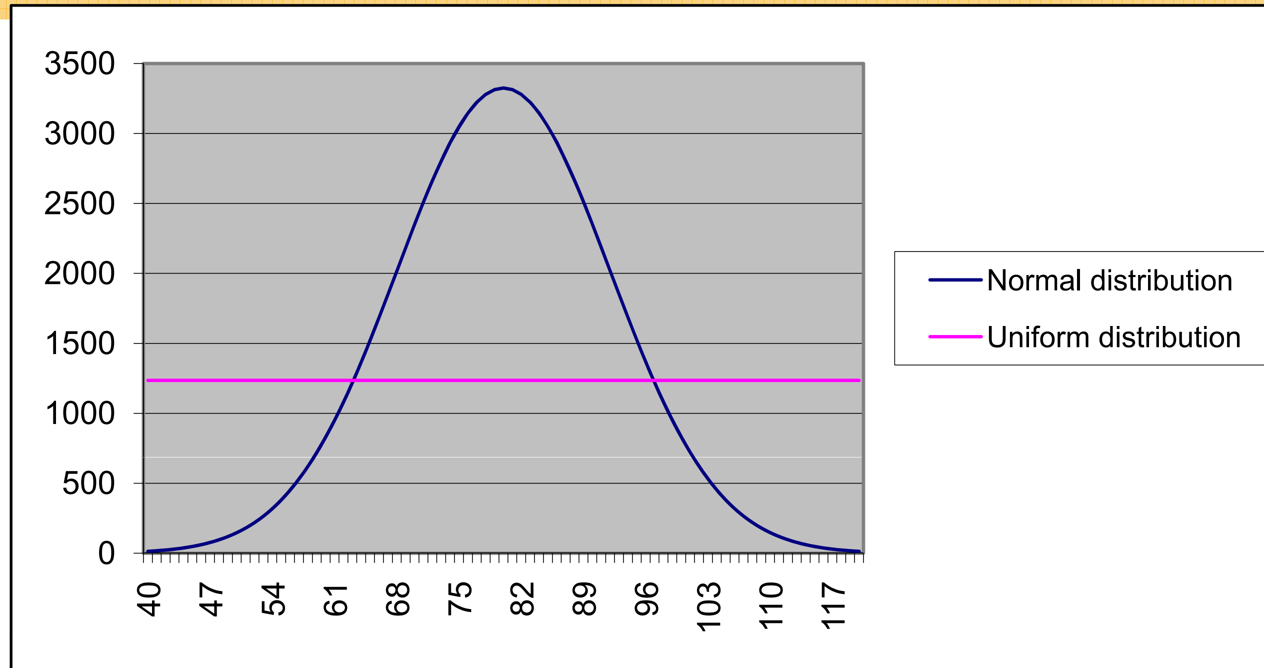


- Normalverteilung
  - Wertebereich: 120-40=80, Mittelwert: 80, stddev: 12; 100000 people
- Gleichverteilung
  - 100000/80=1250 people for each possible weight
  - In fast jedem Bereich fehleranfällig

# Equi-Width Histogramme

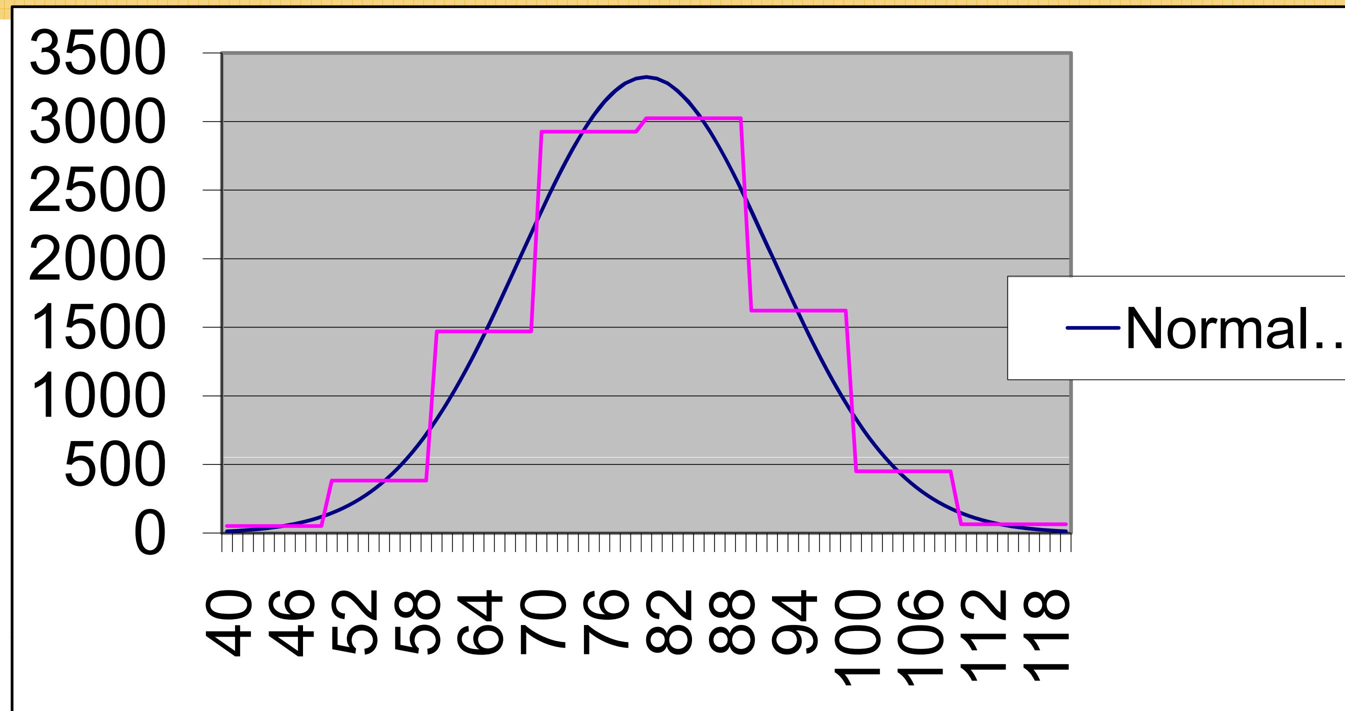


- Feste Anzahl Buckets, jeweils gleicher Breite
  - Vorteil: Grenzen müssen nicht mitgespeichert werden. Startpunkt und Breite genügen.
- Annahme: Gleichverteilung in jedem Bucket
- Berechnung mittels eines Scans von R
- Quellen für weitere Schätzfehler
  - Anzahl der Buckets
  - Werteverteilung innerhalb der Buckets

# Equi-height-Histogramme

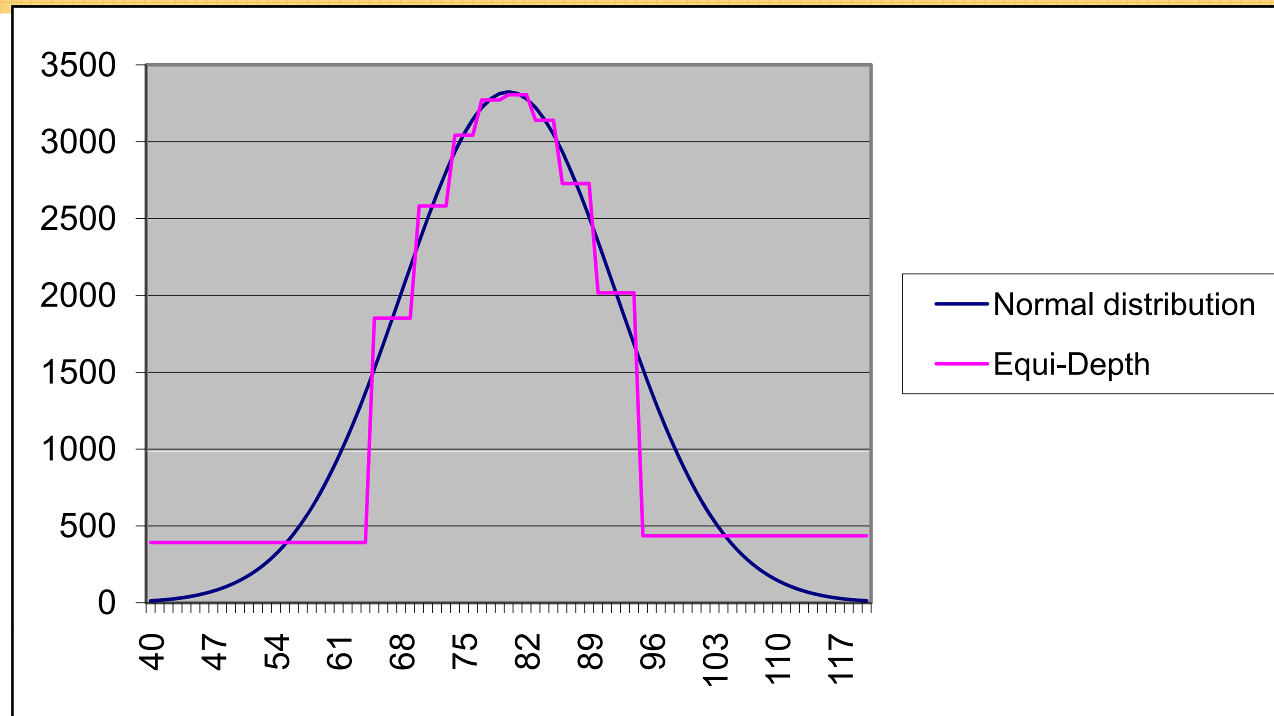


- Auch: Equal-depth-Histogramme bzw. Perzentile
- Feste Anzahl Buckets (z.B. 10 Stück für 10%, 20%, …)
- Wähle Bucketgrenzen so, dass jeder Bucket ungefähr gleiche Anzahl an Tupeln enthält
  - Hier: Ca. 10.000 Personen pro Bucket
  - Bucketgrenzen müssen gespeichert werden
  - Berechnung durch Sortierung und gleichgroße Sprünge.

# Histogramme zur Schätzung für Joins

Hasso Plattner Institut

- ```
  SELECT Januar.Tag, Juli.Tag
  FROM   Januar, Juli
  WHERE  Januar.temp =
                  Juli.temp
  ```
- Schätzung pro Wertebereich
  - Histo1·Histo2/Breite
- 10·5/10 + 5·20/10 = 5 + 10 = 15
- Herkömmliche Schätzung
  - Je 245 Tupel mit gleichverteilten Temperaturen
  - 245·245/100 = 600 Tupel

| Wertebereich Temperatur °F | Januar | Juli |
|---|---|---|
| 0-9 | 40 | 0 |
| 10-19 | 60 | 0 |
| 20-29 | 80 | 0 |
| 30-39 | 50 | 0 |
| 40-49 | 10 | 5 |
| 50-59 | 5 | 20 |
| 60-69 | 0 | 50 |
| 70-79 | 0 | 100 |
| 80-89 | 0 | 60 |
| 90-99 | 0 | 10 |
  ```

# Histogramme zur Schätzung für Joins



- Beispiel: R(A,B) ⋈ S(B,C)
- Histogramme listen jeweils die 3 häufigsten Werte und gruppieren den Rest.
  - Histogramm für R.B: 1: 200; 0:150; 5: 100; Rest: 550
  - Histogramm für S.B: 0: 100; 1: 80; 2: 70; Rest: 250
- V(R,B) = 14 und V(S,B) = 13
  - => Rest in R (550 Tupel) haben 11 verschiedene Werte
    - Annahme: je 50 Tupel
  - => Rest in S (250 Tupel) hat 10 verschiedene Werte
    - Annahme: je 25 Tupel
- Genaue Schätzung für B-Werte 0 und 1: 150·100 + 200·80=31000
- Schätzung: „2" kommt 50 mal in R vor => 50 · 70 = 3500
- Vermutung: „5" ist in R sehr häufig, kommt also vermutlich auch in S 25 mal vor: 100 · 25 = 2500
- 9 weitere Werte je in R und S: 9 · (50 · 25) = 11250

# Erhebung von Statistiken



Statistiken werden nur periodisch erhoben

- Statistiken ändern sich nicht laufend und radikal
- Auch falsche Statistiken funktionieren, wenn sie konsistent angewendet werden
- Statistiken sollen nicht selbst hot-spot werden.
  - Werden oft gelesen => Sollten nicht dauernd geändert werden
- Auslösung
  - Regelmäßig periodisch
  - Nach einer festen Menge an Updates
  - Durch den Administrator
- Berechnung der Statistiken ist aufwändig. Lösung: Sampling

# Enumeration Physischer Anfragepläne



- Idee 1: Vollständige Enumeration
  - Entlang aller Freiheitsgrade
    - Reihenfolge und Gruppierung von assoziativen und kommutativen Operatoren
    - Wahl eines Algorithmus für jeden Operator
    - Zusätzliche Operatoren, die im logischen Plan nicht auftauchen
    - Modus des Datentransports zwischen Operatoren
  - Jeweils Kostenberechnung
  - Wahl des Plan mit geringsten Kosten
  - Problem: Zu viele Pläne
- Es gibt diverse bessere Methoden
  - Heuristische Auswahl, Branch-and-Bound, Hill-Climbing, Dynamische Programmierung, Selinger-Style

## Heuristische Auswahl



- Idee: Wende eine Sequenz bekannter Heuristiken an
- Z.B. für Joinreihenfolge (Greedy)
  1. Wähle zuerst Joinpaar mit kleinstem Zwischenergebnis.
  2. Joine die Relation hinzu, die wiederum kleinstes Zwischenergebnis erzeugt.
  3. usw.
- Weitere Heuristiken
  - Falls Selektion und Index auf Selektionsattribut: Wähle Index-scan
  - Führe mehrere Selektionen auf gleicher Relation zugleich aus.
  - Falls Index auf Joinattribut, wähle Index-Join
  - Falls ein Joininput sortiert ist, wähle sort-merge-join (falls kein Index vorhanden)

# Branch and Bound & Hill-Climbing



- Branch and Bound
  - Idee: Verwende Heuristiken zum Finden eines guten Plans
    - Dessen Kosten bilden obere Schranke, auch für Teilpläne
    - Enumeriere Pläne für diverse Teile der Anfrage
      - Verwerfe Teilpläne, die mehr als Schranke kosten
    - Senke Schranke falls besserer Gesamtplan gefunden wird.
  - Vorteil: Optimierung kann jederzeit abgebrochen werden.
- Hill-Climbing
  - Idee: Verwende Heuristiken zum Finden eines guten Plans
  - Suche schrittweise ähnliche Pläne mit niedrigeren Kosten
    - Ähnlich: Nur eine Änderung
  - Falls kein ähnlicher Plan besser ist: Fertig
  - Nachteil: Lokales Optimum vs. Globales Optimum
  - Varianten zur Verbesserung:
    - Iterative Improvement: Mit 10 verschiedenen Startplänen loslegen
    - Simulated Annealing: Lasse auch Verschlechterungen zu

# Dynamische Programmierung & Selinger-style



- Dynamische Programmierung
  - Idee: Bottom-up Vorgehen im Baum
  - Suche jeweils besten Teilplan und verwende diese, um höheren Teilplan zu bauen.
- Selinger-style
  - Idee: Erweiterung der Dynamischen Programmierung
  - Merke nicht nur besten Plan sondern verschiedene Sortiervarianten (*interesting order*)
    - Dürfen mehr kosten, haben aber später Vorteile
  - Beeinflusst nicht Kardinalitäten von Zwischenergebnissen, aber beeinflusst I/O-Kosten

# Überblick



- (Parsing)
- (Algebraische Transformationsregeln)
- (Logische Anfragepläne)
- Kostenmodell
- Kostenbasierte Optimierung
- Joinreihenfolge
  - Dynamische Programmierung
  - Anwendung für Left-Deep Bäume
- Physische Anfragepläne

# Anfragebearbeitung – Optimierung

Hasso Plattner Institut

Freiheitsgrade:

- Algebraische Anfrageumformung
- Joinreihenfolge
- Joinmethode
  - Nested Loop, Sort-Merge, Hash ...
- Indexzugriff oder Full-Table-Scan
- Operatorreihenfolge
- ...

# Anfragebearbeitung – Optimierung



Joinreihenfolge

- Wichtig hier: nur Joinreihenfolge, nicht Parallelität!
- Join ist i.d.R. teuerster Operator.
- Optimierung konzentriert sich auf beste Reihenfolge.
  - Weitere Optimierungsschritte (Selektionen nach unten, etc.) später
- Bei n Relationen n! Alternativen
  - Aber: Die meisten Alternativen haben kartesisches Produkt.
- Viele Algorithmen
  - Dynamische Programmierung
- Bei mehr-Prozessor Systemen nicht nur Reihenfolge sondern auch Parallelisierung.

# Richard Bellman



- 1920 – 1984
- PhD Princeton (3 Monate)
- Los Alamos (1944-1946)
- 1953 Rand Corporation: Erfindung der Dynamischen Programmierung
- Viele andere Beiträge zur Mathematik
  - Bellman-Ford Algorithmus

# The Stagecoach story



some 150 years ago there was a salesman travelling west by stagecoach ..

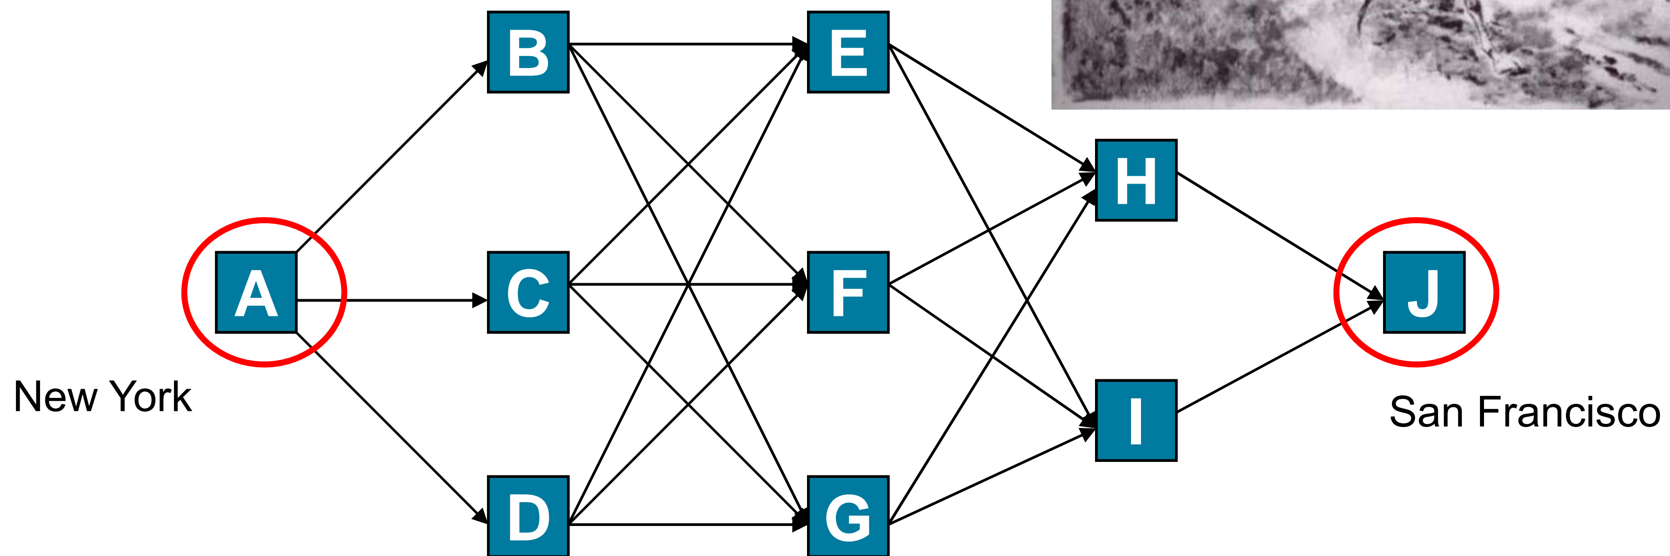


Quelle: Folien Ioana Popescu
http://faculty.insead.edu/popescu/ioana/

# Versicherungskosten



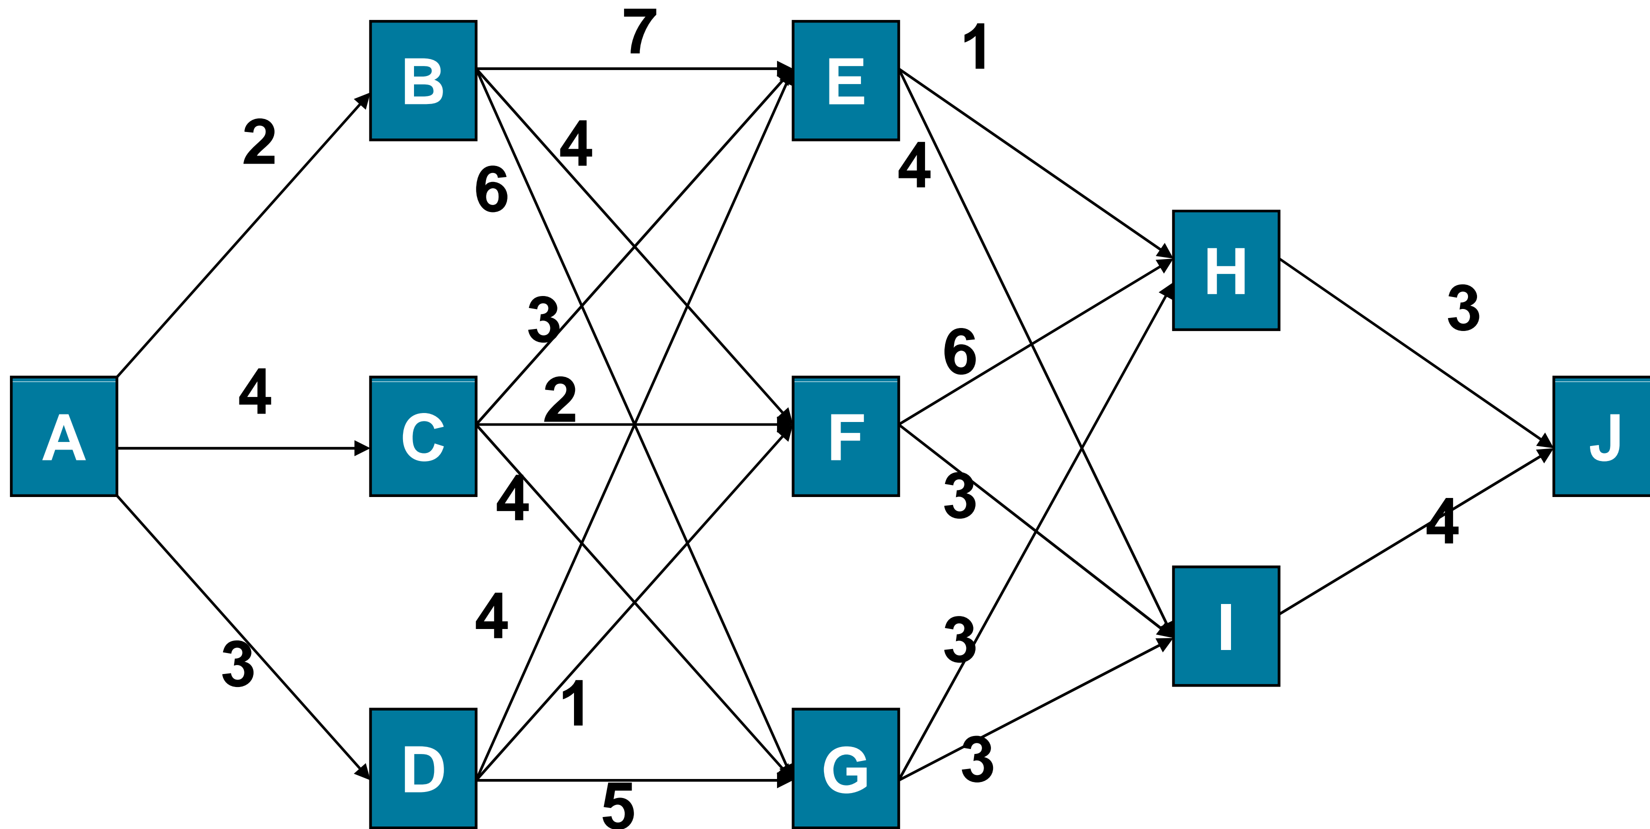


Quelle: Folien Ioana Popescu
http://faculty.insead.edu/popescu/ioana/

# Billigster Weg – Greedy Suche



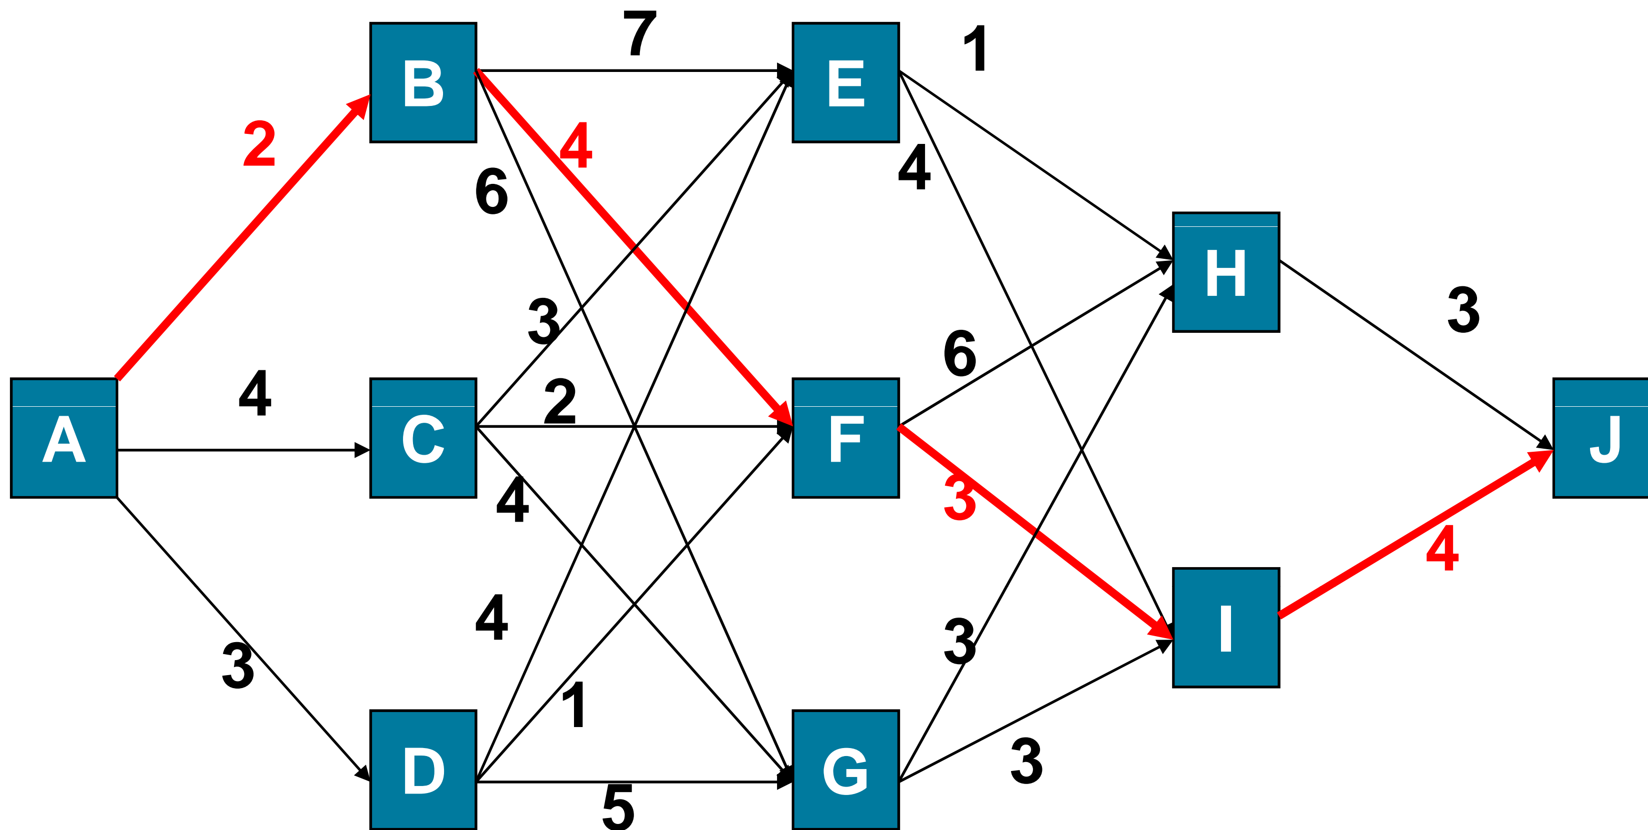


Greedy: A-B-F-I-J = 13

Frage: Gibt es einen besseren Weg?

Quelle: Folien Ioana Popescu
http://faculty.insead.edu/popescu/ioana/

# Billigster Weg – Vollständige Suche



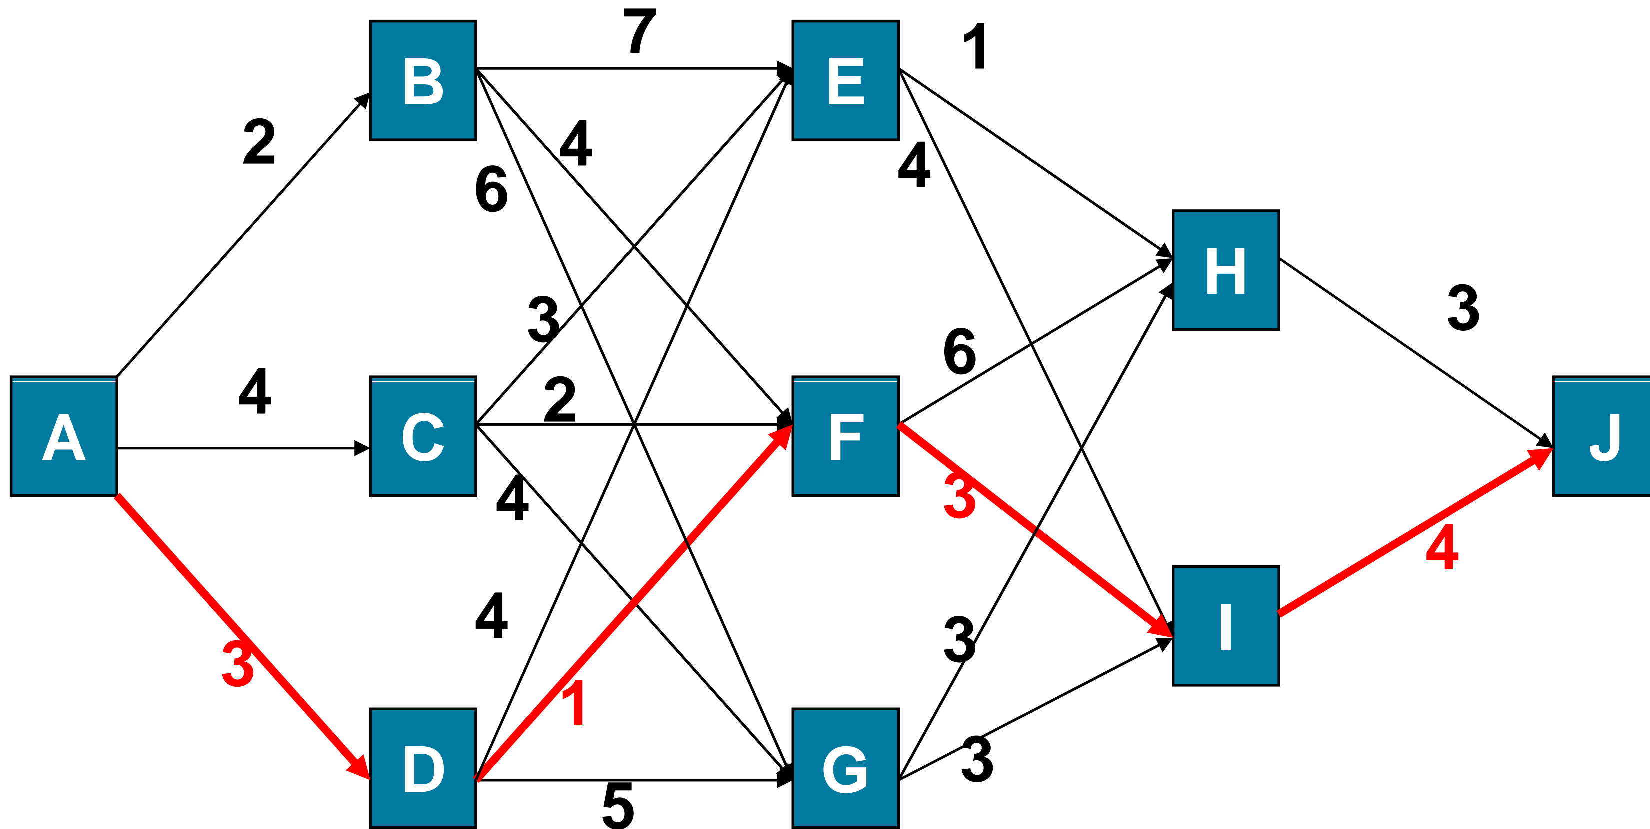


Besser: A-D-F-I-J = 11

Anzahl der möglichen Wege: 3 x 3 x 2 = 18

Quelle: Folien Ioana Popescu
http://faculty.insead.edu/popescu/ioana/

# The Stagecoach Solution

- Idee der Dynamischen Programmierung
  - Hier: “Rückwärtsberechnung”
- Voraussetzung: Prinzip der Optimalität
  - Teilplan eines optimalen Plans ist ebenfalls optimal
- Idee
  - Ausgehend vom Zielknoten stufenweise rückwärts beste Teilpfade berechnen
  - F(X) := minimale Kosten von X nach J

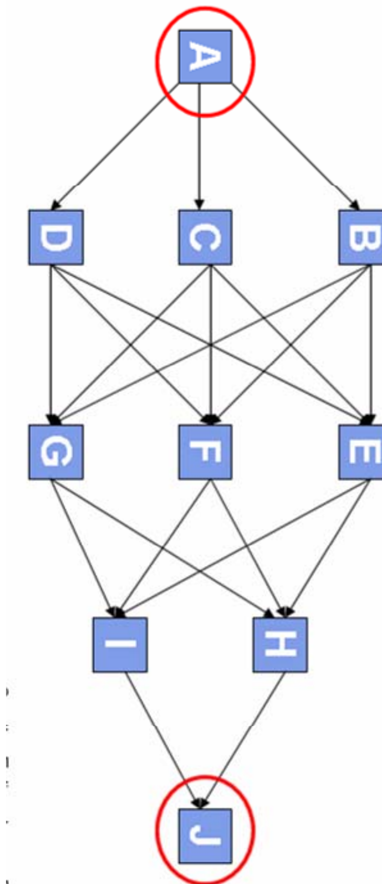


Quelle: Folien Ioana Popescu
http://faculty.insead.edu/popescu/ioana/

# Billigster Weg - DP

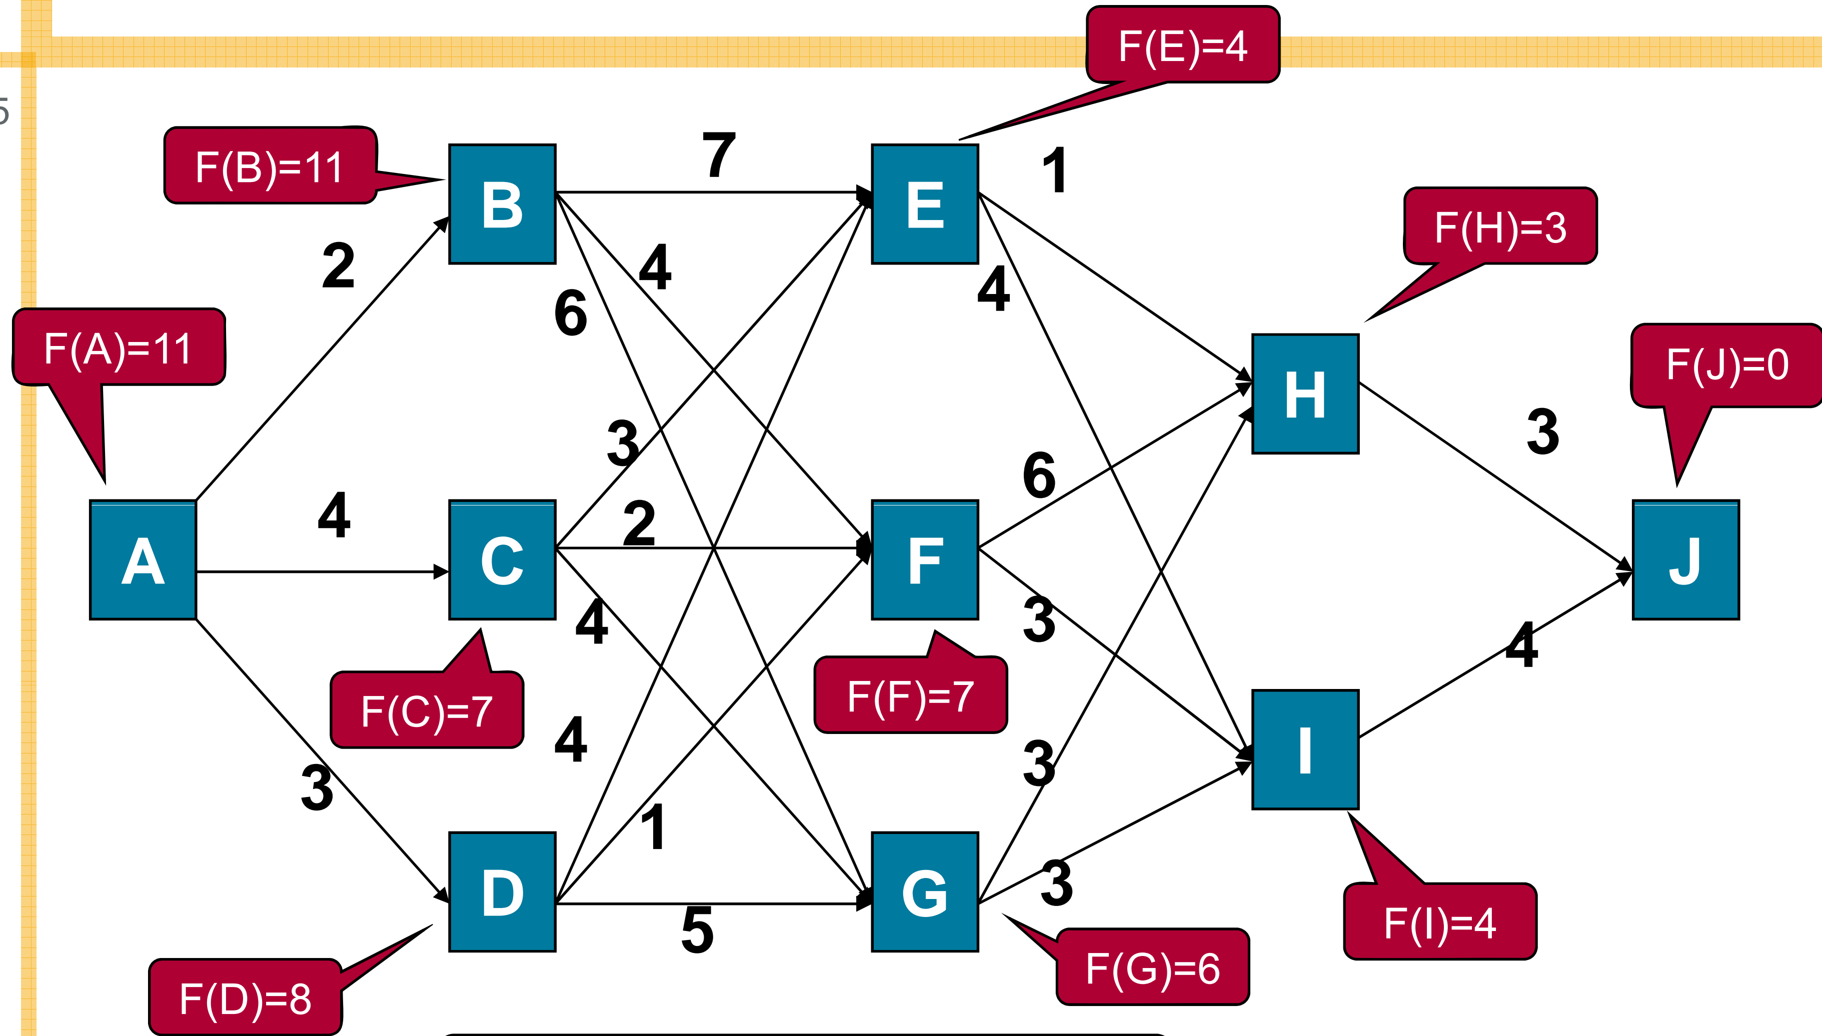


Quelle: Folien Ioana Popescu
http://faculty.insead.edu/popescu/ioana/

# Dynamische Programmierung

Hasso Plattner Institut



- Optimaler Algorithmus
- „Schwierigkeiten"
  - Prinzip der Optimalität muss gelten.
  - Aufteilung des Problems in Teilprobleme
- Aufwand kann exponentiell sein
- Klassische Anwendungen
  - Knapsack Problem
  - Traveling Salesman Problem
  - Maschinenbelegung
  - Transportproblem

- Nun: Anwendung auf die Anfrageplanung

# Überblick



- (Parsing)
- (Algebraische Transformationsregeln)
- (Logische Anfragepläne)
- Kostenmodell
- Kostenbasierte Optimierung
- Joinreihenfolge
  - Dynamische Programmierung
  - Anwendung für Left-Deep Bäume
- Physische Anfragepläne

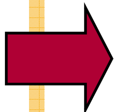

# Anfrageplanung



Heuristische Einschränkung des Suchraums

- Keine Kreuzprodukte
  - Außer explizite Kreuzprodukte in der Anfrage
- Prädikate so früh wie möglich
- Nur links-tiefe (left-deep) Bäume

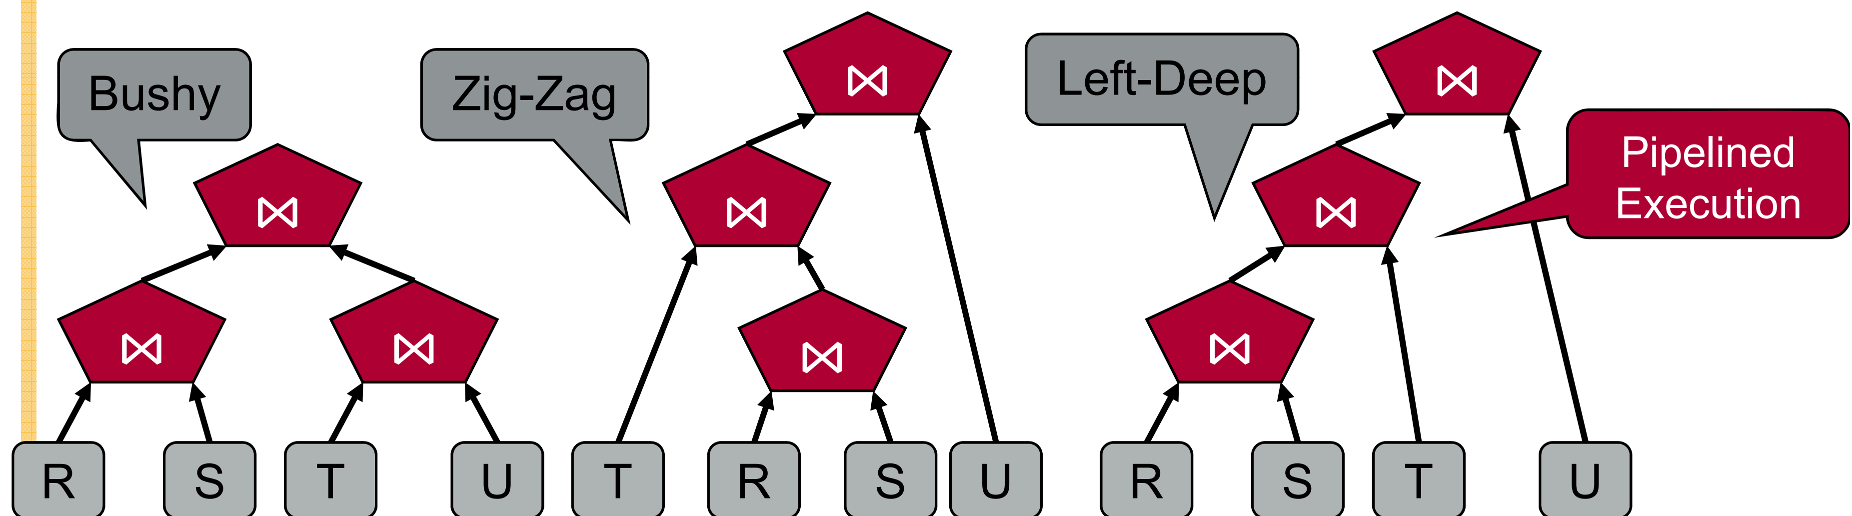

# Dynamische Programmierung: Optimierung im System-R



- A.k.a. “Selinger-style query optimization”
  - Der klassische Artikel zur Anfrageoptimierung: [SAC+79]
  - Ursprünglich im IBM System-R
  - Heutzutage weit verbreitet
- Grundidee:
  - Nur “Left-deep” Anfragebäume
    - D.h. nur Joinreihenfolge interessant
    - Innere und äußere Relation unberücksichtigt
  - Bottom-up Generierung von Anfrageplänen
    - Dynamische Programmierung (DP)
  - Zusätzlich: interesting orders (interessante Sortierungen)
  - (Zusätzlich: interesting sites (interessante Ausführungsorte))

Quelle: u.a. Folien Prof. Chen Li

# Access Path Selection
# in a Relational Database Management System

P. Griffiths Selinger
M. M. Astrahan
D. D. Chamberlin
R. A. Lorie
T. G. Price

IBM Research Division, San Jose, California 95193

ABSTRACT: In a high level query and data manipulation language such as SQL, requests are stated non-procedurally, without reference to access paths. This paper describes how System R chooses access paths for both simple (single relation) and complex queries (such as joins), given a user specification of desired data as a boolean expression of predicates. System R is an experimental database management system developed to carry out research on the relational model of data. System R was designed and built by members of the IBM San Jose Research Laboratory.

## 1. Introduction

System R is an experimental database management system based on the relational model of data which has been under development at the IBM San Jose Research Laboratory since 1975 <1>. The software was developed as a research vehicle in relational database, and is not generally available outside the IBM Research Division retrieval. Nor does a user specify in what order joins are to be performed. The System R optimizer chooses both join order and an access path for each table in the SQL statement. Of the many possible choices, the optimizer chooses the one which minimizes "total access cost" for performing the entire statement.

This paper will address the issues of access path selection for queries. Retrieval for data manipulation (UPDATE, DELETE) is treated similarly. Section 2 will describe the place of the optimizer in the processing of a SQL statement, and section 3 will describe the storage component access paths that are available on a single physically stored table. In section 4 the optimizer cost formulas are introduced for single table queries, and section 5 discusses the joining of two or more tables, and their corresponding costs. Nested queries (queries in predicates) are covered in section 6.

# Bottom-up Anfrageplangenerierung



- Grundannahme 1:
  Nach dem Join über k Relationen ist die Join-Methode die k+1te Relation hinzuzujoinen unabhängig von den vorigen Join-Methoden.
  - Joinmethoden: Nested Loops, Hashjoin, Sort-Merge Join usw.
- Grundannahme 2:
  Jeder Teilplan eines optimalen Plans ist ebenfalls optimal.
  - Entspricht dem Prinzip der Optimalität: Wenn sich zwei Pläne nur in einem Teilplan unterscheiden, so ist der Plan mit dem besseren Teilplan auch der bessere Gesamtplan
- Bottom-up Anfrageplangenerierung:
  - Berechne die optimalen Pläne für den Join über (jede Kombination von) k Relationen
    - Suboptimale Pläne werden verworfen
    - Erweitere diese Pläne zu optimalen Plänen für k+1 Relationen.
    - usw. bis k = n

# Dynamische Programmierung

Hasso Plattner Institut

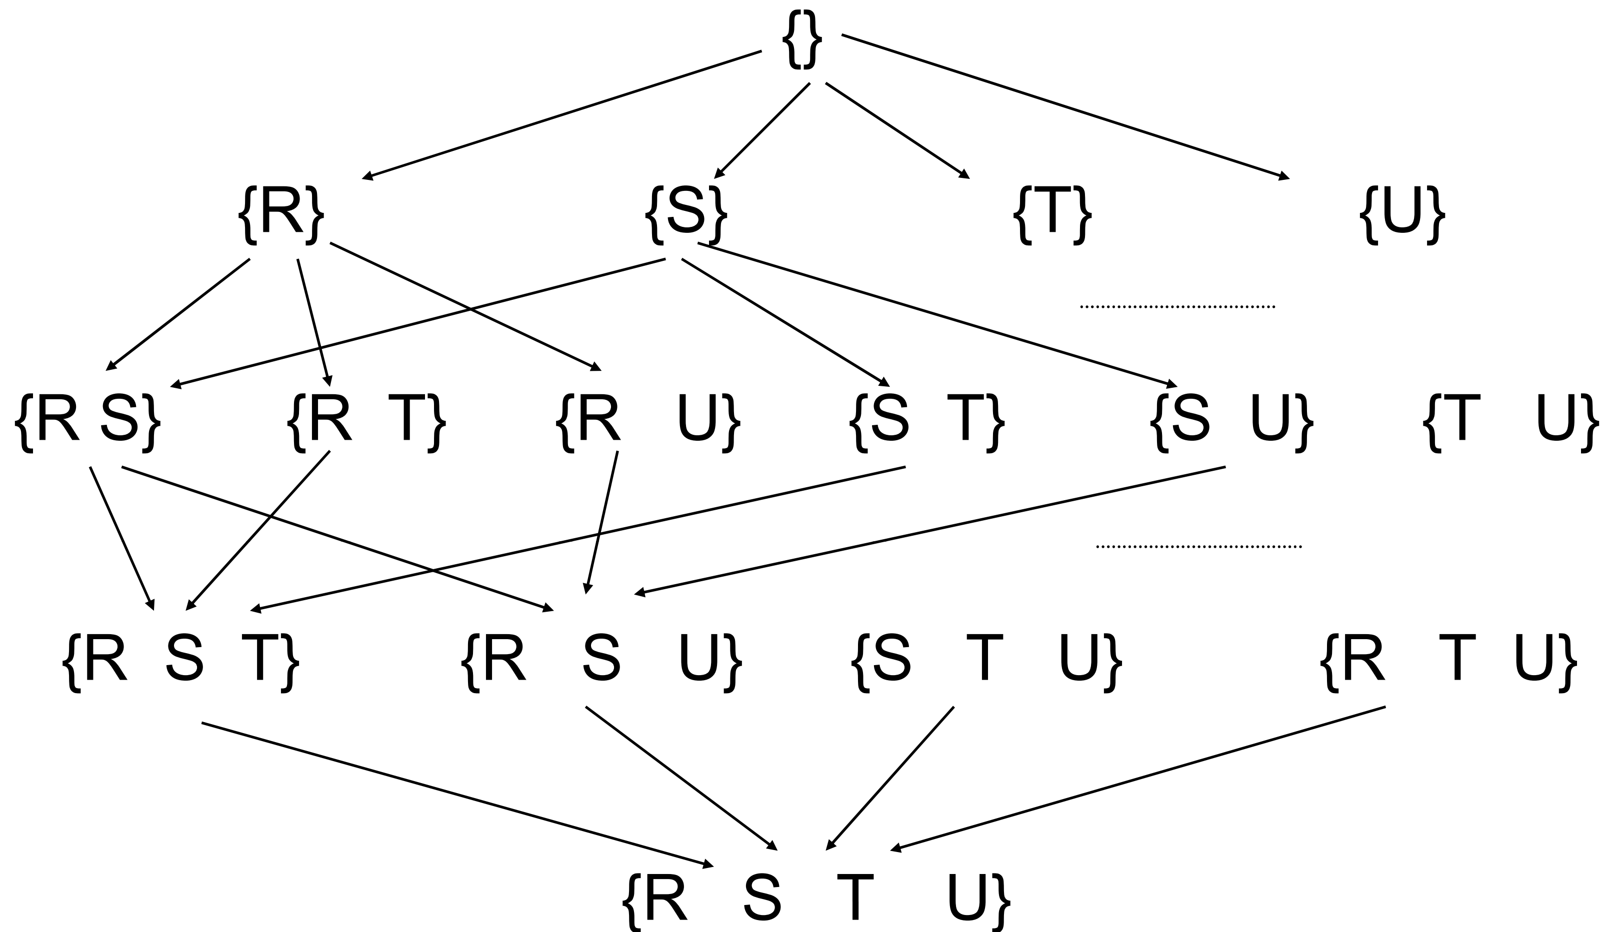

# DP – Grundidee für Anfrageoptimierung

- Für jede Kombination merke (in einer Hilfstabelle):
  - Geschätzte Größe des Ergebnisses (Kardinalität)
  - Geschätzte minimale Kosten
    - Hier zur Vereinfachung: Größe des Zwischenergebnisses
  - Joinreihenfolge, die diese Kosten verursacht (= optimaler Teilplan)
- Induktion über Anzahl der Relationen im Plan
  - N=1: Für jede Relation
    - Kardinalität = Kardinalität der Relation
    - Kosten = 0 (zur Vereinfachung)
    - Joinreihenfolge: n/a
  - N=2: Für jedes Relationenpaar R, S
    - Kardinalität = |R| x |S| x sf
    - Kosten = 0
    - Joinreihenfolge: kleinere Relation links
    - Clou: R und S jeweils mit besten access-path
  - N=3: Für jedes Tripel R, S, T
    - Clou: Nur bestes Relationenpaar aus dem Tripel wird um dritte Relation ergänzt
  - ...

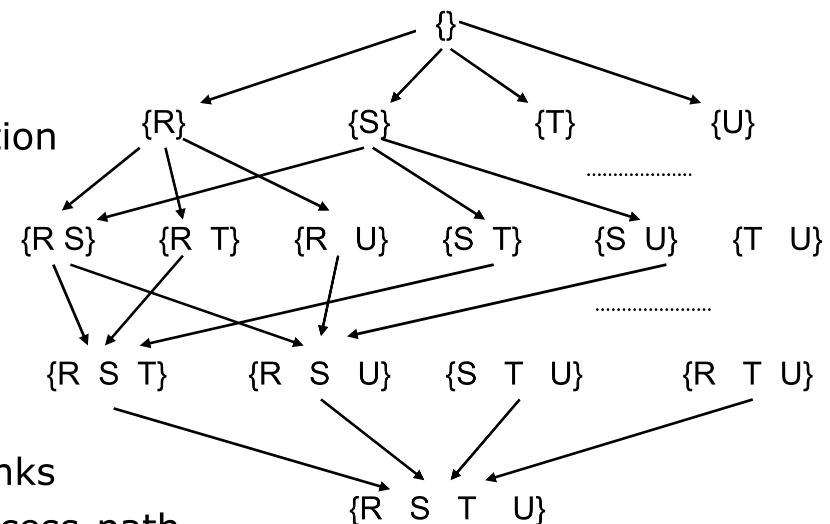

# DP – Beispiel



- Anfrage über Relationen R, S, T, U.
- Vier Join-Bedingungen

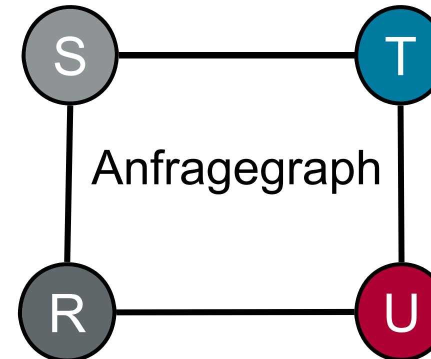


| {R} | {S} | {T} | {U} |
|---|---|---|---|
| 1000<br>0 | 1000<br>0 | 1000<br>0 | 1000<br>0 |
| scan(R) | scan(S) | scan(T) | scan(U) |

u.U. auch IndexScan(...)

# DP – Beispiel

| | {R,S} | {R,T} | {R,U} | {S,T} | {S,U} | {T,U} |
|---|---|---|---|---|---|---|
| Kardinalität | 5000 | 1M | 10000 | 2000 | 1M | 1000 |
| Kosten | 0 | 0 | 0 | 0 | 0 | 0 |
| opt. Plan | R ⋈ S | R ⋈ T | R ⋈ U | S ⋈ T | S ⋈ U | T ⋈ U |

Kreuzprodukte nicht berücksichtigen!

| | {R,S,T} | {R,S,U} | {R,T,U} | {S,T,U} |
|---|---|---|---|---|
| Kardinalität | 10000 | 50000 | 10000 | 2000 |
| Kosten | 2000 | 5000 | 1000 | 1000 |
| opt. Plan | (S⋈ T)⋈ R | (R⋈ S)⋈ U | (T⋈ U)⋈ R | (T⋈ U)⋈ S |

Besser als z.B.
S ⋈ (T ⋈ R) oder (R ⋈ S) ⋈ T

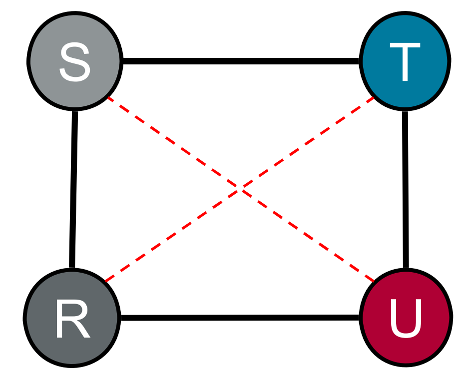

# DP – Beispiel

| | {R,S,T} | {R,S,U} | {R,T,U} | {S,T,U} |
|---|---|---|---|---|
| Kardinalität | 10000 | 50000 | 10000 | 2000 |
| Kosten | 2000 | 5000 | 1000 | 1000 |
| opt. Plan | (S⋈ T)⋈ R | (R⋈ S)⋈ U | (T⋈ U)⋈ R | (T⋈ U)⋈ S |

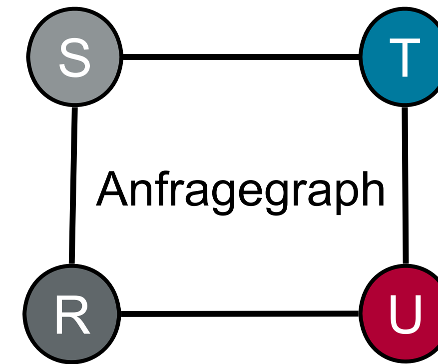


| Plan | Kosten |
|---|---|
| ((S ⋈T)⋈ R)⋈ U | 12k |
| ((R⋈S)⋈ U)⋈ T | 55k |
| ((T ⋈U) ⋈R)⋈ S | 11k |
| ((T ⋈U) ⋈S)⋈ R | 3k |

Optimaler (left-deep) Plan

**Bisher unberücksichtigt: Wahl des Join-Algorithmus**

# DP - interesting orders (Interessante Sortierung)



- WdH.: Prinzip der Optimalität: Wenn sich zwei Pläne nur in einem Teilplan unterscheiden, so ist der Plan mit dem besseren Teilplan auch der bessere Gesamtplan.
- Gegenbeispiel?
  - R(A,B) ⋈ S(A,C) ⋈ T(A,D)
  - Bester (lokaler) Plan für R ⋈ S: Hash-Join
  - Best (globaler) Gesamtplan:
    - 1. Sort-merge Join über R und S
    - 2. Sort-merge Join mit T
- Warum könnte dies so sein?
  - Das Zwischenergebnis von R $\bowtie_{\text{sort-merge}}$S ist nach Join-Attribut A sortiert.
  - Dies ist eine interesting order, die später ausgenutzt werden kann:
    - Spätere sort-merge Joins
    - Gruppierung (GROUP BY)
    - Sortierung (ORDER BY)
    - Eindeutige Tupel (DISTINCT)

# DP - interesting orders (Interessante Sortierung)



- Bei Auswahl des besten Teilplans:
  - Kostenvergleich genügt nicht.
    - Es gibt keine vollständige Ordnung der Teilpläne nach Kosten.
  - Auch Sortierungen müssen berücksichtigt werden.
- Lösung: Für jede Kombination von Relationen, speichere mehrere Sortiervarianten:
  - Nach jeder Variante der beteiligten Teilpläne
  - Die "leere" Sortierung
  - DP Tabellen werden „breiter".
- Merke außerdem Join- und Sortieroperationen, die diese Sortierung erzeugen.

# DP – Algorithmus



**Input:** SPJ query $q$ on relations $R_1, \ldots, R_n$
**Output:** A query plan for $q$

```
1:  for i = 1 to n do {
2:      optPlan({R_i}) = accessPlans(R_i)
3:      prunePlans(optPlan({R_i}))
4:  }
5:  for i = 2 to n do {
6:      for all S ⊆ {R_1, ..., R_n} such that |S| = i do {
7:          optPlan(S) = Ø
8:          for all O ⊂ S do {
9:              optPlan(S) = optPlan(S) ∪ joinPlans(optPlan(O), optPlan(S − O))
10:             prunePlans(optPlan(S))
11:         }
12:     }
13: }
14: return optPlan({R_1, ..., R_n})
```

Alle Zugriffspläne für jede Relation

Schlechtere Zugriffs-pläne verwerfen

Achtung: Nicht left-deep!

Quelle: [Ko00]

# Überblick

- (Parsing)
- (Algebraische Transformationsregeln)
- (Logische Anfragepläne)
- Kostenmodell
- Kostenbasierte Optimierung
- Joinreihenfolge
  - Dynamische Programmierung
  - Anwendung für Left-Deep Bäume
- Physische Anfragepläne

# Letzte Schritte



- Wahl des jeweiligen Algorithmus
  - Wenn nicht schon zuvor (z.B. bei DP) geschehen
  - Hier nur beispielhaft: Selektion und Join
- Pipelining vs. Blocking
- Zugriffsmethoden für Relationen

# Wahl der Selektionsmethode



- Schon kennengelernt
  - Variante 1: Ganz R lesen und Selektionsbedingung auf jedes Tupel anwenden
  - Variante 2: Falls Index auf Selektionsattribut vorhanden: Zugriff über Index
    - Voraussetzung: Index und Gleichheitsbedingung
- Jetzt: Verallgemeinerung auf mehrere Selektionen auf verschiedenen Attributen
  - Mit oder ohne Index
  - Gleichheit oder Ungleichheit ($<$, $>$, $\leq$, $\geq$, $\neq$)

# Wahl der Selektionsmethode



- Annahme: Mindestens eine Selektionsbedingung kann einen Index verwenden.
- Vorgehen mit Indizes (jeweils viele Alternativen):
  - Verwende Indizes um Schnittmenge der Pointermengen zu ermitteln
  - Lese diese Tupel ein (Index-scan)
  - Wende darauf „Filter"-Operator an: Prüft alle übrigen Bedingungen
- Vorgehen ohne Indizes
  - Table-scan für ganz R
  - Wende Filter-Operator für alle Bedingungen an
- Filter-Operator findet nur im Hauptspeicher statt: Keine Kosten
- Jetzt: Kostenvergleich der Alternativen

# Kostenvergleich der Selektionsmethoden



- Bisher: Kostenschätzung durch Schätzung der Ergebnisgröße
  - Kardinalität des Zwischenergebnisses
- Jetzt: Nur Implementierungsvarianten mit jeweils gleichem Ergebnis
  - Deshalb wieder: Disk I/Os
  - Annahme: Indizes kosten nichts (da sehr kleine Mengen)
- Beispiel: $\sigma_{A=10,\ B<20}(R)$
  - Variante 1: Tablescan
    - B(R) falls R clustered
    - T(R) falls R nicht clustered
  - Variante 2: Index auf A verwenden
    - B(R)/V(R,A) falls Index clustering
    - T(R)/V(R,A) falls Index nicht clustering
  - Variante 3: Index auf B verwenden
    - B(R)/3 falls Index clustering
    - T(R)/3 falls Index nicht clustering

# Kostenvergleich der Selektionsmethoden – Beispiel



- $\sigma_{X=1,\ Y=2,\ Z<5}(R)$
  - T(R) = 5000, B(R) = 200, V(R,X)=100, V(R,Y)=500
  - R sei clustered
  - Indizes auf X und Y nicht clustering
  - Index auf Z clustering
- Variante 1: Table-scan und Filter
  - Kosten: B(R) = 200 I/Os
- Variante 2: Index-scan mit X-Index; Filter für den Rest
  - Kosten: T(R)/V(R,X) = 5000/100 = 50 I/Os
- Variante 3: Index-scan mit Y-Index; Filter für den Rest
  - Kosten: T(R)/V(R,Y) = 5000/500 = 10 I/Os
- Variante 4: Index-scan mit (clustering) Z-Index; Filter für den Rest
  - Kosten: B(R)/3= 200/3 = 67 I/Os

# Wahl der Join-Methode



- Kosten je nach Joinmethode (siehe voriger Foliensatz)
  - Annahme: Man kennt M (verfügbarer Hauptspeicher)
    - Und M ändert sich nicht während der Ausführung
  - Annahme: Man kennt B(R), T(R), V(R, …)
- Ideen falls Annahmen nicht stimmen
  - One-pass oder Nested-loop Algorithmus als default
    - Prinzip „Hoffnung"
  - Wähle Sort-merge-join falls mindestens ein Input bereits nach Joinattribut sortiert ist.
  - Wähle Sort-merge-join bei mehr als ein Join auf gleichem Attribut
    - $(R(A,B) \bowtie S(B,C)) \bowtie R(A,D)$
  - $R(A,B) \bowtie S(B,C)$: Falls R klein und Index auf S.B: Wähle Index-Join
  - Falls weder Sortierung noch Indizes vorhanden sind: Wähle Hash-Join
    - Kosten hängen nur von kleinerem Input ab, nicht von beiden Inputs
- Analoge Überlegungen für Mengenoperationen

# Pipelining vs. Blocking



- Naive: Blocking (auch „Materialisierend")
  - Jeder Operator speichert sein Zwischenergebnis auf Disk
- Besser: Vermischung der Ausführung verschiedener Operatoren
  - Pipelining
  - Kette von Iteratoren
- Vorteile von Pipelining
  - Weniger I/O
  - Frühe Ergebnisse bei der Anwendung
- Nachteile des Pipelining?
  - Nicht jeder Operator funktioniert
  - Jeder Operator hat weniger Hauptspeicher
  - => Thrashing
- Pipelining also nicht immer besser!

# Pipelines mit unären Operatoren



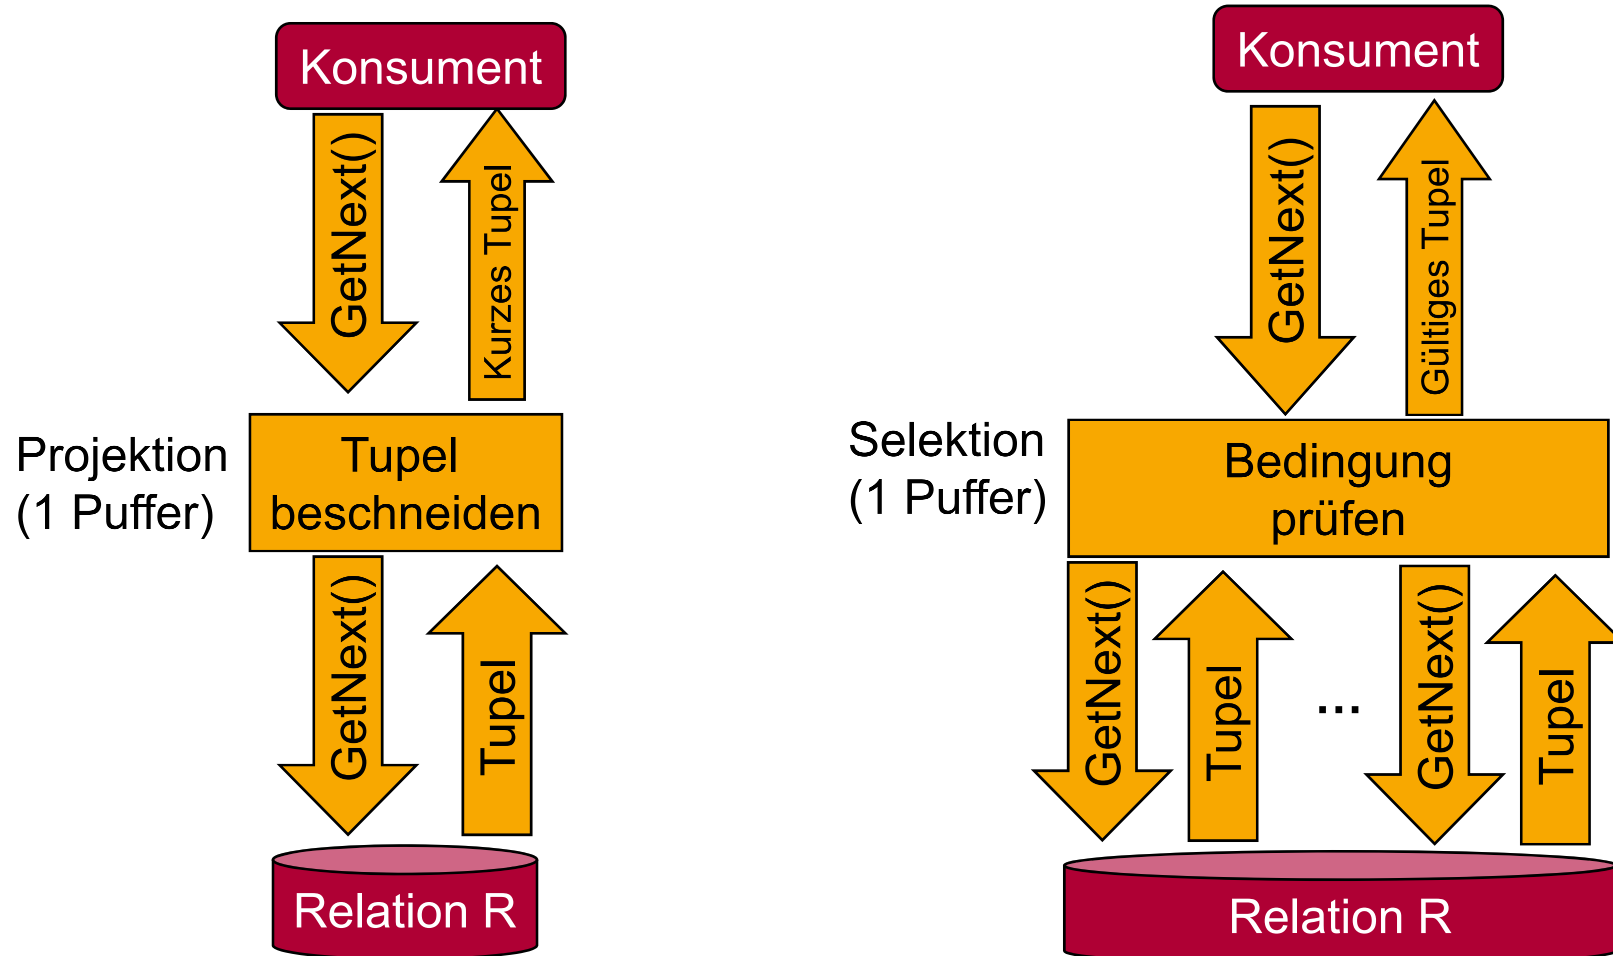

# Pipelines mit binären Operatoren



- 1 Puffer für Output aber mehrere Puffer für Input
- Nun: Betrachtung des shared memory am Beispiel
- ( R(W,X) ⋈ S(X,Y) ) ⋈ U(Y,Z)
  - B(R) = 5000, B(S) = B(U) = 10000
  - Zwischenergebnis R ⋈ S nehme *k* Blöcke ein
    - Wird variieren
  - Beide Joins seien als Hash-join implementiert
    - One-pass oder two-pass (je nach *k*)
  - M = 101

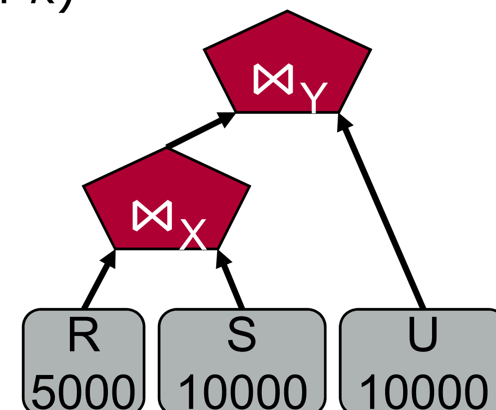

# Pipelines mit binären Operatoren – Beispiel



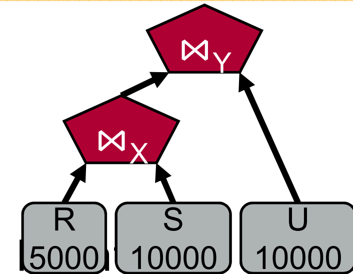


- Zunächst R ⋈ S
  - Keines passt in Hauptspeicher => Two-pass Hash-join
  - Pass 1: M = 101 => 100 Buckets => Jeder Bucket von R hat 50 Blocks
  - Pass 2 benötigt 51 Puffer => 50 verbleiben für Join mit U
- Variation von *k* (Blöcke des Zwischenergebnisses R ⋈ S)
  - $k \leq 49$
    - Pipeline der Ergebnis Tupel in freien Speicher unter Aufbau einer Hashtabelle
    - Mindestens ein freier Puffer verbleibt zum Einlesen von U (also one-pass)
    - I/O: 45000 für two-pass hashjoin + 10000 für U lesen
  - $49 < k \leq 5000$
  - $k > 5000$

# Pipelines mit binären Operatoren – Beispiel

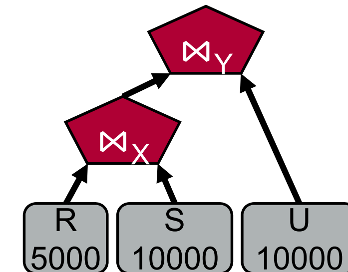


- $49 < k \leq 5000$
  - Wie vorher: Pipeline des Ergebnisses von R ⋈ S
  - Aber: Join mit U als 50-bucket two-pass Hash-join
  1. Hashe U in 50 Buckets á 200 Blocks
  2. Two-pass Hashjoin von R ⋈ S auf 51 buckets
  3. Schreibe Joinergebnisse in einen der 50 U-buckets (wie immer auf Disk schreiben, falls voll)
  4. Bucket-weise Join von R ⋈ S mit U
     - k ≤ 5000 => (R ⋈ S)-buckets maximal 100 groß
  - Kosten:
    - 20000 für Lesen und bucket-Schreiben von U
    - 45000 für two-pass hash-join R ⋈ S
    - *k* zum Schreiben der buckets von R ⋈ S
    - K + 10000 zum Lesen der (R ⋈ S)-buckets und probing mit U
  - Zusammen: 75000 + 2*k*

# Pipelines mit binären Operatoren – Beispiel



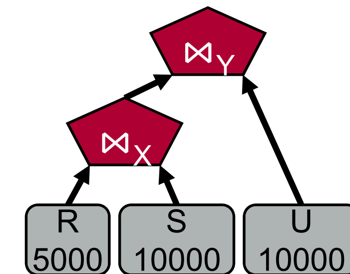


- $k > 5000$
  - Hashing von R ⋈ S klappt nicht mehr: Einer der 50 Buckets passt nicht mehr in Hauptspeicher
- Variante 1: three-pass Join; Kosten 20000 + 2*k* zusätzlich
  - 2 I/O für jede Seite (für U und für R ⋈ S)
  - Zusammen: 95000 + 4*k*
- Variante 2: Auf pipeline verzichten
  - R ⋈ S mit two-pass Hash-join
    - Ergebnis auf Disk schreiben
  - Join mit U mittels two-pass Hash-join
    - Da B(U) = 10000: Build mit 100 buckets ist möglich
    - Also eigentlich U ⋈ (R ⋈ S)
  - Kosten:
    - 45000 + *k* für R ⋈ S und anschließendes Schreiben
    - 30000 + 3*k* für two-pass Hash-join mit U
  - Zusammen: 75000 + 4*k*

# Überblick

HPI Hasso Plattner Institut

- (Parsing)
- (Algebraische Transformationsregeln)
- (Logische Anfragepläne)
- Kostenmodell
- Kostenbasierte Optimierung
- Joinreihenfolge
  - Dynamische Programmierung
- Physische Anfragepläne
- Picasso: Erratische Optimierer

http://dsl.serc.iisc.ernet.in/projects/PICASSO/picasso.html

# Example Query [Q7 of TPC-H]

```
select
   supp_nation, cust_nation, l_year, sum(volume) as revenue
from
(select n1.n_name as supp_nation,  n2.n_name as cust_nation,
          extract(year from l_shipdate) as l_year,
          l_extendedprice * (1 - l_discount) as volume
 from     supplier, lineitem, orders, customer, nation n1, nation n2
 where s_suppkey = l_suppkey and o_orderkey = l_orderkey and
          c_custkey = o_custkey and s_nationkey = n1.n_nationkey
          and c_nationkey = n2.n_nationkey and
        ((n1.n_name = 'FRANCE' and n2.n_name = 'GERMANY') or
         (n1.n_name = 'GERMANY' and n2.n_name = 'FRANCE')) and
         l_shipdate between date '1995-01-01' and date '1996-12-31'
         and  o_totalprice < C1  and  c_acctbal < C2    ) as shipping
  group by supp_nation, cust_nation, l_year
  order by supp_nation, cust_nation, l_year
```

Slides: Naveen Reddy und Jayant Haritsa: "*Analyzing Plan Diagrams of Database Query Optimizers*"; VLDB 2005

# Example Plan Diagram



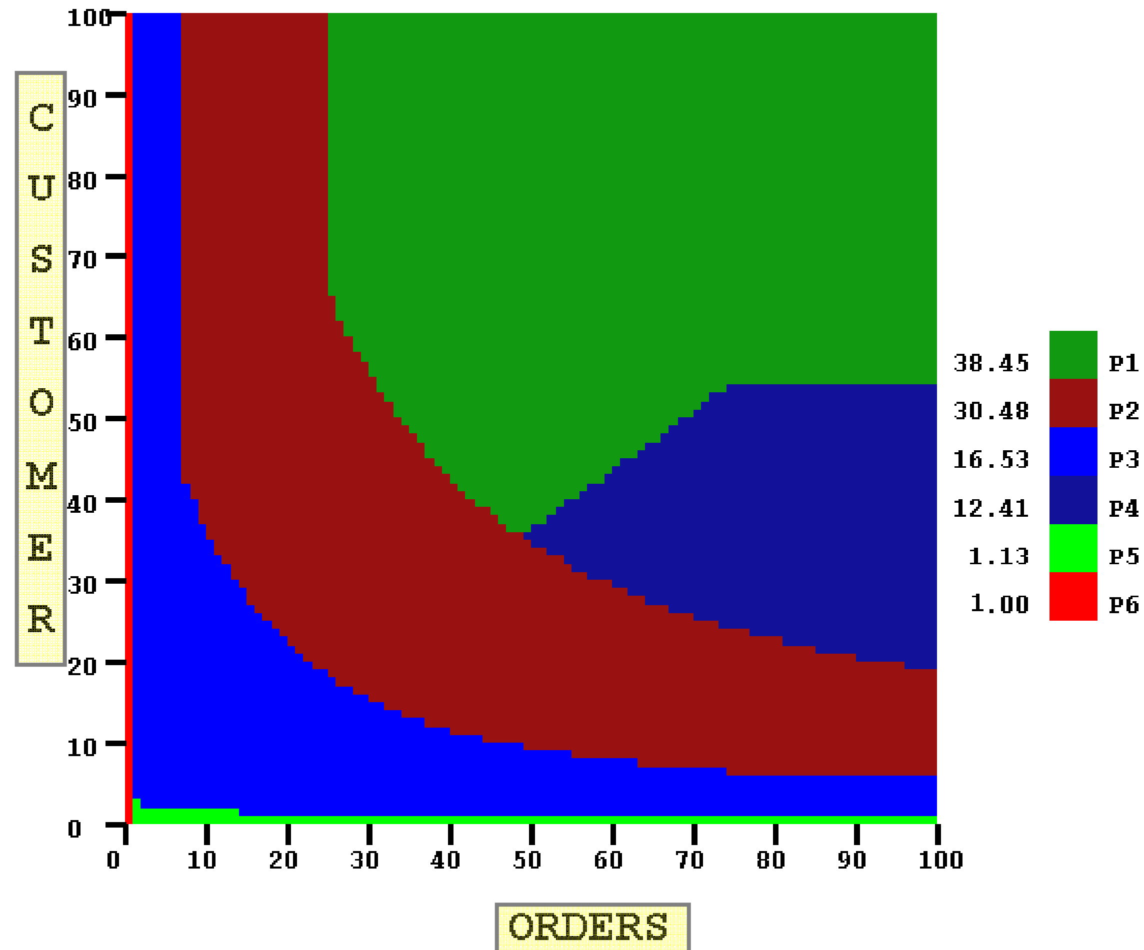


Slides: Naveen Reddy und Jayant Haritsa: "*Analyzing Plan Diagrams of Database Query Optimizers*"; VLDB 2005

# Specific Plan Choices

HPI Hasso Plattner Institut



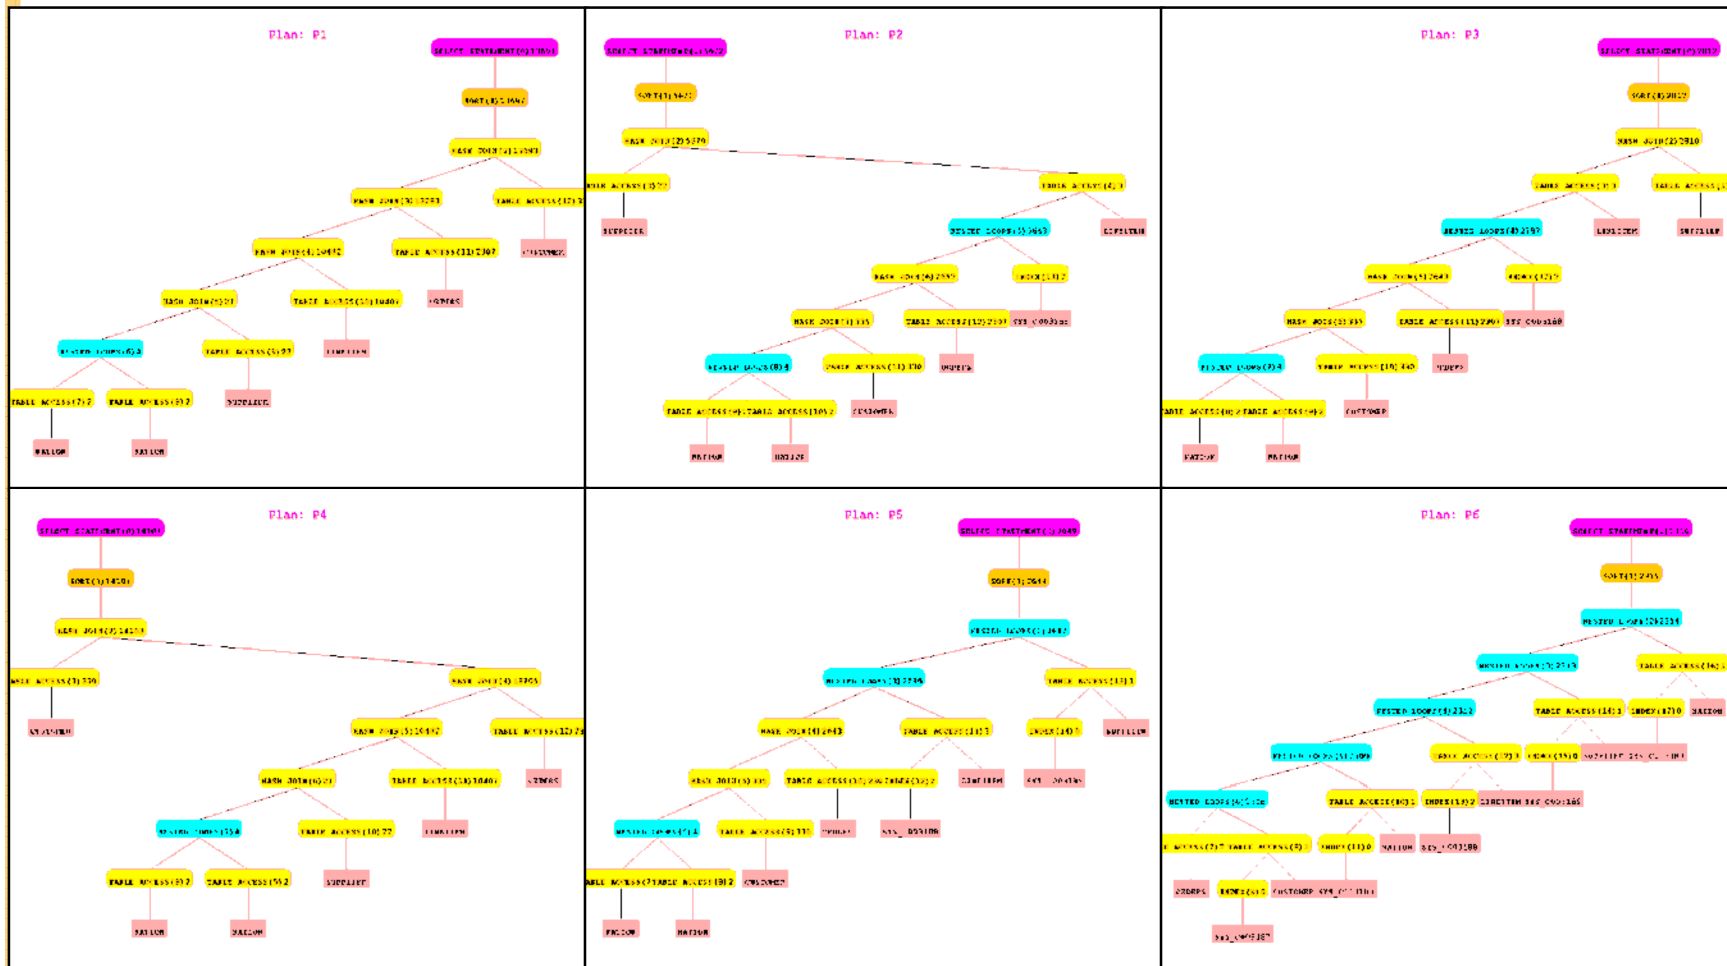


Slides: Naveen Reddy und Jayant Haritsa: “*Analyzing Plan Diagrams of Database Query Optimizers*”; VLDB 2005

# Example Cost Diagram



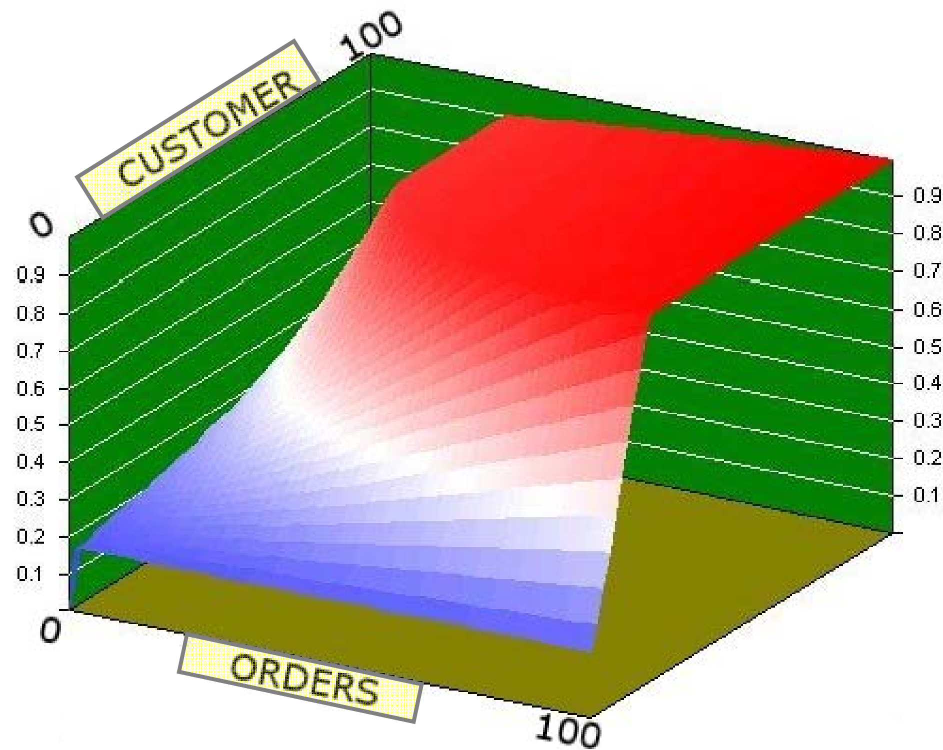


Slides: Naveen Reddy und Jayant Haritsa: “*Analyzing Plan Diagrams of Database Query Optimizers*”; VLDB 2005

C… Diagram [Q8, OptA*]



Highly irregular plan boundaries

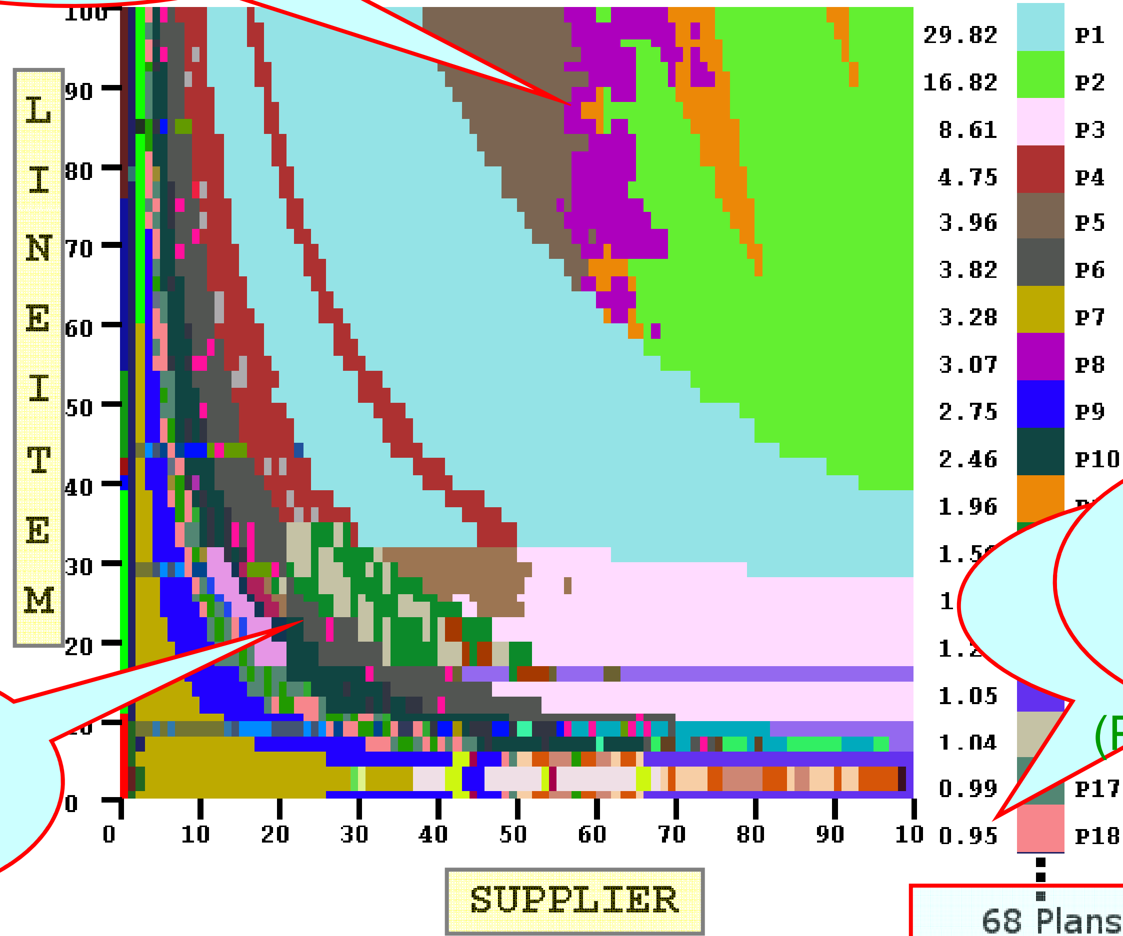


Intricate Complex Patterns

Increases to **80 plans** with 300x300 grid !

(P68 …0.02%)

Slides: Naveen Reddy und Jayant Haritsa: "*Analyzing Plan Diagrams of Database Query Optimizers*"; VLDB 2005

# Duplicates and Islands [Q10, OptA]



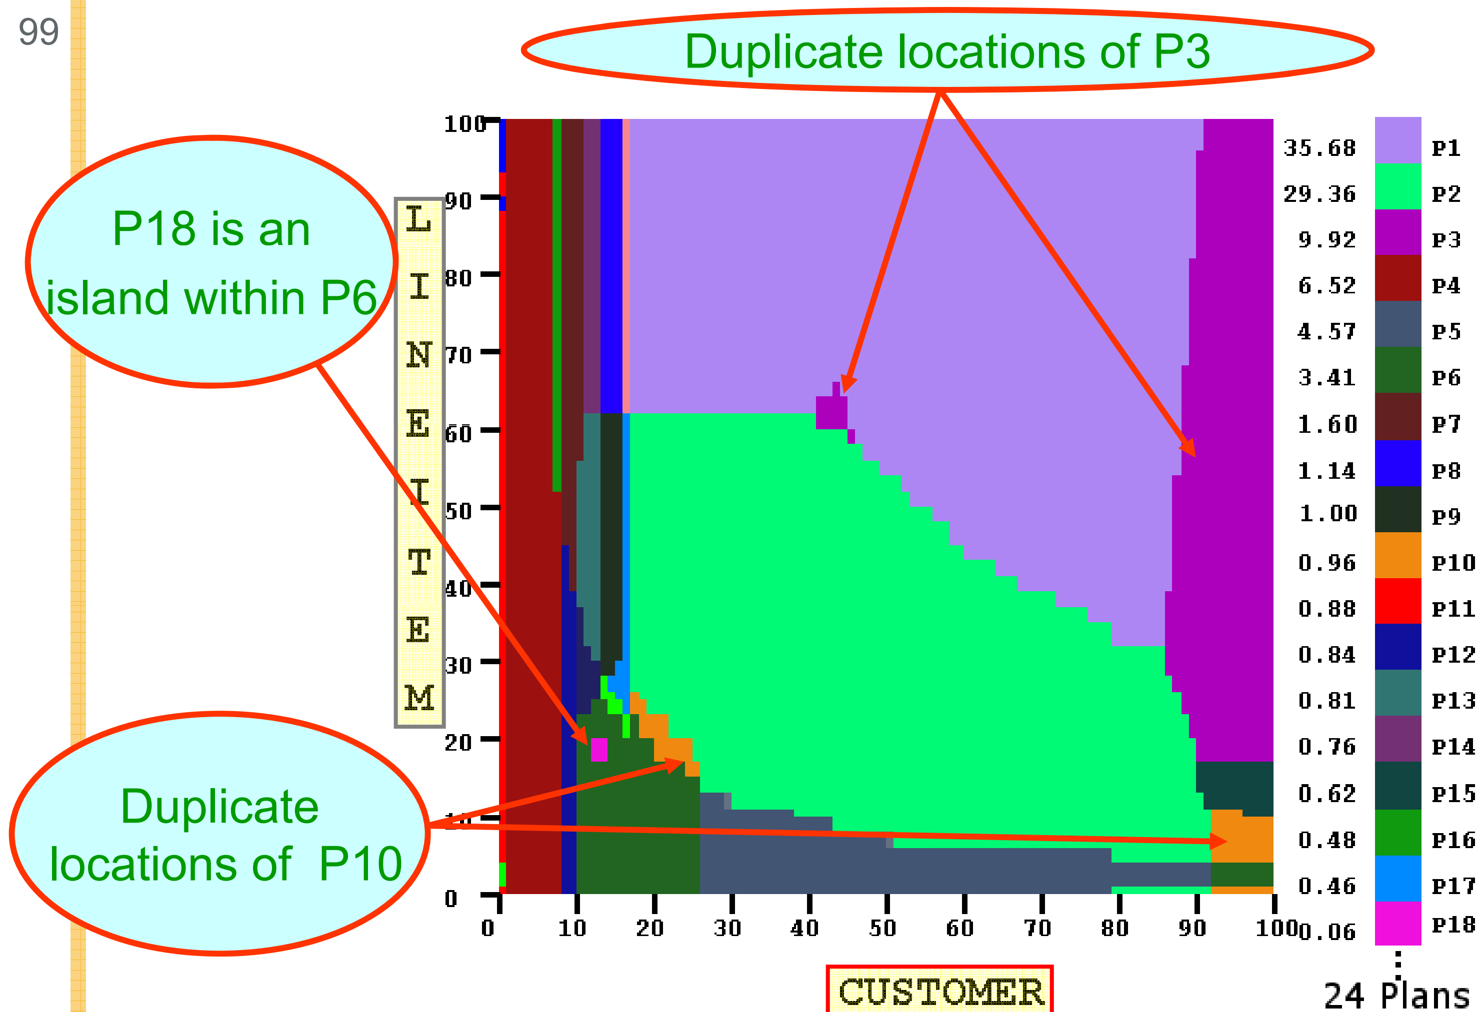


Slides: Naveen Reddy und Jayant Haritsa: "*Analyzing Plan Diagrams of Database Query Optimizers*"; VLDB 2005

# Duplicates and Islands [Q5, OptC]



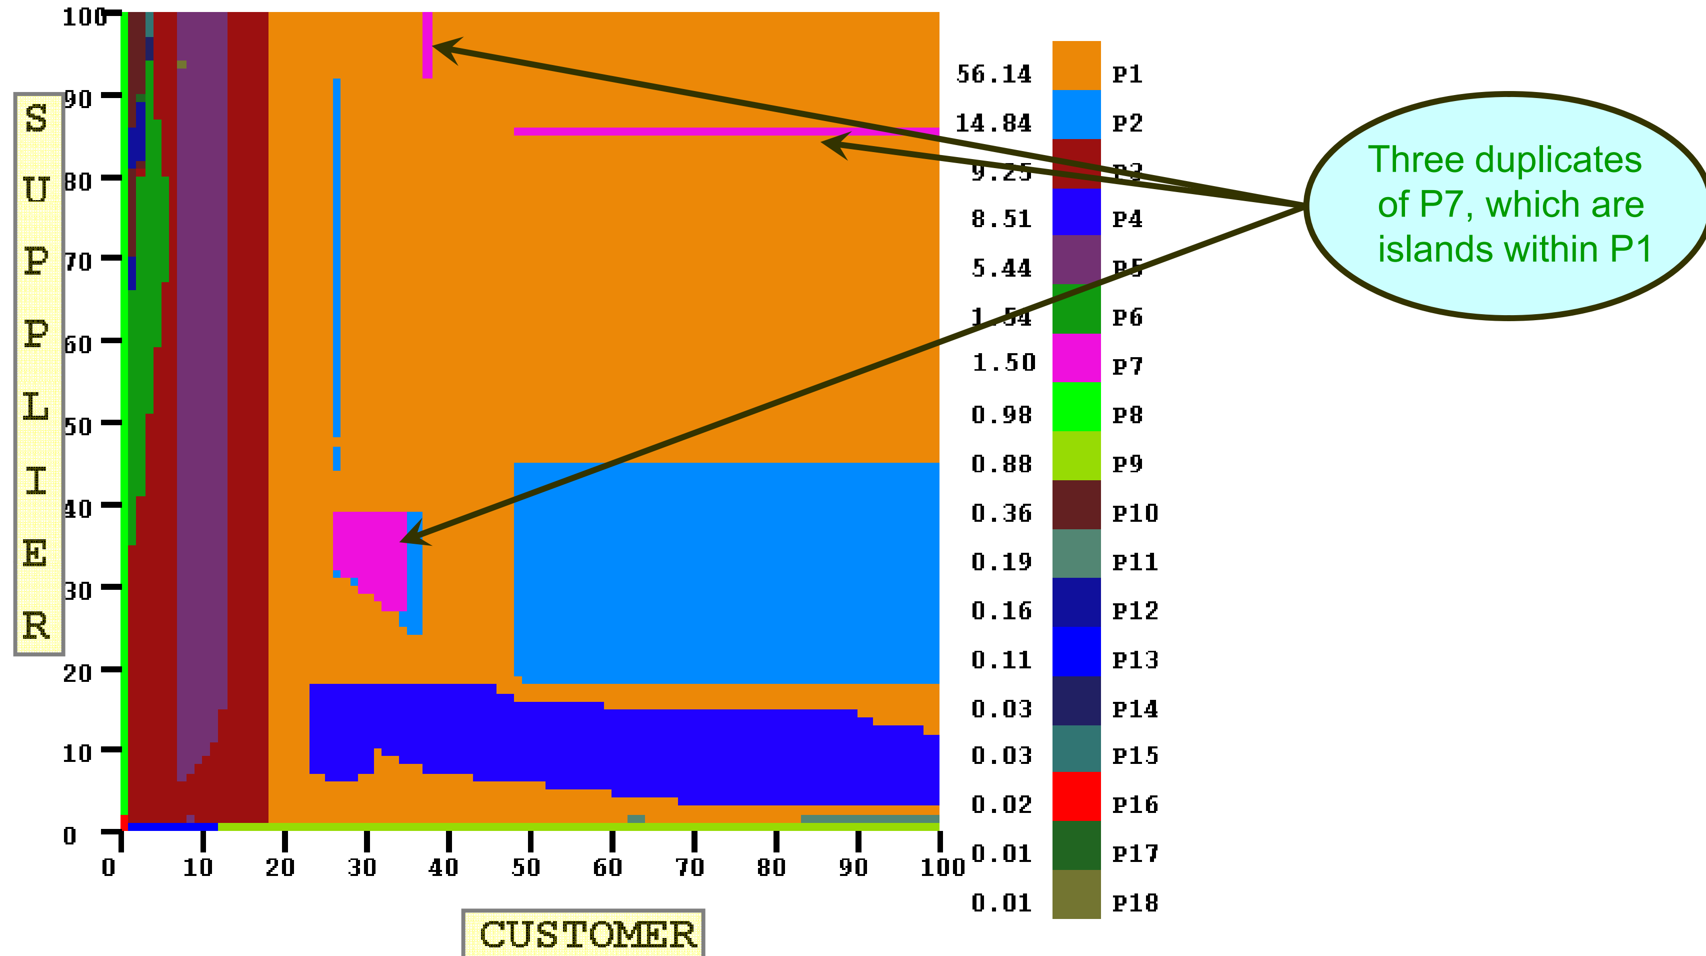


Slides: Naveen Reddy und Jayant Haritsa: "*Analyzing Plan Diagrams of Database Query Optimizers*"; VLDB 2005

# Plan Switch Points [Q9, OptA]

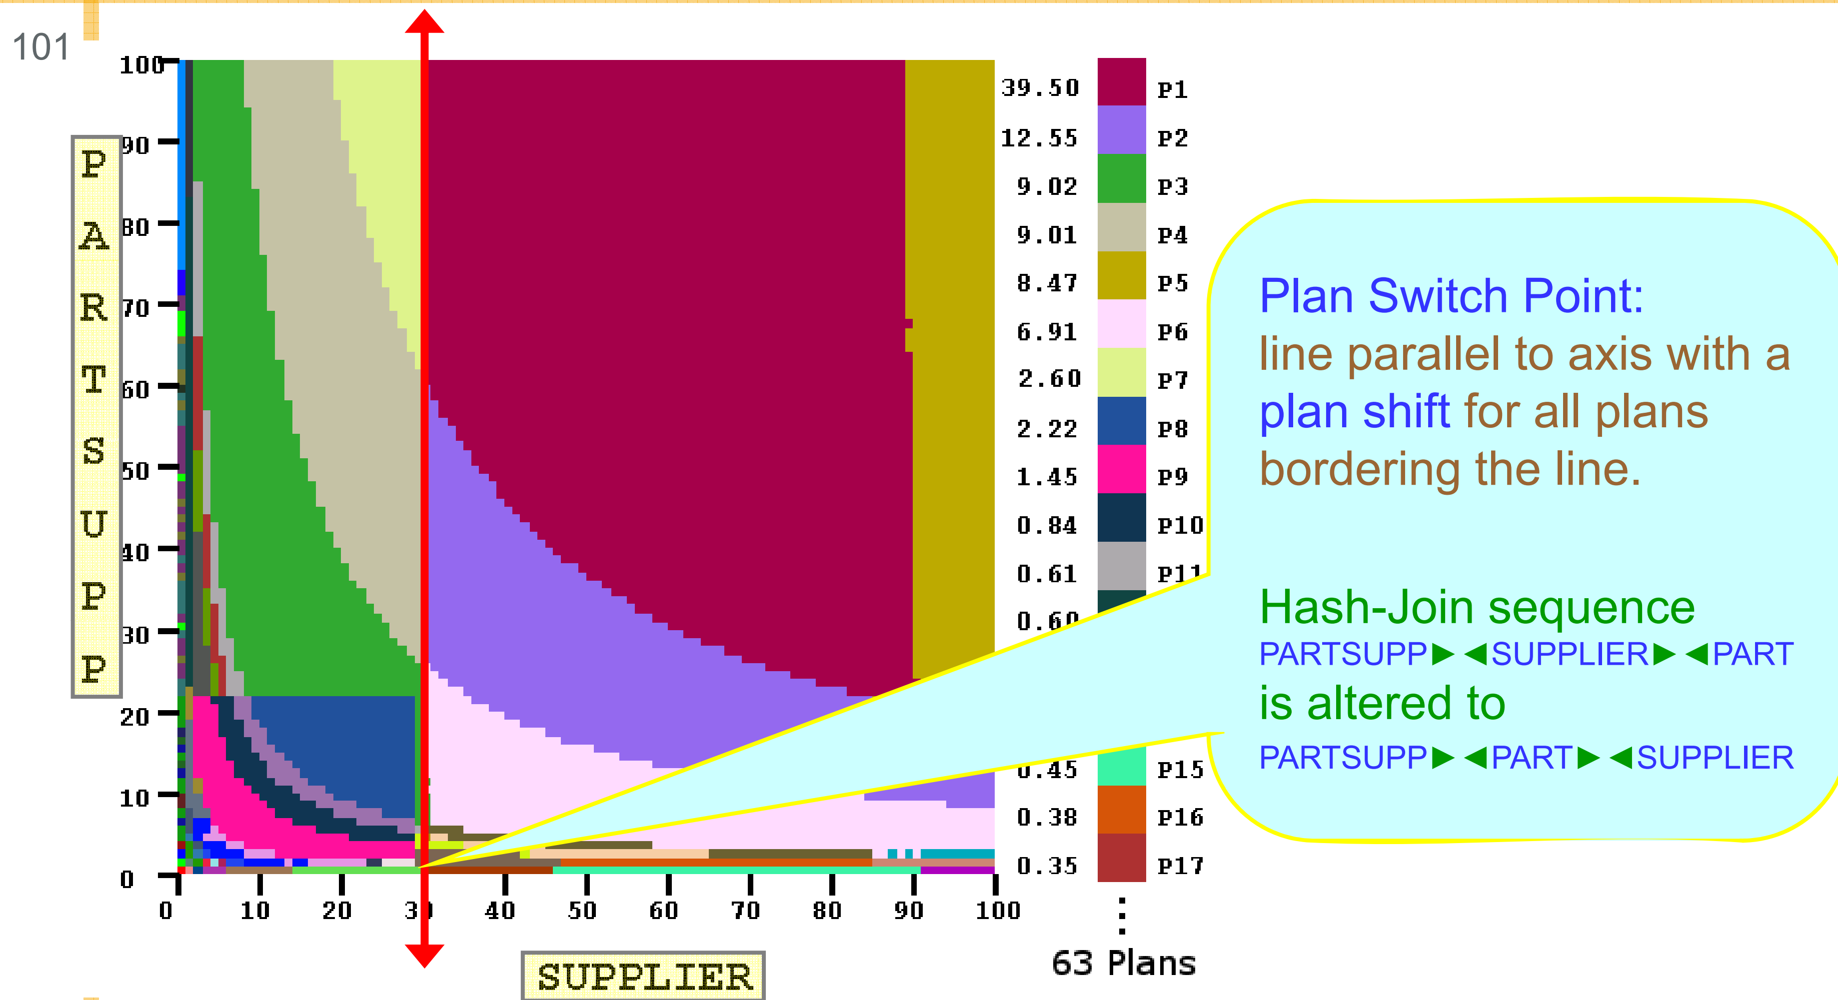


Slides: Naveen Reddy und Jayant Haritsa: "*Analyzing Plan Diagrams of Database Query Optimizers*"; VLDB 2005

# Venetian Blinds [Q9, Opt B]



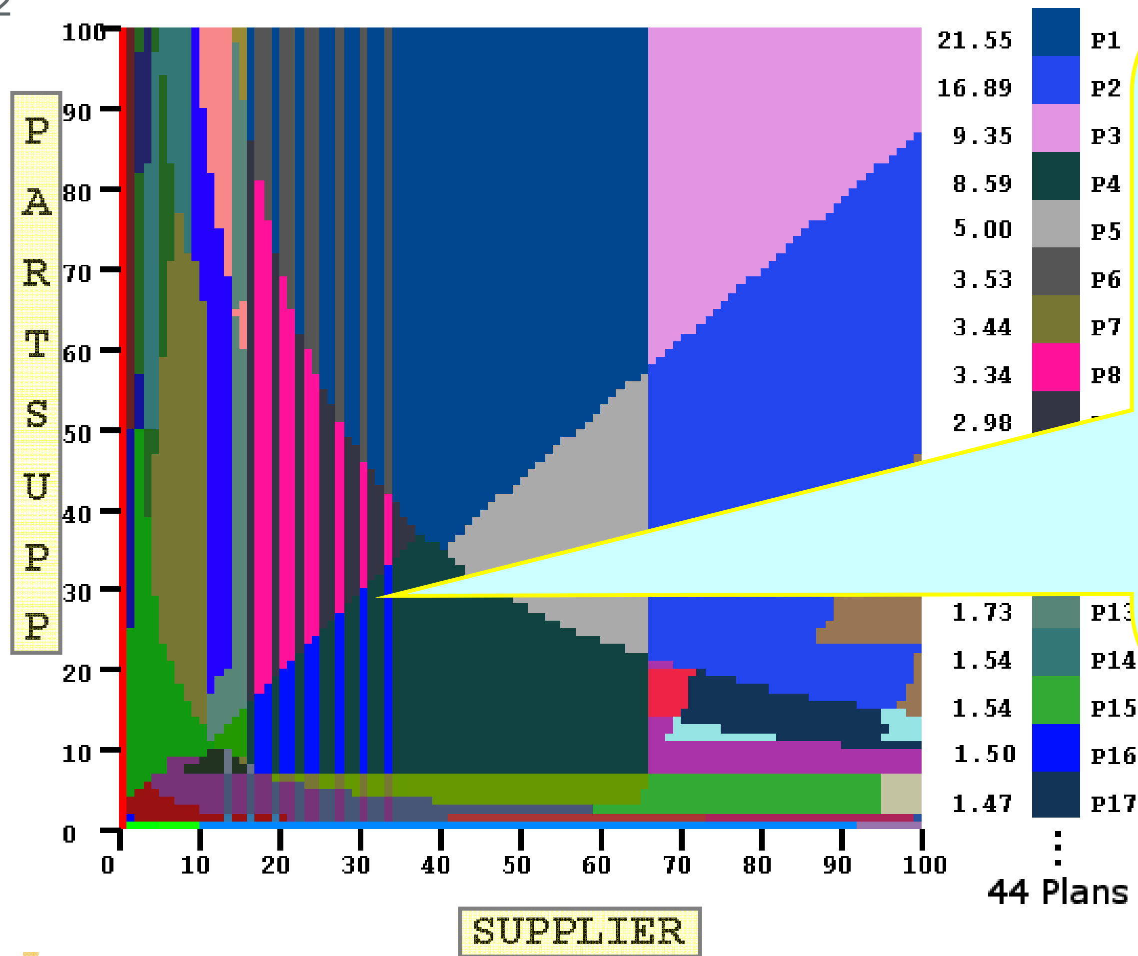


Six plans simultaneously change with rapid alternations to produce a "Venetian blinds" effect.

Left-deep hash join across NATION, SUPPLIER and LINEITEM relations gets replaced by a right-deep hash join.

Slides: Naveen Reddy und Jayant Haritsa: "*Analyzing Plan Diagrams of Database Query Optimizers*"; VLDB 2005

# Footprint Pattern [Q7, Opt A]



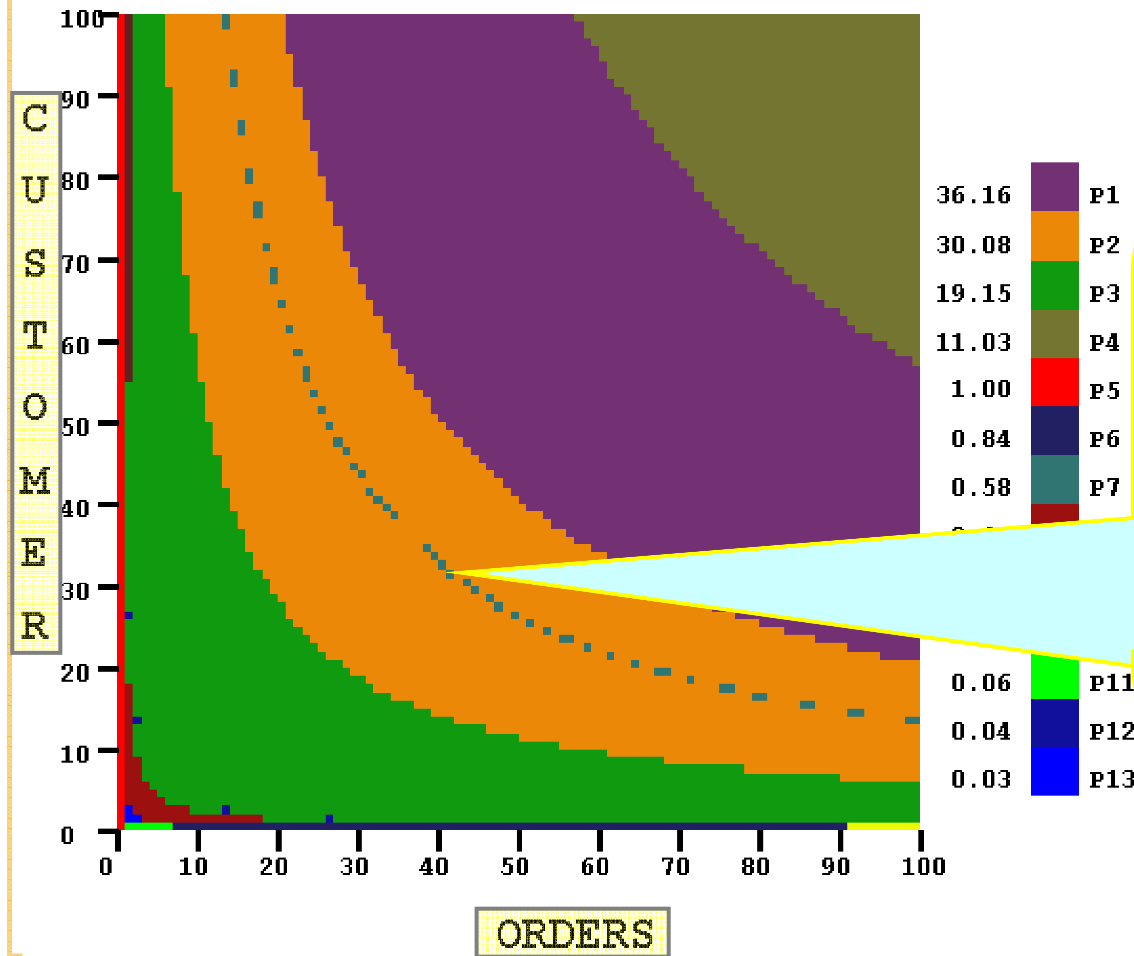


P7 exhibits a thin broken curved pattern in the middle of P2's region.

P2 has sort-merge-join at the top of the plan tree, while P7 has hash-join

Slides: Naveen Reddy und Jayant Haritsa: "*Analyzing Plan Diagrams of Database Query Optimizers*"; VLDB 2005

## Speckle Pattern [Q17, Opt A*]



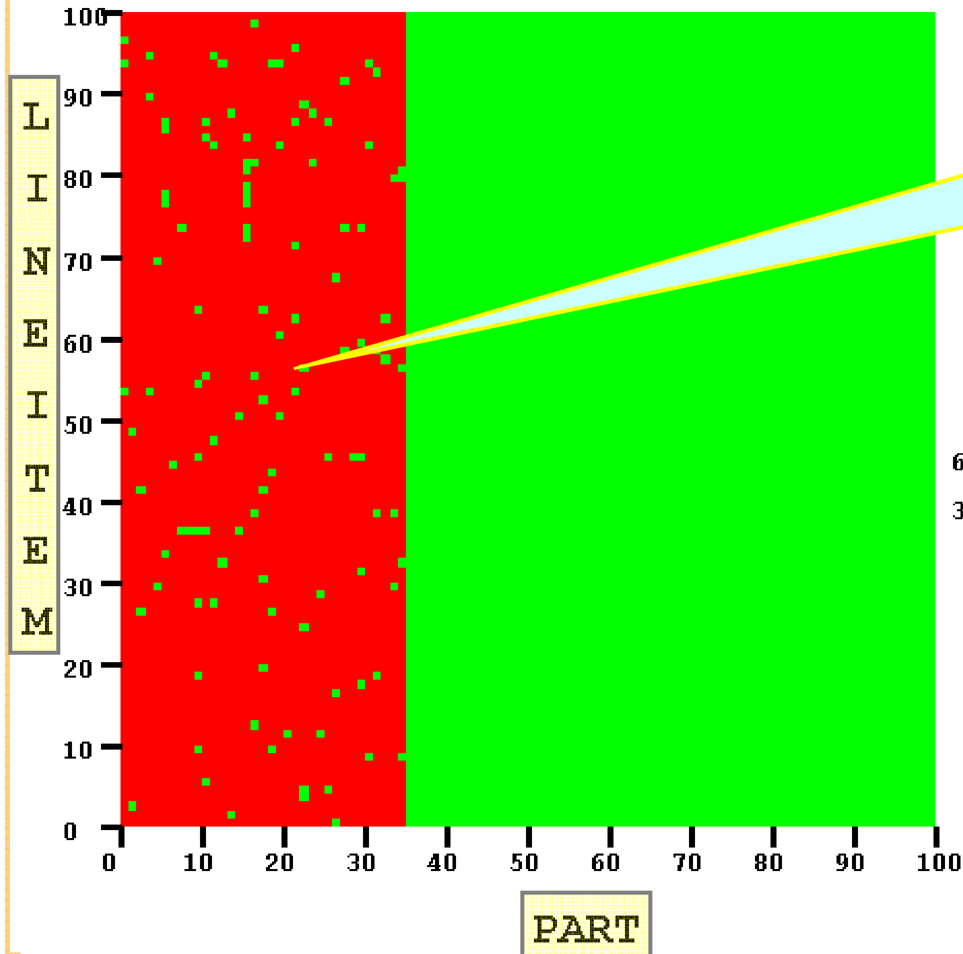


An additional sort operation is present on PART relation in P2, whose cost is very low

Slides: Naveen Reddy und Jayant Haritsa: "*Analyzing Plan Diagrams of Database Query Optimizers*"; VLDB 2005

# Plan-Switch Non-Monotonic Costs [Q2, Opt A]



Presence of Rules?

Parameterized changes in search space?

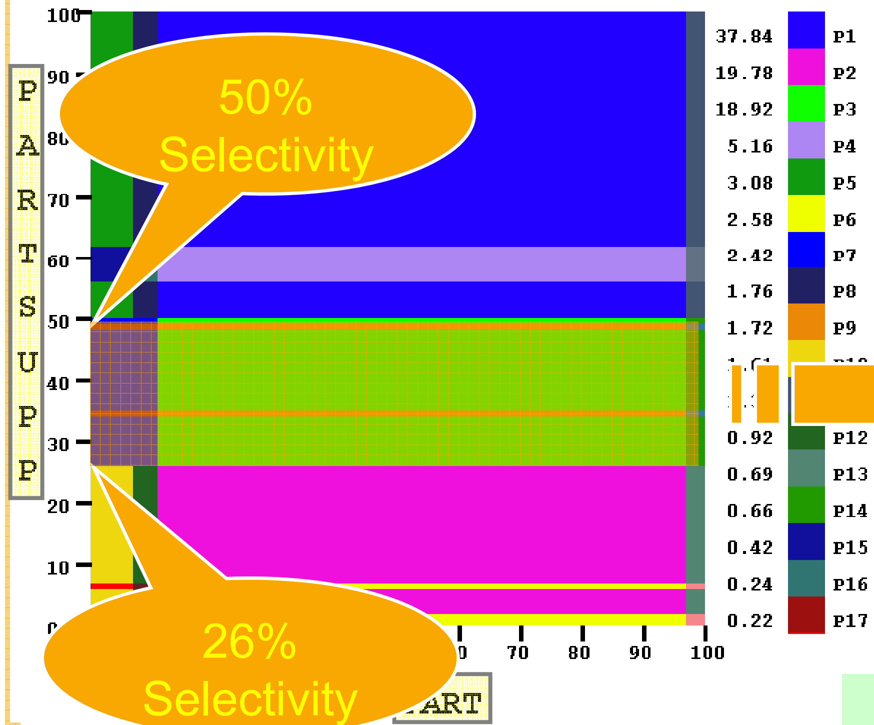


Plan Diagram

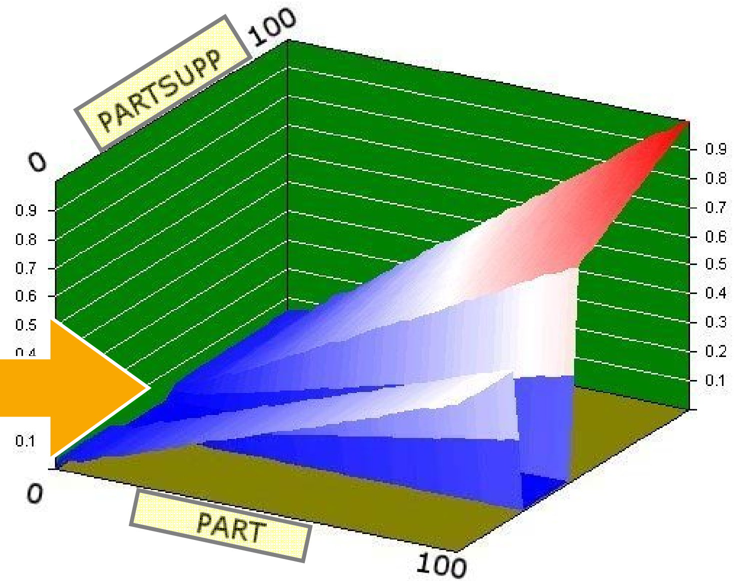


26%: Cost decreases by a factor of *50*

50%: Cost increases by a factor of *70*

Slides: Naveen Reddy und Jayant Haritsa: "*Analyzing Plan Diagrams of Database Query Optimizers*"; VLDB 2005

# Intra-Plan Non-Monotonic Costs [Q21, Opt A]



Plans P1, P3, P4 and P6

*Nested loops join whose cost decreases with increasing input cardinalities*

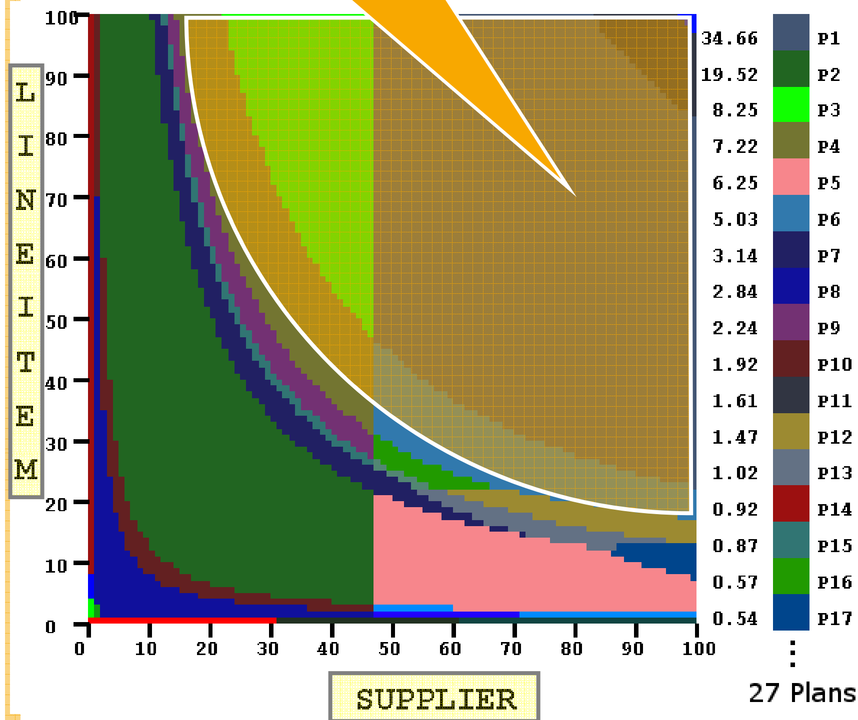


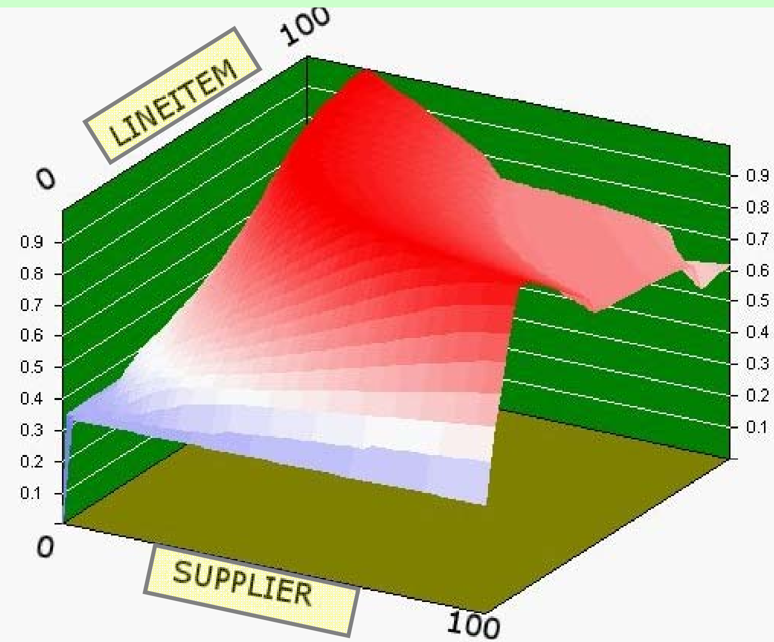


Plan Diagram

Cost Diagram

Slides: Naveen Reddy und Jayant Haritsa: "*Analyzing Plan Diagrams of Database Query Optimizers*"; VLDB 2005