


Übung Datenbanksysteme II

Anfrageoptimierung

Maximilian Jenders

Folien basierend auf
Thorsten Papenbrock



Hausaufgaben 3 + 4

2

- Praktische Übung: Feedback, Probleme?
 - Java-Aufgabe
 - Picasso-Aufgabe
 - Stabilität des Programms

Aufgabe 1: Ausführungsstrategien

Betrachte die Relation $R(a, b, c, d)$, die 1 Million Tupel enthält. Nimm an, dass das Attribut a Schlüsselkandidat für R ist und die Werte von a zwischen 0 und 999.999 liegen. Jeder Block der Relation R fasst 10 Tupel. Außerdem sind die Tupel in R nicht sortiert.

Benenne für jede der folgenden Anfragen diejenige Ausführungsstrategie, die die wahrscheinlich wenigsten I/Os für die Bearbeitung der Anfrage benötigt. Begründe deine Antwort durch Angabe der I/Os für *alle* Ausführungsstrategien. Die beiden aufgeführten Indexe existieren bereits und müssen nicht für eine Anfrage neu angelegt werden. Sie liegen allerdings auf der Festplatte, so dass für genutzte Index-Strukturen ebenfalls I/O-Kosten anfallen. Falls nötig, triff geeignete Annahmen bzgl. benötigter Parameter und deren Werte!

Die zu betrachtenden Ausführungsstrategien sind:

- Scannen der kompletten Relation R .
- Nutzen eines B+-Baum-Indexes für $R.a$.
- Nutzen eines Hash-Indexes für $R.a$.

Die Anfragen sind:

- | | |
|--|-----|
| a) Finde alle Tupel aus R . | 3 P |
| b) Finde alle Tupel aus R mit $a < 50$. | 3 P |
| c) Finde alle Tupel aus R mit $a = 50$. | 3 P |
| d) Finde alle Tupel aus R mit $a > 50$ und $a < 100$. | 3 P |

Hausaufgabe 4:

Aufgabe 1

4

- Berechnung der I/O Kosten vom Hash-Index war größte Fehlerquelle
- B+Baum gab auch einige Fehler (z.B. Auslesen des gesamten Baumes bei den Bereichsanfragen statt Suche nach dem ersten Element und anschließendes Traversieren)
- Schlüsselkandidat != Schlüssel!

Hausaufgabe 4: Aufgabe 1

Strategie	R	R, a<50	R, a=50	R, 50<a<100
Full Scan	$10^6/B$ $=10^5$	$10^6/B$ $=10^5$	$10^6/B$ $=10^5$	$10^6/B$ $=10^5$
B ⁺ -Baum	$(h-1)+10^6/M+10^6$ $\approx 10^6$	$(h-1)+50/M+50$ ≈ 50	$(h-1)+1+1$ ≈ 3	$(h-1)+50/M+49$ ≈ 49
Hash-Index	$10^6/(N*c)+10^6$ $\approx 10^6$	$50+50$ $=100$	$1+1$ $=2$	$49+49$ $=98$

- B: #Tupel/Block (=10)
- M: #Schlüssel-Pointer-Pare/Blatt-Block (>10)
- h: Höhe des B⁺-Baums
- N: #Daten-Pointer/Hash-Block (>10)
- c: Füllgrad eines Hash-Blocks

▪ Warum?

6

- Aufgabenstellung nicht richtig gelesen oder falsch verstanden
- Berechnung von Werten wurde nicht angegeben, sondern es gab plötzliche magische Werte, mit denen die richtige Lösung ermittelt werden konnte

Aufgabe 2: Sort-Merge Join-Algorithmus

- 2b) Gegeben sind zwei Relationen $R(\underline{A}, B)$ und $S(\underline{A}, C)$. Die Tupel in R umfassen $2^{13} = 8.192$ Blöcke und die Tupel in S umfassen $2^{10} = 1.024$ Blöcke. Für die Berechnung von $R \bowtie S$ können insgesamt $2^7 = 128$ Blöcke des Hauptspeichers genutzt werden.
 - a) Wie viele sortierte Teillisten entstehen in der ersten Phase des Two-Phase Multiway Merge-Sort (TPMMS) bei der Sortierung von R ? Wie viele für S ? 2 P
 - b) Wie viele Blöcke müsste eine der beiden Eingaberelationen *mindestens* umfassen, damit die Sortierung mittels des TPMMS *nicht* mehr möglich ist? 2 P

Eine Sortierung mit TPMMS ist dann nicht mehr möglich, wenn nicht von jeder Teilliste mindestens ein Block plus ein Outputblock in den Hauptspeicher passt. Das ist der Fall, wenn $B(R)/M > M-1 \Leftrightarrow x/2^7 > 2^7-1 \Leftrightarrow x > 2^{14} - 2^7 = 16.256$, also wenn eine Relation 16.257 oder mehr Blöcke umfasst.

Hausaufgabe 4: Aufgabe 3

7

- A3:
 - Es wurde angenommen, dass die Formeln des Hybrid Hash Joins anwendbar sind
 - Der Hash Join wurde noch nicht (gut) verstanden, insbesondere die Unterscheidung zwischen Hashen und Joinen und die Auswirkungen auf die Bucket-Anzahl
 - Erläuterungen/Begründungen waren unvollständig

Hausaufgabe 4: Aufgabe 3

8

- Grundalgorithmus
- Gegeben M Speicherblöcke, verteile R auf $M-1$ Buckets
 - Möglichst gleicher Größe
 - Ein Bucket pro Speicherblock
- Letzter Speicherblock für Einlesen der Tupel aus R

- Idee
 - Für jedes Tupel aus R berechne $h(t)$ und bewege Tupel in entsprechenden Bucket.
 - Falls Block voll: Schreibe als Overflowblock auf Disk
 - Am Ende: Schreibe auch alle Buckets auf Disk

Hausaufgabe 4: Aufgabe 3

9

Hashjoin

- Algorithmus wie zuvor
- Aber: Hashschlüssel sind Joinattribute
 - Tupel mit gleichen Joinattributwerten landen im korrespondierenden Bucket.
- Danach One-pass Join Variante für jedes Bucket-Paar
- Beispiel von zuvor: $B(R) = 1000$, $B(S) = 500$, $M = 101$
- Hashing
 - Ca. 10 R-Blocks pro Bucket
 - Ca. 5 S-Blocks pro Bucket
- $\text{Min}(10, 5) = 5 \Rightarrow$ One-pass Algorithmus klappt ($5 < 101$)
 - Hole ersten S-Bucket in Hauptspeicher;
 - Joine Blöcke des passenden R-Buckets hinzu
 - Hole nächsten S-Bucket in Hauptspeicher ... usw ...
- I/O-Kosten:
 - 1500 für das Hashing + 1500 um Buckets zu schreiben
 - 1500 um Buckets zu lesen
 - Zusammen: $3(B(R) + B(S)) = 4500$ (wie sort-basierte Methode)

Aber es geht noch besser.

Hausaufgabe 4: Aufgabe 3

10

I/O Einsparungen

Grundidee: Nutze nicht-verwendeten Speicher

- Idee 1: Verwende mehr als 1 Speicherblock pro Bucket
 - Effizienteres Schreiben (aber gleiche I/O-Kosten)
- Idee 2: Hybrid Hashjoin
 - Beim Hashen von S : Behalte m Buckets komplett im Speicher
 - Auch nach Ende des Hashens
 - Jeweils mit geeigneter Datenstruktur

Hausaufgabe 4:

Aufgabe 4

11

- A4:
 - Indizes können benutzt werden, um weniger I/O-Kosten zu erreichen.
 - Kostenmodelle mit 1 I/O pro Tupel und 1 I/O pro Block gemischt ohne zu erklären weshalb

Zu Hausaufgabe 3: Aufgabe 4

- SpieltMit vollständig lesen
- ‚King Kong‘-Titel selektieren
- Über Index die Schauspieler suchen
- ‚w‘-Geschlechter selektieren

```
SELECT *  
FROM SpieltMit  
WHERE M.name =  
AND titel='King Kong'
```

Die angefragten Relationen

```
SpieltMit (titel,  
Schauspieler (name,  
Schlechte
```

In Relationaler Algebra lässt sich die Anfrage

```
 $\sigma_{\text{titel}='KingKong'}(\text{SpieltMit}) \bowtie$ 
```

Nimm an, dass beide Relationen jeweils etwa 10.000 Zeilen und es ein Index auf Schauspieler.name gibt.

Vergleiche die I/O-Kosten eines Index-basierten, eines Sort-basierten und eines Hash-basierten Joins für die gegebene Anfrage. Falls nötig, triff geeignete Annahmen bzgl. der Parameter der einzelnen Join-Implementierungen (z.B. Blockgrößen). Wähle für jede Join-Variante außerdem die jeweils optimale Ausführungsreihenfolge von Selektionen und Join. Welche Algorithmus-Klasse sollte die Datenbank hier wählen?

Implementierung

Die Schauspielerinnen des Films 'King Kong' sucht:


- SpieltMit vollständig lesen
- ‚King Kong‘-Titel selektieren
- Ergebnis sortieren/hashieren
- Schauspieler vollständig lesen
- ‚w‘-Geschlechter selektieren
- Ergebnis sortieren/hashieren
- Joinen

13

- Algebraische Transformation



- Kardinalitätsschätzung



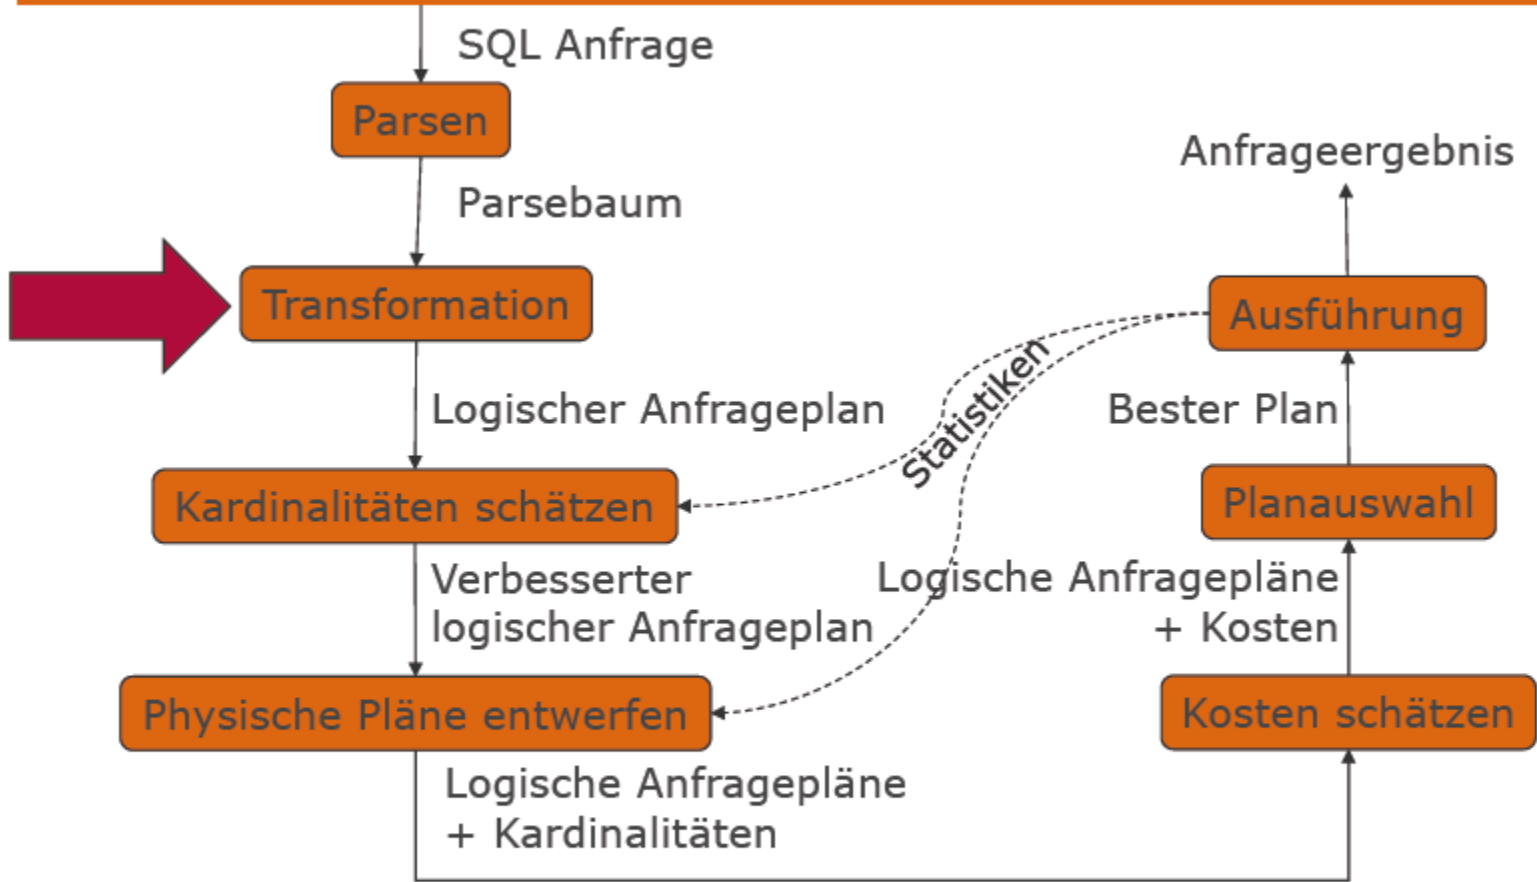
- Join-Reihenfolge



Recap: Algebraische Transformation

Ablauf der Anfragebearbeitung

14



Recap: Algebraische Transformation

15

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

Recap: Algebraische Transformation

16

- \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

- $\sigma_{c_1 \text{ AND } c_2}(R) = \sigma_{c_1}(\sigma_{c_2}(R))$
- $\sigma_{c_1 \text{ OR } c_2}(R) = \sigma_{c_1}(R) \cup \sigma_{c_2}(R)$
 - Nicht bei Multimengen
- $\sigma_{c_1}(\sigma_{c_2}(R)) = \sigma_{c_2}(\sigma_{c_1}(R))$
- $\sigma_c(R \Phi S) \equiv (\sigma_c(R)) \Phi (\sigma_c(S))$
 - $\Phi \in \{\cup, \cap, -, \bowtie\}$
- $\sigma_c(R \Phi S) \equiv (\sigma_c(R)) \Phi S$
 - $\Phi \in \{\cup, \cap, -, \bowtie\}$
 - Falls sich c nur auf Attribute in R bezieht.

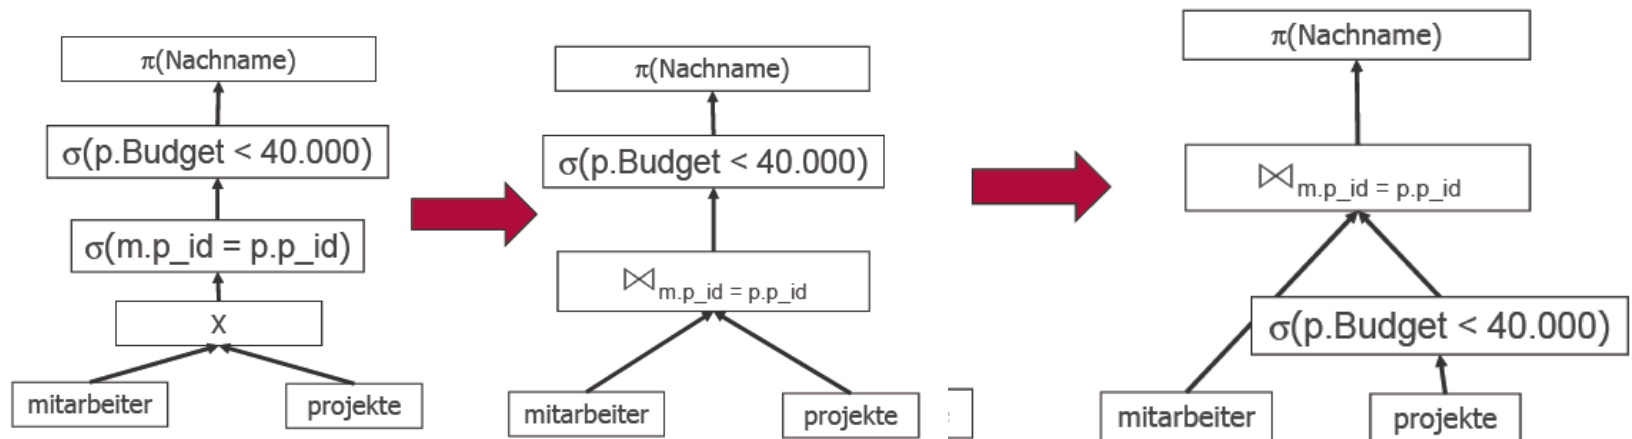
Projektion

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

Recap: Algebraische Transformation

18

Anfragebearbeitung – Beispiel



- Gegeben: $R(a,b,c)$ und $S(c,d,e)$
- Gesucht: Kostengünstigste Anfragepläne für folgende Anfragen

d.h. möglichst kleine Zwischenergebnisse, also Selektionen und Projektionen so früh wie möglich

a. $\sigma_{b=3 \wedge e=4 \wedge c>10} (R \bowtie S)$

$$\sigma_{c>10} (\sigma_{b=3} (R) \bowtie \sigma_{e=4} (S))$$

b. $\pi_{a,d} (R \bowtie S)$


$$\pi_{a,d} (\pi_{a,c} (R) \bowtie \pi_{c,d} (S))$$

20

- Algebraische Transformation



- Kardinalitätsschätzung



- Join-Reihenfolge



Kosten von Operationen - Zwischenergebnisse

- 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 Kostenmodell schätzt u.a. für jede Operation die Anzahl der Ausgabebetupel.
 - „Selektivität“ in Bezug auf Inputgröße
 - $\# \text{Ausgabebetupel} = \# \text{Eingabetupel} \times \text{Selektivität}$
 - Auch „Selektivitätsfaktor“ (*selectivity factor, sf*)

22 Kostenschätzung – Selektion

- 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 Spalte A
 - D.h. selectivity factor ist $1/V(R,A)$
 - 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

Kostenschätzung – Selektion mit Disjunktion

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

- $\Rightarrow T(S) = n \left(1 - \left(1 - \frac{m_1}{n}\right) \left(1 - \frac{m_2}{n}\right)\right)$

Anteil Tupel, die nicht
C1 entsprechen

Anteil Tupel, die nicht
C2 entsprechen

- Gegeben: $R(a,b,c,d)$ und $S(d,e)$
 $T(R)=100$; $V(R,a)=100$; $V(R,b)=10$; $V(R,c)=1$; $V(R,d)=50$
 $T(S)=500$; $V(S,d)=30$; $V(S,e)=100$

- Gesucht: Geschätzte Ergebniskardinalität für folgende Anfragen

a. $\sigma_{b=25}(R)$

$$T(R)/V(R,b) = 10$$

b. $\sigma_{c=30}(R)$

$$T(R)/V(R,c) = 100$$

c. $\sigma_{b=25 \wedge c=30}(R)$

$$T(R)/(V(R,b) \cdot V(R,c)) = 10$$

d. $\sigma_{b>25}(R)$

$$T(R)/3 \approx 33$$

e. $\sigma_{a>30 \wedge b=10}(R)$

$$T(R)/(3 \cdot V(R,b)) \approx 3$$

f. $\sigma_{b>25 \wedge b=11}(R)$

$$0 \text{ (widersprüchliche Selektion)}$$

g. $\sigma_{b=25 \vee d=13}(R)$

$$T(R)/V(R,b) + T(R)/V(R,d) - T(R)/(V(R,b) \cdot V(R,d)) = 11,8 \approx 12$$

h. $R \bowtie S$


$$T(R) \cdot T(S) / \max[V(R,d), V(S,d)] = 1000$$

25

- Algebraische Transformation



- Kardinalitätsschätzung



- Join-Reihenfolge



Recap: Kardinalitätsschätzung bei Join

26

Kostenschätzung – Join

- Hier nur natural join
 - Equijoin analog
 - Thetajoin: „<“, „>“, usw: Wie zuvor schätzen. Z.B. $1/3 T(R) \cdot 1/3 T(S)$
- $R(X,Y) \bowtie S(Y,Z)$
 - Vereinfachende Annahme: Y ist nur ein 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 alle 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 $V(R,Y) \leq V(S,Y) \Rightarrow$ 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?

Recap: Kardinalitätsschätzung bei Join

27

Kostenschätzung – Join

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

Recap: Kardinalitätsschätzung bei Join

28

Kostenschätzung – Join

- $R(X,Y) \bowtie S(Y,Z)$
 - Y enthält mehr als ein Attribut
 - Schreibweise hier: $R(X,Y_1, Y_2) \bowtie S(Y_1, Y_2, Z)$
- $T(R \bowtie S) = T(R) \cdot T(S) / (\max[V(R,Y_1),V(S,Y_1)] \cdot \max[V(R,Y_2),V(S,Y_2)])$
- Allgemein
 - Ergebniskardinalität von $R \bowtie S$ entspricht dem Produkt der Kardinalitäten von R und S, dividiert durch das Produkt des jeweils größeren von $V(R,Y)$ und $V(S,Y)$ **für jedes** Join-Attribut Y.

Aufgabe 3: Join-Reihenfolge

29

- Gegeben: Folgende Relationen und deren Statistiken

$W(A, B)$	$X(B, C)$	$Y(C, D)$	$Z(D, A)$
$T(W) = 100$	$T(X) = 200$	$T(Y) = 300$	$T(Z) = 400$
$V(W, A) = 20$			$V(Z, A) = 100$
$V(W, B) = 60$	$V(X, B) = 50$		
	$V(X, C) = 100$	$V(Y, C) = 50$	
		$V(Y, D) = 50$	$V(Z, D) = 40$

- Gesucht: Optimale Join-Reihenfolge für $W \bowtie X \bowtie Y \bowtie Z$
- Bestimme die Join-Reihenfolge als Left Deep Tree. Nutze dazu Dynamische Programmierung und gib die Tabellen aller Zwischenschritte an.

Aufgabe 3: Join-Reihenfolge

$W(A,B)$	$X(B,C)$	$Y(C,D)$	$Z(D,A)$
$T(W) = 100$	$T(X) = 200$	$T(Y) = 300$	$T(Z) = 400$
$V(W,A) = 20$			$V(Z,A) = 100$
$V(W,B) = 60$	$V(X,B) = 50$	$V(Y,C) = 50$	
	$V(X,C) = 100$	$V(Y,D) = 50$	$V(Z,D) = 40$

30

	{W}	{X}	{Y}	{Z}
Kardinalität	100	200	300	400
Kosten	0	0	0	0
Opt. Plan	W	X	Y	Z

Kleinste Relation links

	{W,X}	{W,Y}	{W,Z}	{X,Y}	{X,Z}	{Y,Z}
Kard.	$100 \cdot 200$ $/60 =$ 33333	$100 \cdot 300$ $=$ 30000	$100 \cdot 400$ $/100 =$ 400	$200 \cdot 300$ $/100 =$ 600	$200 \cdot 400$ $=$ 80000	$300 \cdot 400$ $/50 =$ 2400
Kosten	0	0	0	0	0	0
Opt. Plan	$W \bowtie X$	$W \bowtie Y$	$W \bowtie Z$	$X \bowtie Y$	$X \bowtie Z$	$Y \bowtie Z$

Aufgabe 3: Join-Reihenfolge

$W(A,B)$	$X(B,C)$	$Y(C,D)$	$Z(D,A)$
$T(W) = 100$	$T(X) = 200$	$T(Y) = 300$	$T(Z) = 400$
$V(W,A) = 20$			$V(Z,A) = 100$
$V(W,B) = 60$	$V(X,B) = 50$	$V(Y,C) = 50$	
	$V(X,C) = 100$	$V(Y,D) = 50$	$V(Z,D) = 40$

31

	$\{W,X\}$	$\{W,Y\}$	$\{W,Z\}$	$\{X,Y\}$	$\{X,Z\}$	$\{Y,Z\}$
Kard.	$100 \cdot 200$ $/60 =$ 333,33	$100 \cdot 300$ $=$ 30000	$100 \cdot 400$ $/100 =$ 400	$200 \cdot 300$ $/100 =$ 600	$200 \cdot 400$ $=$ 80000	$300 \cdot 400$ $/50 =$ 2400
Kosten	0	0	0	0	0	0
Opt. Plan			$W \bowtie Z$	$X \bowtie Y$	$X \bowtie Z$	$Y \bowtie Z$

Kardinalität ist für alle möglichen Joinreihenfolgen gleich!

Kosten: (Kardinalität + Kosten des Zwischenergebniss)

	$\{W,X,Y\}$	$\{W,X,Z\}$	$\{W,Y,Z\}$	$\{X,Y,Z\}$
Kardinalität	$333,33 \cdot 300$ $/100 =$ 1000	$333,33 \cdot 400$ $/100 =$ 1333,33	$400 \cdot 300$ $/50 =$ 2400	$600 \cdot 400$ $/50 =$ 4800
Kosten	333,33	333,33	400	600
Opt. Plan	$(W \bowtie X) \bowtie Y$	$(W \bowtie X) \bowtie Z$	$(W \bowtie Z) \bowtie Y$	$(X \bowtie Y) \bowtie Z$

Aufgabe 3: Join-Reihenfolge

$W(A,B)$	$X(B,C)$	$Y(C,D)$	$Z(D,A)$
$T(W) = 100$	$T(X) = 200$	$T(Y) = 300$	$T(Z) = 400$
$V(W,A) = 20$			$V(Z,A) = 100$
$V(W,B) = 60$	$V(X,B) = 50$	$V(Y,C) = 50$	
	$V(X,C) = 100$	$V(Y,D) = 50$	$V(Z,D) = 40$

32

	$\{W,X\}$	$\{W,Y\}$	$\{W,Z\}$	$\{X,Y\}$	$\{X,Z\}$	$\{Y,Z\}$
Kard.	$100 \cdot 200 / 60 = 333,33$	$100 \cdot 300 = 30000$	$100 \cdot 400 / 100 = 400$	$200 \cdot 300 / 100 = 600$	$200 \cdot 400 = 80000$	$300 \cdot 400 / 50 = 2400$
Kosten	0	0	0	0	0	0
Opt. Plan	$W \bowtie X$	$W \bowtie Y$	$W \bowtie Z$	$X \bowtie Y$	$X \bowtie Z$	$Y \bowtie Z$

	$\{W,X,Y\}$	$\{W,X,Z\}$	$\{W,Y,Z\}$	$\{X,Y,Z\}$
Kardinalität	$333,33 \cdot 300 / 100 = 1000$	$333,33 \cdot 400 / 100 = 1333,33$	$400 \cdot 300 / 50 = 2400$	$600 \cdot 400 / 50 = 4800$
Kosten	333,33	333,33	400	600
Opt. Plan	$(W \bowtie X) \bowtie Y$	$(W \bowtie X) \bowtie Z$	$(W \bowtie Z) \bowtie Y$	$(X \bowtie Y) \bowtie Z$

Aufgabe 3: Join-Reihenfolge

$W(A,B)$	$X(B,C)$	$Y(C,D)$	$Z(D,A)$
$T(W) = 100$	$T(X) = 200$	$T(Y) = 300$	$T(Z) = 400$
$V(W,A) = 20$			$V(Z,A) = 100$
$V(W,B) = 60$	$V(X,B) = 50$	$V(Y,C) = 50$	
	$V(X,C) = 100$	$V(Y,D) = 50$	$V(Z,D) = 40$

33

	$\{W,X,Y\}$	$\{W,X,Z\}$	$\{W,Y,Z\}$	$\{X,Y,Z\}$
Kardinalität	$333,33 \cdot 300$ /100 = 1000	$333,33 \cdot 400$ /100 = 1333,33	$400 \cdot 300$ /50 = 2400	$600 \cdot 400$ /50 = 4800
Kosten	333,33	333,33	400	600
Opt. Plan	$(W \bowtie X) \bowtie Y$	$(W \bowtie X) \bowtie Z$	$(W \bowtie Z) \bowtie Y$	$(X \bowtie Y) \bowtie Z$

	$\{W,X,Y,Z\}$	$\{W,X,Y,Z\}$	$\{W,X,Y,Z\}$	$\{W,X,Y,Z\}$
Kard.	$1000 \cdot 400$ /(100·50) = 80	$1333,33 \cdot 300$ /(100·50) = 80	$2400 \cdot 200$ /(100·60) = 80	$4800 \cdot 100$ /(100·60) = 80
Kosten	1333,33	1666,66	2800	5400
Plan	$((W \bowtie X) \bowtie Y) \bowtie Z$	$((W \bowtie X) \bowtie Z) \bowtie Y$	$((W \bowtie Z) \bowtie Y) \bowtie X$	$((X \bowtie Y) \bowtie Z) \bowtie W$



34

X(a,b)	Y(a,b)	Z(a,b)
T(X)=100	T(Y)=200	T(Z)=300
V(X,a)=10	V(Y,a)=20	V(Z,a)=30
V(X,b)=3	V(Y,b)=2	V(Z,b)=1

$$X \bowtie Y = 100 \cdot 200 / (20 \cdot 3) = 333,33$$

$$(X \bowtie Y) \bowtie Z = 333,33 \cdot 300 / (30 \cdot \mathbf{2}) = 1666,66$$

- *Preservation of Value Sets* gilt nicht, wenn das Attribut ein Join-Attribut war!
- Wegen *Containment of Value Sets* wissen wir aber, dass nach dem Join $V(X \bowtie Y, a) = 10$ und $V(X \bowtie Y, b) = 2$ sein müssen.

Allgemein:

$$X \bowtie Y \bowtie Z = T(X) \cdot T(Y) \cdot T(Z) / [V(Y,a) \cdot V(Z,a)] \cdot [V(X,b) \cdot V(Y,b)]$$

Für jedes Join-Attribut teile durch alle Kardinalitäten außer der Kleinsten!