Datenbanken 2

Anfragebearbeitung

Nikolaus Augsten
nikolaus.augsten@sbg.ac.at
FB Computerwissenschaften
Universität Salzburg

http://dbresearch.uni-salzburg.at

WS 2020/21

Version 6. Oktober 2021

Inhalt

Literatur und Quellen

Lektüre zum Thema "Anfragebearbeitung":

- Kapitel 8 aus Kemper und Eickler: Datenbanksysteme: Eine Einführung. Oldenbourg Verlag, 2013.
- Chapter 12 in Silberschatz, Korth, and Sudarashan: Database System Concepts. McGraw Hill, 2011.

Danksagung Die Vorlage zu diesen Folien wurde entwickelt von:

- Michael Böhlen, Universität Zürich, Schweiz
- Johann Gamper, Freie Universität Bozen, Italien

Inhalt

PostgreSQL Beispiel/1

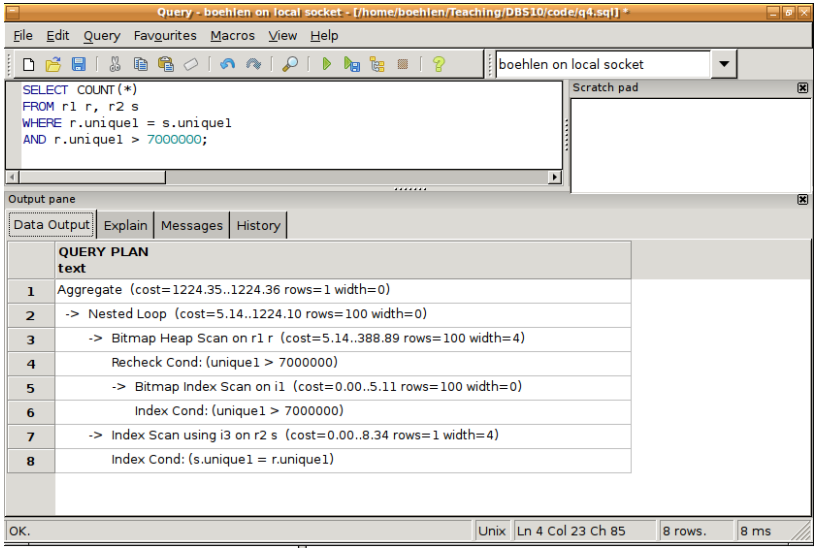

PostgreSQL Beispiel/2

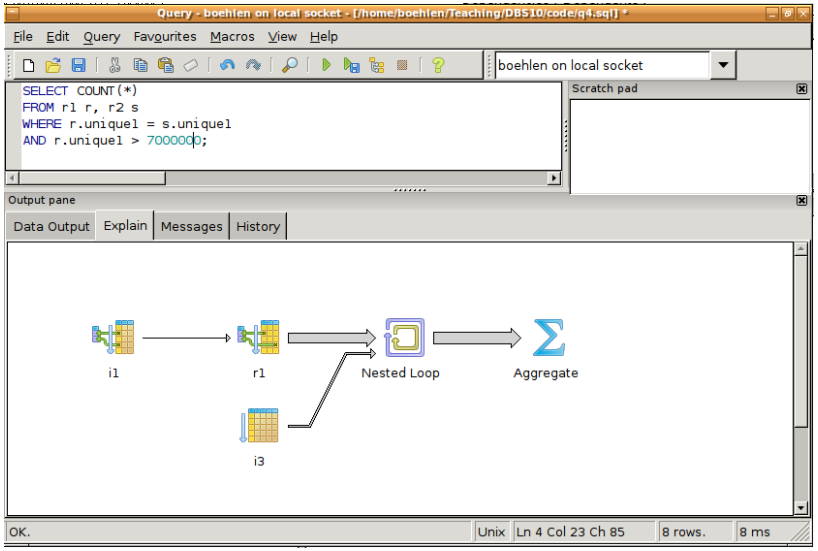

Anfragebearbeitung

- Effizienter Auswertungsplan gehört zu den wichtigsten Aufgaben eines DBMS.
- 3 Schritte der Anfragebearbeitung:

1. **Parsen und übersetzen**
   (von SQL in Rel. Alg.)
2. **Optimieren**
   (Auswertungsplan erstellen)
3. **Auswerten**
   (Auswertungsplan ausführen)

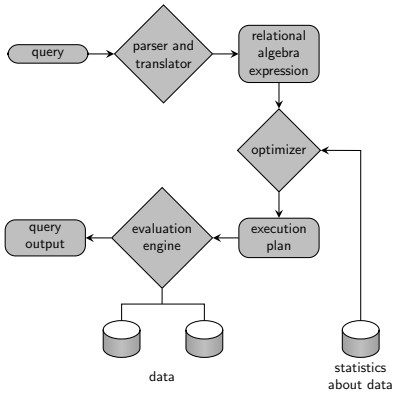

Inhalt

Anfragekosten/1

- Anfragekosten werden als gesamte benötigte Zeit verstanden.
- Mehrere Faktoren tragen zu den Anfragekosten bei:
  - CPU
  - Netzwerk Kommunikation
  - Plattenzugriff
    - sequentielles I/O
    - random I/O
  - Puffergröße
- Puffergröße:
  - mehr Puffer-Speicher (RAM) reduziert Anzahl der Plattenzugriffe
  - verfügbarer Puffer-Speicher hängt von anderen OS Prozessen ab und ist schwierig von vornherein festzulegen
  - wir verwenden oft worst-case Anschätzung mit der Annahme, dass nur der mindest nötige Speicher vorhanden ist

Anfragekosten/2

- Plattenzugriff macht größten Teil der Kosten einer Anfrage aus.
- Kosten für Plattenzugriff relativ einfach abzuschätzen als Summe von:
  - Anzahl der Spurwechsel * mittlere Spurwechselzeit (avg. seek time)
  - Anzahl der Block-Lese-Operationen * mittlere Block-lese-Zeit
  - Anzahl der Block-Schreib-Operationen * mittlere Block-schreib-Zeit
    - → Block schreiben ist teuerer als lesen, weil geschriebener Block zur Kontrolle nochmal gelesen wird.
- Zur Vereinfachung
  - zählen wir nur die Anzahl der Schreib-/Lese-Operationen
  - berücksichtigen wir nicht die Kosten zum Schreiben des Ergebnisses auf die Platte

Inhalt

Sorting

- Sortieren ist eine wichtige Operation:
  - SQL-Anfragen können explizit eine sortierte Ausgabe verlangen
  - mehrere Operatoren (z.B. Joins) können effizient implementiert werden, wenn die Relationen sortiert sind
  - oft ist Sortierung der entscheidende erste Schritt für einen effizienten Algorithmus
- Sekundärindex für Sortierung verwenden?
  - Index sortiert Datensätze nur logisch, nicht physisch.
  - Datensätze müssen über Pointer im Index zugegriffen werden.
  - Für jeden Pointer (Datensatz) muss möglicherweise ein eigener Block von der Platte gelesen werden.
- Algorithmen je nach verfügbarer Puffergröße:
  - Relation kleiner als Puffer: Hauptspeicher-Algorithmen wie **Quicksort**
  - Relation größer als Puffer: Platten-Algorithmen wie **Mergesort**

Externes Merge-Sort/1

- Grundidee:
  - **teile** Relation in Stücke (Läufe, *runs*) die in den Puffer passen
  - **sortiere** jeden Lauf im Puffer und schreibe ihn auf die Platte
  - **mische** sortierte Läufe so lange, bis nur mehr ein Lauf übrig ist
- Notation:
  - b: Anzahl der Plattenblöcke der Relation
  - M: Anzahl der Blöcke im Puffer (Hauptspeicher)
  - $N = \lceil b/M \rceil$: Anzahl der Läufe

Externes Merge-Sort/2

- Schritt 1: erzeuge N Läufe
  1. starte mit $i = 0$
  2. wiederhole folgende Schritte bis Relation leer ist:
     a. lies M Blöcke der Relation (oder den Rest) in Puffer
     b. sortiere Tupel im Puffer
     c. schreibe sortierte Daten in Lauf-Datei L_i
     d. erhöhe i
- Schritt 2: mische Läufe (N-Wege-Mischen) (Annahme $N < M$)
  (N Blöcke im Puffer für Input, 1 Block für Output)
  1. lies ersten Block jeden Laufs L_i in Puffer Input Block i
  2. wiederhole bis alle Input Blöcke im Puffer leer sind:
     a. wähle erstes Tupel in Sortierordnung aus allen nicht-leeren Input Blöcken
     b. schreibe Tupel auf Output Block
        – falls der Block voll ist, schreibe ihn auf die Platte
     c. lösche Tupel vom Input Block
        – falls Block i leer ist, lies nächsten Block des Laufs L_i

Externes Merge-Sort/3

- Falls $N \geq M$, werden mehrere Misch-Schritte (Schritt 2) benötigt.
- Pro Durchlauf...
  - werden jeweils $M - 1$ Läufe gemischt
  - wird die Anzahl der Läufe um Faktor $M - 1$ reduziert
  - werden die Läufe um den Faktor $M - 1$ größer
- Durchläufe werden wiederholt bis nur mehr ein Lauf übrig ist.
- Beispiel: Puffergröße $M = 11$, Anzahl Blocks $b = 1100$
  - $N = \lceil b/M \rceil = 100$ Läufe à 11 Blocks werden erzeugt
  - nach erstem Durchlauf: 10 Läufe à 110 Blocks
  - nach zweitem Durchlauf: 1 Lauf à 1100 Blocks

Externes Merge-Sort/4

- Beispiel: M = 3, 1 Block = 1 Tupel

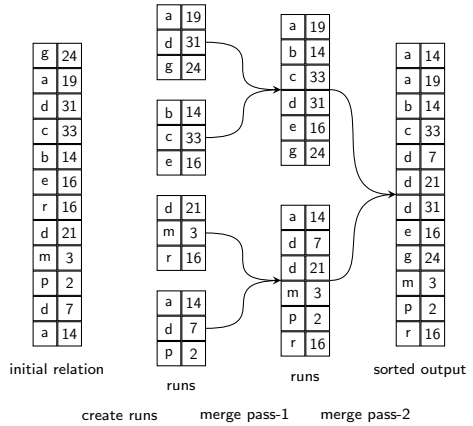

Externes Merge-Sort/5

- Kostenanalyse:
  - b: Anzahl der Blocks in Relation R
  - anfängliche Anzahl der Läufe: b/M
  - gesamte Anzahl der Misch-Durchläufe: $\lceil log_{M-1}(b/M) \rceil$
    - $\rightarrow$ die Anzahl der Läufe sinkt um den Faktor $M-1$ pro Misch-Durchlauf
  - Plattenzugriffe für Erzeugen der Läufe und für jeden Durchlauf: $2 * b$
    - $\rightarrow$ Ausnahme: letzter Durchlauf hat keine Schreibkosten
- Kosten für externes Merge-Sort: Anzahl der gelesenen oder geschriebenen Blöcke

$$Kosten = b(2\lceil log_{M-1}(b/M) \rceil + 1)$$

- Beispiel: Kostenanalyse für voriges Beispiel:
  - $M = 3, b = 12$
  - $12 * (2 * \lceil \log_2(12/3) \rceil + 1) = 60$ Schreib-/Lese-/Operationen

Inhalt

Auswertung der Selektion/1

- Der Selektionsoperator:
  - **select** * **from** R **where** θ
  - $\sigma_\theta(R)$

  berechnet die Tupel von R welche das Selektionsprädikat (=Selektionsbedingung) θ erfüllen.
- Selektionsprädikat θ ist aus folgenden Elementen aufgebaut:
  - Attributnamen der Argumentrelation R oder Konstanten als Operanden
  - arithmetische Vergleichsoperatoren ($=$, $<$, $>$)
  - logische Operatoren: $\wedge$ (**and**), $\vee$ (**or**), $\neg$ (**not**)
- Strategie zur Auswertung der Selektion hängt ab
  - von der Art des Selektionsprädikats
  - von den verfügbaren Indexstrukturen

Auswertung der Selektion/2

Grundstrategien für die Auswertung der Selektion:

- Sequentielles Lesen der Datei (file scan):
  - Klasse von Algorithmen welche eine Datei Tupel für Tupel lesen um jene Tupel zu finden, welche die Selektionsbedingung erfüllen
  - grundlegendste Art der Selektion
- Index Suche (index scan):
  - Klasse von Algorithmen welche einen Index benutzen um eine Vorauswahl von Tupeln zu treffen
  - Beispiel: B^+-Baum Index auf A und Gleichheitsbedingung: $\sigma_{A=5}(R)$

Auswertung der Selektion/3

Arten von Prädikaten:

- Gleichheitsanfrage: $\sigma_{A=V}(R)$
- Bereichsanfrage: $\sigma_{A<V}(R)$ oder $\sigma_{A>V}(R)$
- Konjunktive Selektion: $\sigma_{\theta_1 \wedge \theta_2 \cdots \wedge \theta_n}(\mathrm{R})$
- Disjunktive Selektion: $\sigma_{\theta_1 \vee \theta_2 \cdots \vee \theta_n}(\mathrm{R})$

Auswertung der Selektion/4

A1 Lineare Suche: Lies jeden einzelnen Block der Datei und überprüfe jeden Datensatz ob er die Selektionsbedingung erfüllt.

- Ziemlich teuer, aber immer anwendbar, unabhängig von:
  - (nicht) vorhandenen Indexstrukturen
  - Sortierung der Daten
  - Art der Selektionsbedingung
- Hintereinanderliegende Blöcke lesen wurde von den Plattenherstellern optimiert und ist schnell hinsichtlich Spurwechsel und Latenz (pre-fetching)
- Kostenabschätzung (b = Anzahl der Blöcke in der Datei):
  - Worst case: $\mathit{Cost} = b$
  - Selektion auf Kandidatenschlüssel: $\mathit{Mittlere\ Kosten} = b/2$ (Suche beenden, sobald erster Datensatz gefunden wurde)

Auswertung der Selektion/5

A2 Binäre Suche: verwende binäre Suche auf Blöcken um Tupel zu finden, welche Bedingung erfüllen.

- Anwendbar falls
  - die Datensätze der Tabelle physisch sortiert sind
  - die Selektionsbedingung auf dem Sortierschlüssel formuliert ist
- Kostenabschätzung für $\sigma_{A=C}(R)$:
  - $\lfloor log_2(b) \rfloor + 1$: Kosten zum Auffinden des ersten Tupels
  - plus Anzahl der weiteren Blöcke mit Datensätzen, welche Bedingung erfüllen (diese liegen alle nebeneinander in der Datei)

Auswertung der Selektion/6

Annahme: Index ist B^+-Baum mit H Ebenen[1]

A3 Primärindex + Gleichheitsbedingung auf Suchschlüssel

- gibt einen einzigen Datensatz zurück
- $\mathit{Kosten} = H + 1$ (Knoten im B^+-Baum + 1 Datenblock)

A3 Clustered Index + Gleichheitsbedingung auf Suchschlüssel

- gibt mehrere Datensätze zurück
- alle Ergebnisdatensätze liegen hintereinander in der Datei
- $\mathit{Kosten} = H + \#\ \mathit{Blöcke\ mit\ Ergebnisdatensätzen}$

[1] $H \leq \lceil \log_{\lceil m/2 \rceil}(L) \rceil + 1$ für B$^+$-Baum mit L Blattknoten

Auswertung der Selektion/7

A5 Sekundärindex + Gleichheitsbedingung auf Suchschlüssel

- Suchschlüssel ist Kandidatenschlüssel
  - gibt einen einzigen Datensatz zurück
  - $Kosten = H + 1$
- Suchschlüssel ist nicht Kandidatenschlüssel[2]
  - mehrere Datensätze werden zurückgeliefert
  - $Kosten =$ $(H-1) + \#\ Blattknoten\ mit\ Suchschlüssel + \#\ Ergebnisdatensätze$
  - kann sehr teuer sein, da jeder Ergebnisdatensatz möglicherweise auf einem anderen Block liegt
  - sequentielles Lesen der gesamten Datei möglicherweise billiger

[2] Annahme: TIDs werden an Suchschlüssel angehängt, um diese im B^+-Baum eindeutig zu machen; die Erweiterung um TIDs ist für Benutzer nicht sichtbar.

Auswertung der Selektion/8

A6 Primärindex auf A + Bereichsanfrage

- $\sigma_{A>V}(R)$: verwende Index um ersten Datensatz $> V$ zu finden, dann sequentielles Lesen
- $\sigma_{A<V}(R)$: lies sequentiell bis erstes Tupel $\geq V$ gefunden; Index wird nicht verwendet

A7 Sekundärindex auf A + Bereichsanfrage

- $\sigma_{A>V}(R)$: finde ersten Datensatz $> V$ mit Index; Index sequentiell lesen um alle Pointer zu den entsprechenden Datensätzen zu finden; Pointer verfolgen und Datensätze holen
- $\sigma_{A<V}(R)$: Blätter des Index sequentiell lesen und Pointer verfolgen bis Suchschlüssel $\geq V$
- Pointer verfolgen braucht im schlimmsten Fall eine Lese-/Schreib-Operation pro Datensatz; sequentielles Lesen der gesamten Datei möglicherweise schneller

Auswertung der Selektion/9

- Pointer verfolgen in Sekundärindex:
  - jeder Datensatz liegt möglicherweise auf einem anderen Block
  - Pointer sind nicht nach Block-Nummern sortiert
  - das führt zu Random-Zugriffen quer durch die Datei
  - derselbe Block wird möglicherweise sogar öfters gelesen
  - falls Anzahl der Ergebnisdatensätze $\geq b$, dann wird im Worst Case jeder Block der Relation gelesen
- Bitmap Index Scan: hilft bei großer Anzahl von Pointern
  - Block i wird durch i-tes Bit in Bit Array der Länge b repräsentiert
  - statt Pointer im Index zu verfolgen, wird nur das Bit des entsprechenden Blocks gesetzt
  - dann werden alle Blöcke gelesen, deren Bit gesetzt ist
  - ermöglicht teilweise sequentielles Lesen
  - gut geeignet, falls Suchschlüssel kein Kandidatenschlüssel ist

Integrierte Übung 3.1

Was ist die beste Auswertungsstrategie für folgende Selektion, wenn es einen B^+-Baum Sekundärindex auf $(BrName, BrCity)$ auf der Relation $Branch(\underline{BrName}, \underline{BrCity}, Assets)$ gibt?

$$\sigma_{BrCity<'Brighton'\ \wedge\ Assets<5000\ \wedge\ BrName='Downtown'}(Branch)$$

Inhalt

Join Operator/1

- Theta-Join: $r \bowtie_\theta s$
  - für jedes Paar von Tupeln $t_r \in r$, $t_s \in s$ wird Join-Prädikat θ überprüft
  - falls Prädikat erfüllt, ist $t_r \circ t_s$ im Join-Ergebnis
  - Beispiel: Relationen $r(a, b, c)$, $s(d, e, f)$
    Join-Prädikat: $(a < d) \wedge (b = d)$
    Schema des Join-Ergebnisses: (a, b, c, d, e, f)
- Equi-Join: Prädikat enthält "=" als einzigen Operator
- Natürlicher Join: $r \bowtie s$
  - Equi-Join, bei dem alle Attribute gleichgesetzt werden die gleich heißen
  - im Ergebnis kommt jedes Attribut nur einmal vor
  - Beispiel: Relationen $r(a, b, c)$, $s(c, d, e)$
    Natürlicher Join $r \bowtie s$ entspricht θ-Equi-Join $\pi_{a,b,c,d,e}(r \bowtie_{r.c=s.c} s)$
    Schema des Ergebnisses: (a, b, c, d, e)

Join Operator/2

- Join ist kommutativ (bis auf Ordnung der Attribute):

$$r \bowtie s = \pi(s \bowtie r)$$

  - Ordnung der Attribute wird durch (logisches) Vertauschen der Spalten (Projektion π) wiederhergestellt und ist praktisch kostenlos
- Join ist assoziativ:

$$(r \bowtie s) \bowtie t = r \bowtie (s \bowtie t)$$

- Effizienz der Auswertung:
  - vertauschen der Join-Reihenfolge ändert zwar das Join-Ergebnis nicht
  - die Effizienz kann jedoch massiv beeinflusst werden!
- Benennung der Relationen: $r \bowtie s$
  - r die äußere Relation
  - s die innere Relation

Join Selektivität

- Kardinalität: absolute Größe des Join Ergebnisses $r \bowtie_\theta s$

$$|r \bowtie_\theta s|$$

- Selektivität: relative Größe des Join Ergebnisses $r \bowtie_\theta s$

$$sel_\theta = \frac{|r \bowtie_\theta s|}{|r \times s|}$$

- schwache Selektivität: Werte nahe bei 1 (viele Tupel im Ergebnis)
- starke Selektivität: Werte nahe bei 0 (wenig Tupel im Ergebnis)

Integrierte Übung 3.2

Gegeben Relationen $R1(\underline{A}, B, C)$, $R2(\underline{C}, D, E)$, $R3(\underline{E}, F)$, Schlüssel unterstrichen, mit Kardinalitäten $|R1| = 1000$, $|R2| = 1500$, $|R3| = 750$.

- Schätzen Sie die Kardinalität des Joins $R1 \bowtie R2 \bowtie R3$ ab (die Relationen enthalten keine Nullwerte).
- Geben Sie eine Join-Reihenfolge an, welche möglichst kleine Joins erfordert.
- Wie könnte der Join effizient berechnet werden?

Join Operator/3

- Es gibt verschiedene Algorithmen um einen Join auszuwerten:
  - Nested Loop Join
  - Block Nested Loop Join
  - Indexed Nested Loop Join
  - Merge Join
  - Hash Join
- Auswahl aufgrund einer Kostenschätzung.
- Wir verwenden folgende Relationen in den Beispielen:
  - Anleger = (AName, Stadt, Strasse)
    - Anzahl der Datensätze: $n_a = 10'000$
    - Anzahl der Blöcke: $b_a = 400$
  - Konten = (AName, KontoNummer, Kontostand)
    - Anzahl der Datensätze: $n_k = 5'000$
    - Anzahl der Blöcke: $b_k = 100$

Nested Loop Join/1

- Nested Loop Join Algorithms: berechne Theta-Join $r \bowtie_\theta s$

```
for each tuple t_r in r do
  for each tuple t_s in s do
    if (t_r, t_s) erfüllt Join-Bedingung θ then
      gib t_r ∘ t_s aus
  end
end
```

- Immer anwendbar:
  - für jede Art von Join-Bedingung θ anwendbar
  - kein Index erforderlich
- Teuer da jedes Tupel des Kreuzproduktes ausgewertet wird

Nested Loop Join/2

- Ordnung der Join Argumente relevant:
  - r wird 1x gelesen, s wird bis zu n_r mal gelesen
- Worst case: $M = 2$, nur 1 Block von jeder Relation passt in Puffer
  $Kosten = b_r + n_r * b_s$
- Best case: $M > b_s$, innere Relation passt vollständig in Puffer (+1 Block der äußeren Relation)
  $Kosten = b_r + b_s$
- Beispiel:
  - Konten $\bowtie$ Anleger: $M = 2$
    $b_k + n_k * b_a = 100 + 5'000 * 400 = 2'000'100$ Block Zugriffe
  - Anleger $\bowtie$ Konten: $M = 2$
    $b_a + n_a * b_k = 400 + 10'000 * 100 = 1'000'400$ Block Zugriffe
  - Kleinere Relation *(Konten)* passt in Puffer: $M > b_k$
    $b_a + b_k = 400 + 100 = 500$ Block Zugriffe
- Einfacher Nested Loop Algorithms wird nicht verwendet da er nicht Block-basiert arbeitet.

Block Nested Loop Join/1

- Block Nested Loop Join vergleicht jeden Block von r mit jedem Block von s.
- Algorithmus für $r \bowtie_\theta s$

for each Block B_r **of** r **do**
  for each Block B_s **of** s **do**
    for each Tuple t_r **in** B_r **do**
      for each Tuple t_s **in** B_s **do**
        if (t_r, t_s) erfüllt Join-Bedingung θ **then**
          gib $t_r \circ t_s$ aus

Block Nested Loop Join/2

- Worst case: $M = 2$, $Kosten = b_r + b_r * b_s$
  - Jeder Block der inneren Relation s wird für jeden Block der äußeren Relation einmal gelesen (statt für jedes Tupel der äußeren Relation)
- Best case: $M > b_s$, $Kosten = b_r + b_s$
- Beispiel:
  - Konten $\bowtie$ Anleger: $M = 2$
    $b_k + b_k * b_a = 100 + 100 * 400 = 40'100$ Block Zugriffe
  - Anleger $\bowtie$ Konten: $M = 2$
    $b_a + b_a * b_k = 400 + 400 * 100 = 40'400$ Block Zugriffe
  - Kleinere Relation *(Konten)* passt in Puffer: $M > b_k$
    $b_a + b_k = 400 + 100 = 500$ Block Zugriffe

Block Nested Loop Join/3

- Zick-Zack Modus: $R \bowtie_\theta S$
  - reserviere $M - k$ Blöcke für R und k Blöcke für S
  - innere Relation wird abwechselnd vorwärts und rückwärts durchlaufen
  - dadurch sind die letzten k Seiten schon im Puffer (LRU Puffer Strategie) und müssen nicht erneut gelesen werden
- Kosten: $k \leq b_s, 0 < k < M$

$$b_r + k + \lceil b_r/(M-k) \rceil (b_s - k)$$

  - r muss einmal vollständig gelesen werden
  - innere Schleife wird $\lceil b_r/(M-k) \rceil$ mal durchlaufen
  - erster Durchlauf erfordert b_s Block Zugriffe
  - jeder weitere Durchlauf erfordert $b_s - k$ Block Zugriffe
- Optimale Ausnutzung des Puffers:
  - $b_r \leq b_s$: kleinere Relation außen (Heuristik)
  - $k = 1$: $M - 1$ Blöcke für äußere Relation, 1 Block für innere

Integrierte Übung 3.3

Berechne die Anzahl der Block Zugriffe für folgende Join Alternativen, jeweils mit Block Nested Loop Join, Puffergröße $M = 20$.
Konto: $n_k = 5'000$, $b_k = 100$. Anleger: $n_a = 10'000$, $b_a = 400$

- Konto $\bowtie$ Anleger, $k = 19$
- Konto $\bowtie$ Anleger, $k = 10$
- Konto $\bowtie$ Anleger, $k = 1$
- Anleger $\bowtie$ Konto, $k = 1$

Indexed Nested Loop Join/1

- Index Suche kann Scannen der inneren Relation ersetzen
  - auf innerer Relation muss Index verfügbar sein
  - Index muss für Join-Prädikat geeignet sein (z.B. Equi-Join)
- Algorithmus: Für jedes Tupel t_r der äußeren Relation r verwende den Index um die Tupel der inneren Relation zu finden, welche die Bedingung θ erfüllen.
- Worst case: für jedes Tupel der äußeren Relation wird eine Index Suche auf die innere Relation gemacht.
  $Kosten = b_r + n_r * c$
  - c sind die Kosten, den Index zu durchlaufen und alle passenden Datensätze aus der Relation s zu lesen
  - c kann durch die Kosten einer einzelnen Selektion mithilfe des Index abgeschätzt werden
- Index auf beiden Relationen: kleinere Relation außen

Indexed Nested Loop Join/2

- Beispiel: Berechne Konten ⋈ Anleger (Konten als äußere Relation), B^+-Baum mit $m = 20$ auf Relation Anleger.
- Lösung:
  - Anleger hat $n_a = 10'000$ Datensätze.
  - Kosten für 1 Datensatz von Relation Anleger mit Index lesen:

$$c = \lceil \log_{\lceil m/2 \rceil}(L) \rceil + 2 = \lceil \log_{\lceil m/2 \rceil}(\lceil \frac{n_a}{\lceil \frac{m-1}{2} \rceil} \rceil) \rceil + 2 = 5$$

    → B^+-Baum durchlaufen: maximale Pfadlänge + 1
    → 1 Zugriff auf Datensatz (Schlüssel)
  - Konten hat $n_k = 5'000$ Datensätze und $b_k = 100$ Blöcke.
  - Indexed Nested Loop Join:
    Kosten $= b_k + n_k * c = 100 + 5'000 * 5 = 25'100$ Blockzugriffe

Merge Join/1

- Merge Join: Verwende zwei Pointer pr und ps die zu Beginn auf den ersten Datensatz der sortierten Relationen r bzw. s zeigen und bewege die Zeiger synchron, ähnlich wie beim Mischen, nach unten.
- Algorithmus: $r \bowtie s$ (Annahme: keine Duplikate in Join-Attributen)
  1. sortiere Relationen nach Join-Attributen (falls nicht schon richtig sortiert)
  2. starte mit Pointern bei jeweils 1. Tupel
  3. aktuelles Tupel-Paar ausgeben falls es Join-Bedingung erfüllen
  4. bewege den Pointer der Relation mit dem kleineren Wert; falls die Werte gleich sind, bewege den Pointer der äußeren Relation

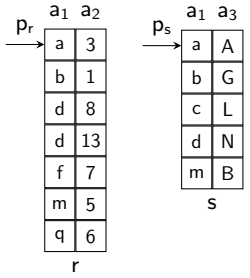

- Duplikate in den Join-Attributen: bei gleichen Werten muss jede Kopie der äußeren mit jeder Kopie der inneren Relation gepaart werden

Merge Join/2

- Anwendbar nur für Equi- und Natürliche Joins
- Kosten: Falls alle Tupel zu einem bestimmten Join-Wert im Puffer Platz haben:
  - r und s 1x sequentiell lesen
  - $Kosten = b_r + b_s$ (+ Sortierkosten, falls Relationen noch nicht sortiert)
- Andernfalls muss ein Block Nested Loop Join zwischen den Tupeln mit identischen Werten in den Join-Attributen gemacht werden.
- Sort-Merge Join: Falls Relationen noch nicht sortiert sind, muss zuerst sortiert werden.

Hash Join/1

- Nur für Equi- und Natürliche Joins.
- Partitioniere Tupel von r und s mit derselben Hash Funktion h, welche die Join-Attribute ($JoinAttrs$) auf die Menge $\{0, 1, \ldots, n\}$ abbildet.
- Alle Tupel einer Relation mit demselben Hash-Wert bilden eine Partition (=Bucket):
  - Partition r_i enthält alle Tupel $t_r \in r$ mit $h(t_r[JoinAttrs]) = i$
  - Partition s_i enthält alle Tupel $t_s \in s$ mit $h(t_s[JoinAttrs]) = i$

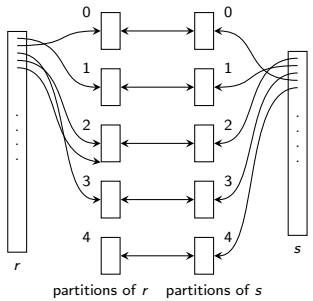

- Partitionsweise joinen: Tupel in r_i brauchen nur mit Tupel in s_i verglichen werden
  - ein r-Tupel und ein s-Tupel welche die Join-Kondition erfüllen, haben denselben Hash-Wert i und werden in die Partitionen r_i bzw. s_i gelegt

Hash Join/2

- Algorithmus für Hash Join $r \bowtie s$.
  1. Partitioniere r und s mit derselben Hash Funktion h; jede Partition wird zusammenhängend auf die Platte geschrieben
  2. Für jedes Paar (r_i, s_i) von Partitionen:
     a. build: lade s_i in den Hauptspeicher und baue einen Hauptspeicher-Hash-Index mit neuer Hash-Funktion $h' \neq h$.
     b. probe: für jedes Tupel $t_r \in r_i$ suche zugehörige Join-Tupel $t_s \in s_i$ mit Hauptspeicher-Hash-Index.
- Relation s wird Build Input genannt; r wird Probe Input genannt.
- Kleinere Relation (in Anzahl der Blöcke) wird als Build Input verwendet, damit weniger Partitionen benötigt werden.
  - Hash-Index für jede Partition des Build Input muss in Hauptspeicher passen ($M - 1$ Blöcke für Puffergröße M)
  - von Probe Input brauchen wir jeweils nur 1 Block im Speicher

Hash Join/3

- Kosten für Hash Join:
  - Partitionieren der beiden Relationen: $2 * (b_r + b_s)$
    $\rightarrow$ jeweils gesamte Relation einlesen und zurück auf Platte schreiben
  - Build- und Probe-Phase lesen jede Relation genau einmal: $b_r + b_s$
  - $Kosten = 3 * (b_r + b_s)$
  - Kosten von nur teilweise beschriebenen Partitionen werden nicht berücksichtigt.

Hash Join/4

Beispiel: $Konto \bowtie Anleger$ soll als Hash Join berechnet werden.
Puffergröße $M = 20$ Blöcke, $b_k = 100$, $b_a = 400$.

- Welche Relation wird als Build Input verwendet?
  Konto, da kleiner ($b_k < b_a$)
- Wieviele Partitionen müssen gebildet werden?
  $\lceil \frac{b_k}{M-1} \rceil = 6$ Partitionen, damit Partitionen von Build Input in Puffer ($M - 1 = 19$) passen. Partitionen von Probe Input müssen nicht in Puffer passen: es wird nur je ein Block eingelesen.
- Wie groß sind die Partitionen?
  Build Input: $\lceil 100/6 \rceil = 17$, Probe Input: $\lceil 400/6 \rceil = 67$
- Kosten für Join?
  $3(b_k + b_a) = 1'500$ laut Formel. Da wir aber nur ganze Blöcke schreiben können, sind die realen Kosten etwas höher:
  $b_k + b_a + 2 * (6 * 17 + 6 * 67) = 1'508$

Rekursives Partitionieren

- Eine Relation kann höchstens in $M-1$ Partitionen zerlegt werden:
  - 1 Input-Block
  - $M-1$ Output Blocks (1 Block pro Partition)
- Partitionen der Build-Relation (b Blöcke) müssen in Speicher passen
  - Build-Partition darf maximal $M-1$ Blöcke haben
    $\Rightarrow$ Anzahl der Partitionen mindestens $\lceil \frac{b}{M-1} \rceil$
- Build-Relation könnte zu groß für maximale Partitionen-Anzahl sein:
  - falls $\lceil \frac{b}{M-1} \rceil > M-1$ können nicht genug Partitionen erzeugt werden
- Rekursives Partitionieren:
  - erzeuge $M-1$ Partitionen (r_i, s_i), $1 \leq i < M$
  - partitioniere jedes Paar (r_i, s_i) rekursiv (mit einer neuen Hash-Funktion), bis Build-Partition in Hauptspeicher passt
  - (r_i, s_i) wird also behandelt wie zwei Relationen

Overflows/1

- Overflow: Build Partition passt nicht in den Hauptspeicher
  - kann auch vorkommen, wenn es sich von der Größe der Build-Relation her ausgehen müsste (d.h. $\lceil \frac{b}{M-1} \rceil \leq M-1$)
- Overflows entstehen durch verschieden große Partitionen:
  - einige Werte kommen viel häufiger vor oder
  - die Hashfunktion ist nicht uniform und random
- Fudge Factor:
  - etwas mehr als $\lceil \frac{b}{M-1} \rceil$ Partitionen (z.B. 20% mehr) werden angelegt
  - dadurch werden kleine Unterschiede in der Partitionsgröße abgefedert
  - hilft nur bis zu einem gewissen Grad
- Lösungsansätze
  - Overflow Resolution
  - Overflow Avoidance

Overflows/2

- Overflow Resolution: während der Build-Phase
  - falls Build-Partition s_i zu groß: partitioniere Probe- und Build-Partition (r_i, s_i) erneut bis Build-Partition in Speicher passt
  - für erneutes Partitionieren muss neue Hashfunktion verwendet werden
  - selbe Technik wie rekursives Partitionieren
    (es wird jedoch aufgrund unterschiedlicher Partitionsgrößen neu partitioniert, nicht wegen der Größe der Build-Relation)
- Overflow Avoidance: während des Partitionierens
  - viele kleine Partitionen werden erzeugt
  - während der Build-Phase werden so viele Partitionen wie möglich in den Hauptspeicher geladen
  - die entsprechenden Partitionen in der anderen Relation werden für das Probing verwendet
- Wenn alle Stricke reißen...
  - wenn einzelne Werte sehr häufig vorkommen versagen beide Ansätze
  - Lösung: Block-Nested Loop Join zwischen Probe- und Build-Partition

Zusammenfassung

- Nested Loop Joins:
  - Naive NL: ignoriert Blöcke
  - Block NL: berücksichtigt Blöcke
  - Index NL: erfordert Index auf innere Relation
- Equi-Join Algorithmen:
  - Merge-Join: erfordert sortierte Relationen
  - Hash-Join: keine Voraussetzung