Hasso Plattner Institut

IT Systems Engineering | Universität Potsdam

Datenbanksysteme II
Anfrageausführung
(Kapitel 15)

2.6.2008

Felix Naumann

Zoom in die interne Ebene: Die 5-Schichten Architektur

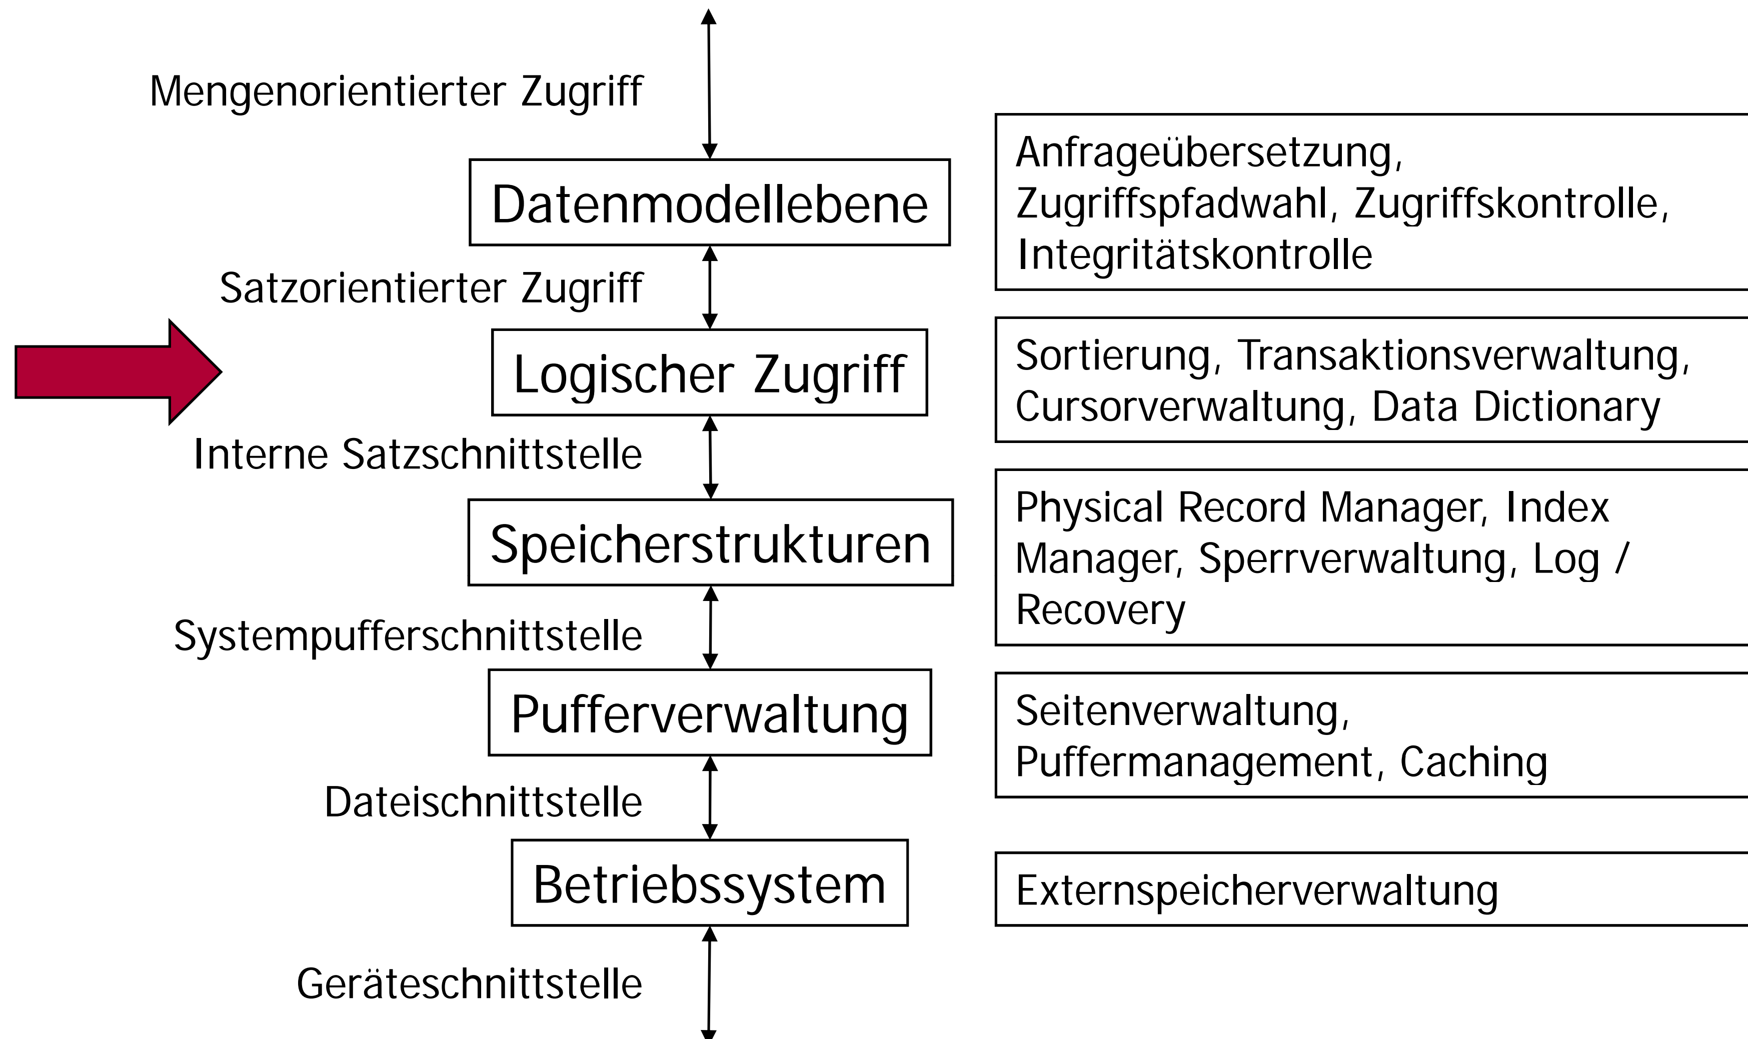

Ablauf der Anfragebearbeitung

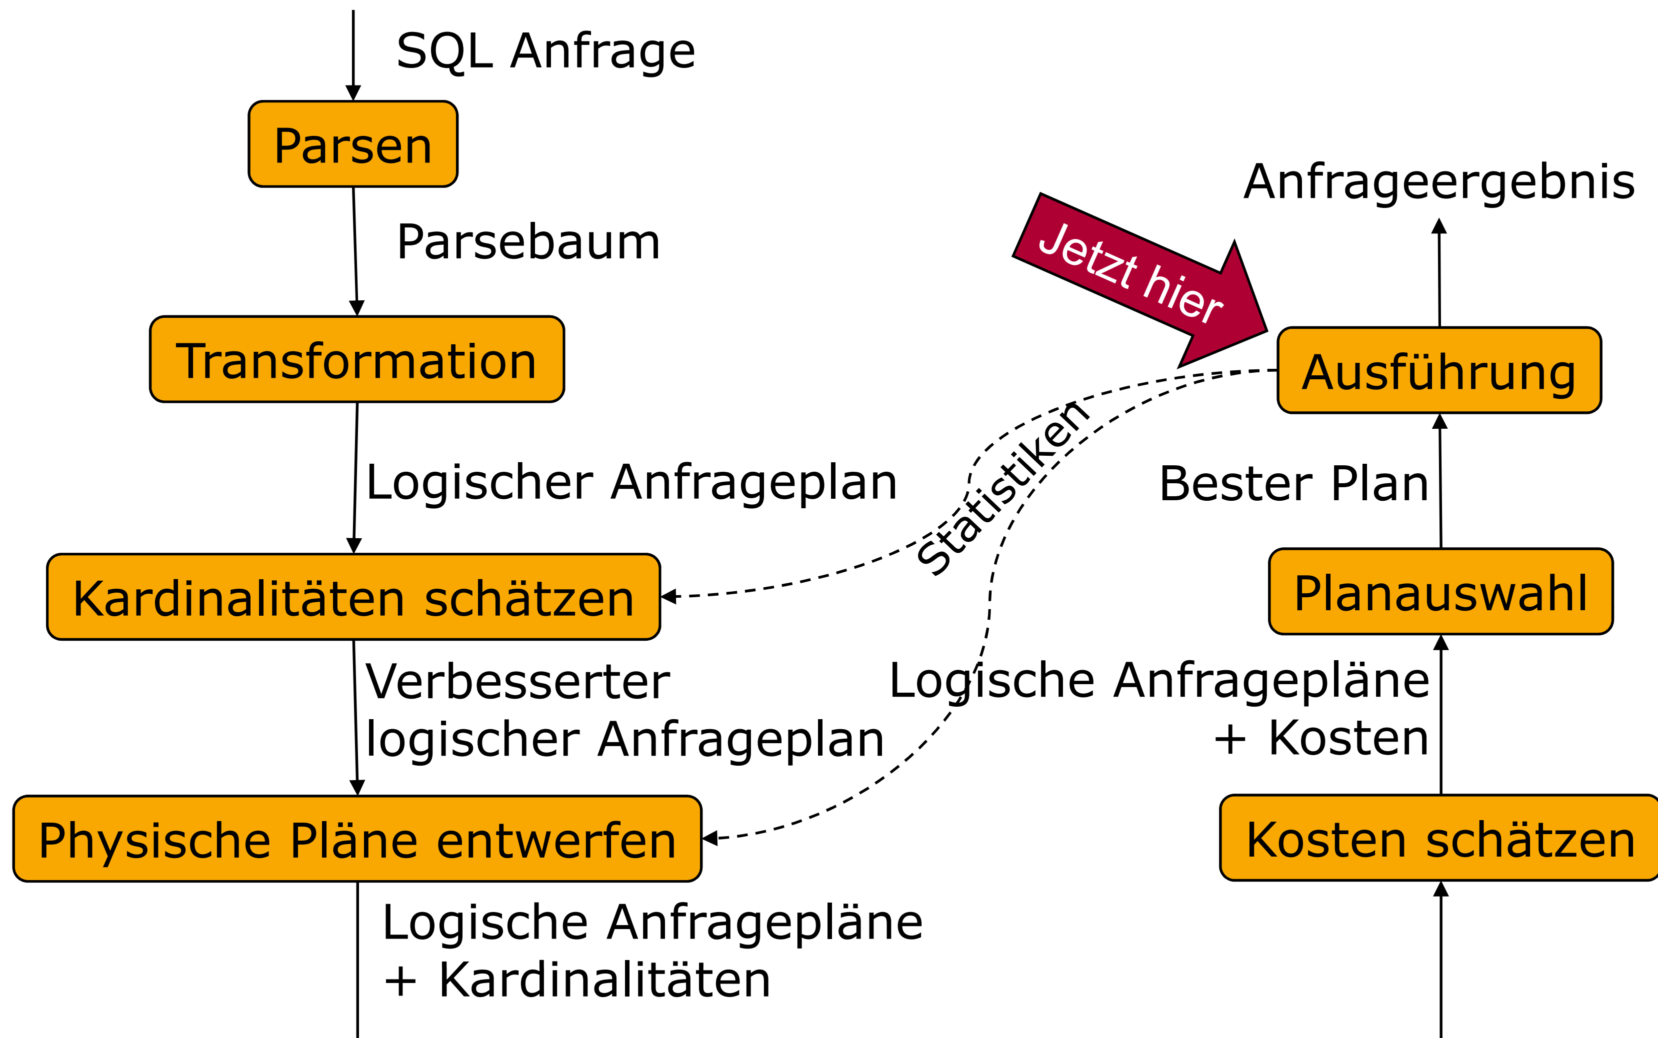

Überblick

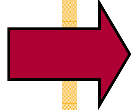

- Physische Operatoren
- One-Pass Algorithmen
- Nested Loop Join
- Sort-basierte Two-Pass Algorithmen
- Hash-basierte Two-Pass Algorithmen
- Index-basierte Algorithmen
- Puffermanagement

Grundbausteine

- Anfragepläne bestehen aus Operatoren.
  - Oft Operatoren der Relationalen Algebra
  - Aber auch: Scan einer Tabelle
- Physische Operatoren implementieren einen logischen Operator
  - Mehrere Implementierungen pro Operator

Tabellen Scannen

- Einfachste Operation
- Gesamte Relation einlesen
  - Join, Union, …
- Gegebenenfalls kombiniert mit Selektionsbedingung
- Zwei Varianten
  - *Table-scan*: Blöcke liegen in einer (bekannten) Region der Festplatte.
    - Einlesen aller Blöcke
  - *Index-scan*: Index besagt, welche Blöcke zur Relation gehören und wo diese liegen.
    - Hier Kombination mit Selektionen besonders effizient (-> später)

Sortiertes Einlesen

Sortiertes Einlesen von Relationen kann nützlich sein:

1. ORDER BY in der Anfrage
2. Spätere Operatoren nutzen Sortierung aus

- *Sort-scan*:
  - Gegeben Sortierschlüssel (ein oder mehr Attribute + Sortierreihenfolge)
  - Gegeben Relation
  - Gebe gesamte Relation sortiert zurück
- Implementierungsvarianten
  - B-Baum mit Sortierschlüssel als Suchschlüssel
  - Sequentielle Datei, sortiert nach Sortierschlüssel
  - Relation ist klein und kann im Hauptspeicher sortiert werden
    - Table-scan + Sortierung
    - Index-scan + Sortierung
  - Relation ist groß: TPMMS
    - Ausgabe nicht auf Festplatte sondern als Iterator

Berechnungsmodell

- Kosten eines Operators
  - Nur I/O-Kosten werden gezählt
  - CPU-Kosten werden von I/O-Kosten dominiert
  - Ausnahme: Netzwerkübertragung -> nicht hier
- Annahme
  - Input eines Operators wird von Disk gelesen
  - Output eines Operators muss <u>nicht</u> auf Disk geschrieben werden.
    - Falls letzter Operator im Baum:
      - Anwendung verarbeitet Tupel einzeln
      - Diese I/O Kosten hängen von Anfrage ab, sowieso nicht vom Plan
    - Falls innerer Operator: Pipelining möglich

Kostenparameter / Statistiken

- Verfügbarer Hauptspeicher für einen Operator: M Einheiten
  - Eine Einheit entspricht Blockgröße auf Festplatte
  - Hauptspeicherverbrauch nur für Input und Operator, nicht für Output
  - Meist: M entspricht fast gesamtem Hauptspeicher
  - Kann dynamisch (während Anfragebearbeitung) bestimmt werden
  - Deswegen: M ist nur Schätzung
    - => Gesamtkosten sind nur geschätzt
    - => Gewählter Plan nicht unbedingt optimal
      - Dies hat auch andere Gründe

Kostenparameter / Statistiken

- Anzahl Blocks: *B*
  - Anzahl benötigter Blocks einer Relation: *B(R)*
  - Annahme: *B(R)* = Anzahl tatsächlich belegter Blocks
- Anzahl Tupel: *T*
  - Anzahl Tupel einer Relation: *T(R)*
  - *T/B* = Anzahl Tupel pro Block
- Anzahl unterschiedlicher Werte: *V*
  - Anzahl unterschiedlicher Werte einer Relation im Attribut *a*: *V(R,a)*
  - DISTINCT values
  - $V(R, [a_1, a_2, \ldots, a_n]) = |\delta(\pi_{a1,a2,\ldots,an}(R))|$

Scan Kosten - Beispiele

- R clustered
  - Table-scan: Kosten *B*
  - Sort-scan
    - Kosten *B* falls *R* in Hauptspeicher passt
    - Kosten 3*B*, falls TPMMS nötig
- R nicht clustered (also verteilt zusammen mit Tupeln anderer Relationen)
  - Table-Scan: Kosten *T*
  - Sort-scan
    - Kosten *T* falls R in Hauptspeicher passt
    - Kosten *T* + 2*B* falls TPMMS nötig
- Index-scan
  - Annahme: Kosten *B* bzw. T, auch wenn Index selbst einige Blöcke groß ist

Iteratoren

Viele physische Operatoren werden als Iterator implementiert.

- **`Open()`**
  - Öffnet Iterator, initialisiert Datenstrukturen
  - Ruft wiederum Open für Input-Operator(en) auf
  - Holt noch kein Tupel
- **`GetNext()`**
  - Holt nächstes Tupel
  - Ruft wiederum **`GetNext`** für Input-Operator(en) auf
  - Falls kein Tupel mehr vorhanden: **`NotFound`**
- **`Close()`**
  - Beendet und schließt Iterator
  - Ruft wiederum Close für Input-Operator(en) auf

Pull-basierte Anfrageauswertung

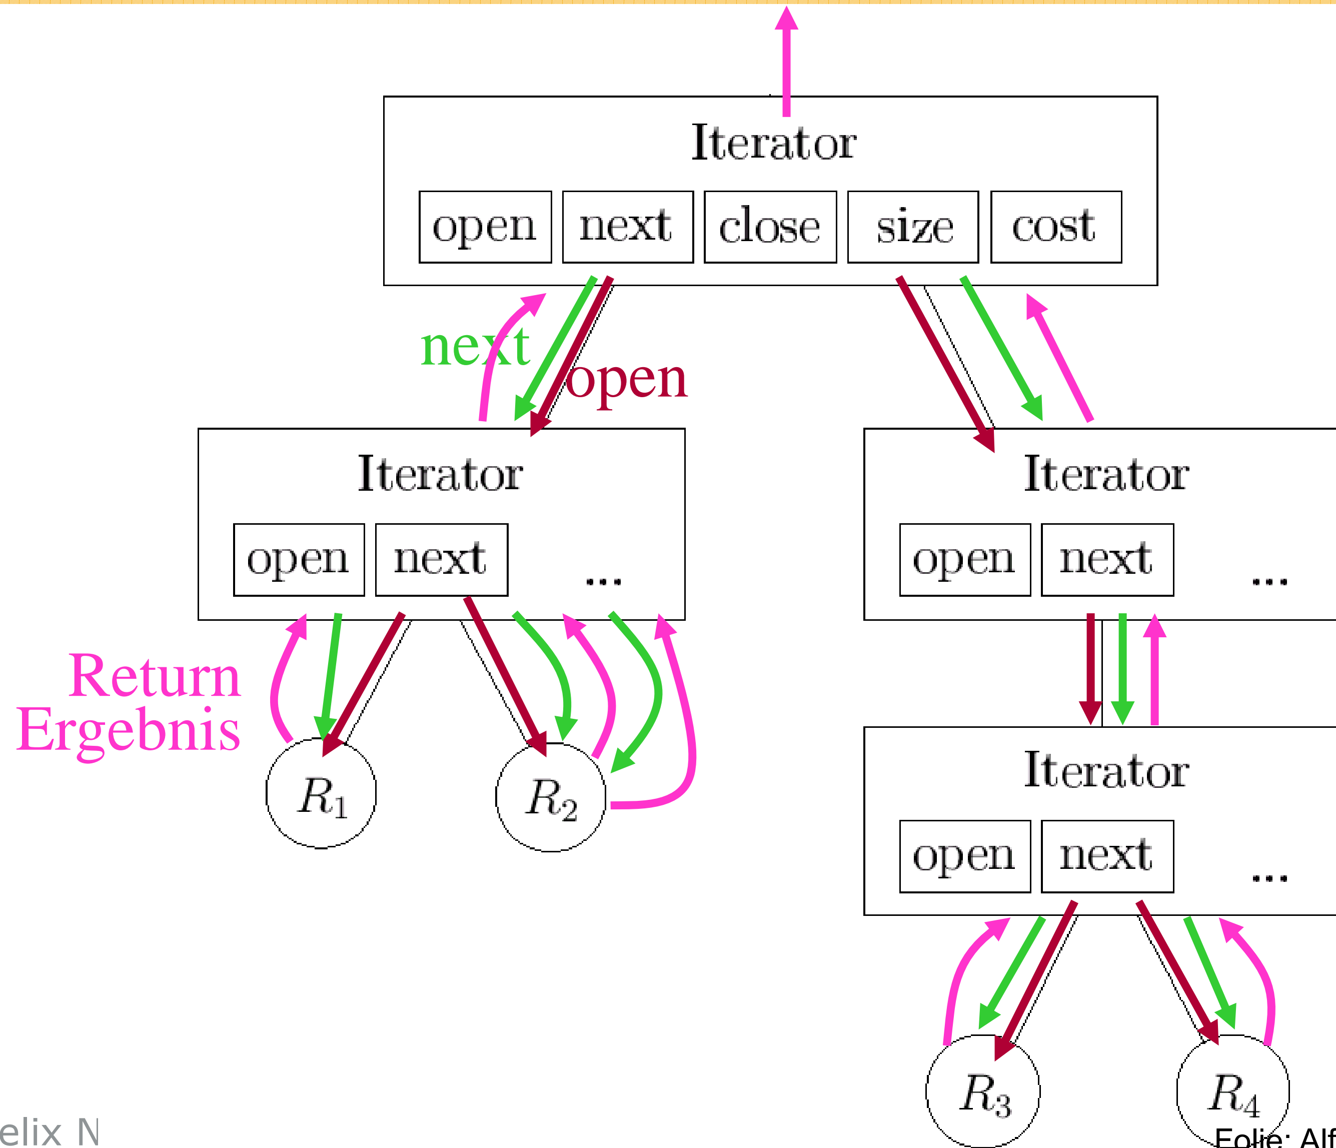

Folie: Alfons Kemper, TU München

Iterator – Beispiel

- Open()
  - b := the first block of R;
  - t := the first tuple of block b;
- GetNext()
  - IF (t is past the last tuple on block b)
    - Increment b to the next block;
    - IF (there is no next block)
      - RETURN NotFound;
    - ELSE
      - t := first tuple on block b;
  - oldt := t;
  - Increment t to the next tuple of b;
  - RETURN oldt;
- Close()
  - Do Nothing

Annahme: durch Pointer implementiert

Annahme: durch Block-organisation implementiert

Frage: Was wird hier implementiert?

Antwort: Table-scan

Iterator – Beispiel


```
Open(R,S) {
        R.open();
        CurRel := R;
}
GetNext(R,S) {
        IF (CurRel = R) {
                t := R.GetNext();
                IF(t <> NotFound) /*R ist nicht erschöpft*/
                    RETURN t;
                ELSE /*R ist erschöpft*/ {
                   S.Open();
                   CurRel := S;
        }}
        RETURN S.GetNext();
}
Close(R,S) {
        R.Close();
        S.Close()
}
```

Was passiert falls S erschöpft ist?

Frage: Was wird hier implementiert?

Antwort: UNION ALL

Iterator – Beispiele

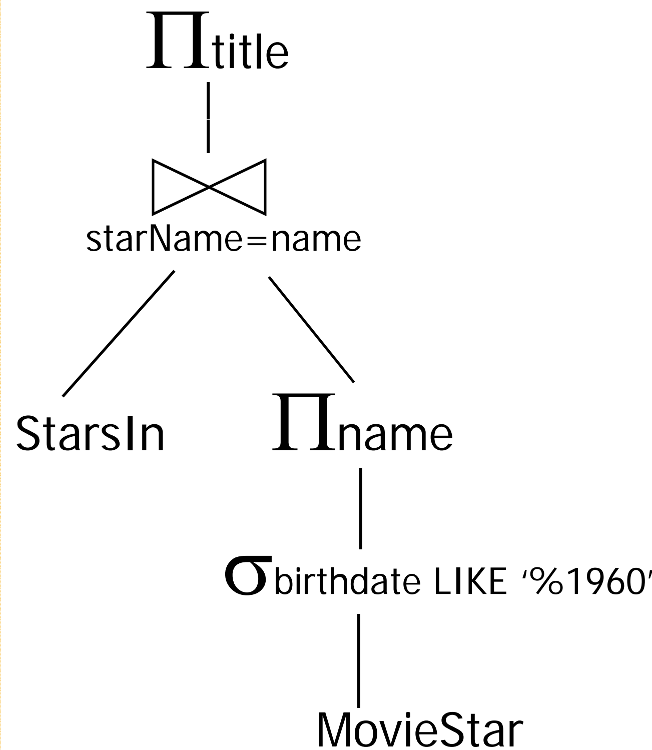


```
p = projection.Open();
while (t <> NotFound)
  t = p.GetNext()
  return t;
p.Close();
```

```
class projection {
Open() {
  j = join.Open();
  while (t <> NotFound)
    t:=j.GetNext()
    tmp[i++]=t.title;
  j.Close();
}
GetNext( ) {
  if (cnt < tmp.size())
    return tmp[cnt++];
  else return NotFound;
}
Close() {
  discard(tmp);
}
}
```

```
class join {
Open() {
  l = table.open();
  while (tl <> NotFound)
    t1 = l.GetNext();
    r = projection.Open();
    while (tr <> NotFound)
      tr = r.GetNext();
      if tl.starname=tr.name
        tmp[i++]=tl⋈tr;
    end while;
    l.Close();
  end while;
  r.Close();
}
GetNext( ) {
  if (cnt < tmp.size())
    return tmp[cnt++];
  else return NotFound;
}
Close() {
  discard(tmp);
  Close();
}
}
```

Folie: Ulf Leser, HU Berlin

Pipelined versus Blocked

- Pipelining ist im allgemeinen sehr vorteilhaft.
  - Kein Puffern großer Zwischenergebnisse auf Festplatte
  - Operationen können auf Threads und CPUs verteilt werden
- Pipeline breaker
  - Sortierung:
    - `next()` kann erst ausgeführt werden wenn gesamte Relation gesehen wurde.
    - Ausnahme: Input ist bereits sortiert
  - Gruppierung und Aggregation
    - Implementiert durch Sortierung oder Hashing
    - Dann führt `next()` die Aggregation für eine Gruppe aus
  - Minus, Durchschnitt
- Projection mit Duplikateliminierung
  - Nicht unbedingt pipeline breaker
  - `next()` kann früh Ergebnisse weiterreichen (Sortierung nicht nötig)
  - Aber: Man muss sich alle bereits gelieferten Ergebnisse merken (großer Zwischenspeicher)

Pipelining vs. Pipeline-Breaker

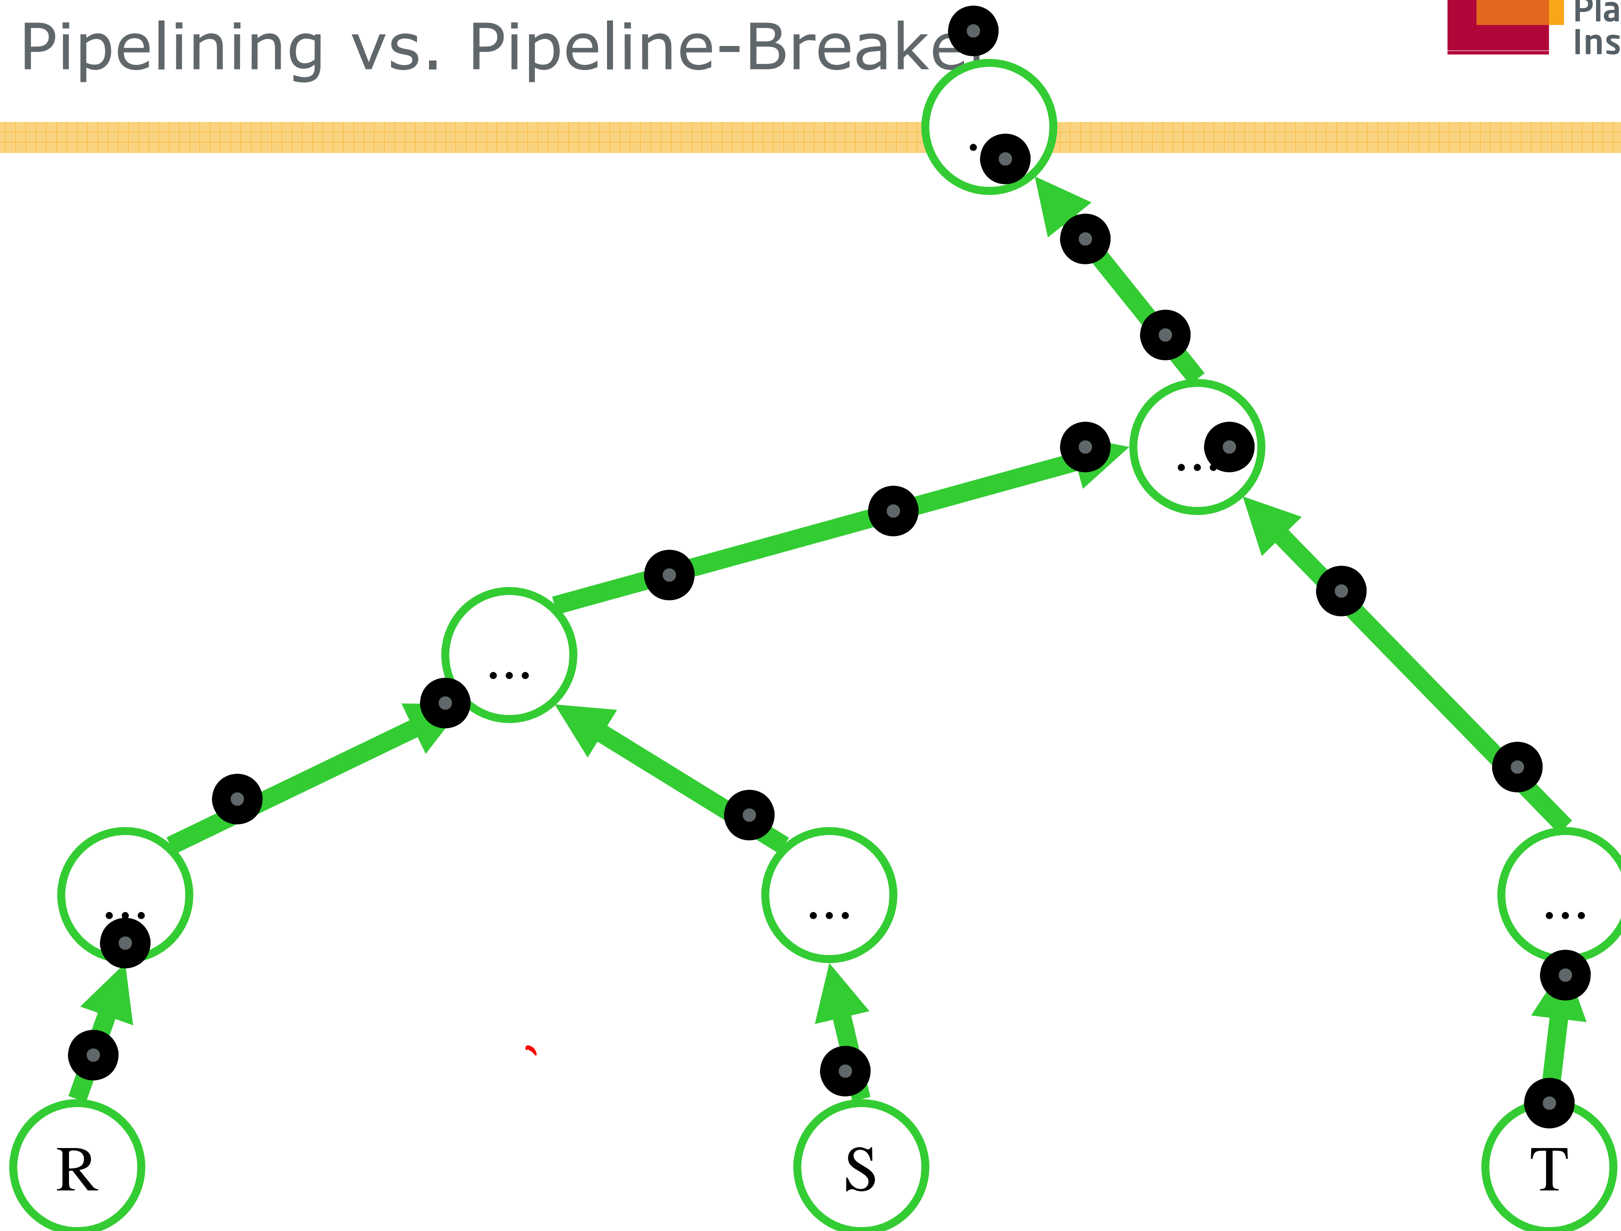

Folie: Alfons Kemper, TU München

Pipelining vs. Pipeline-Breaker

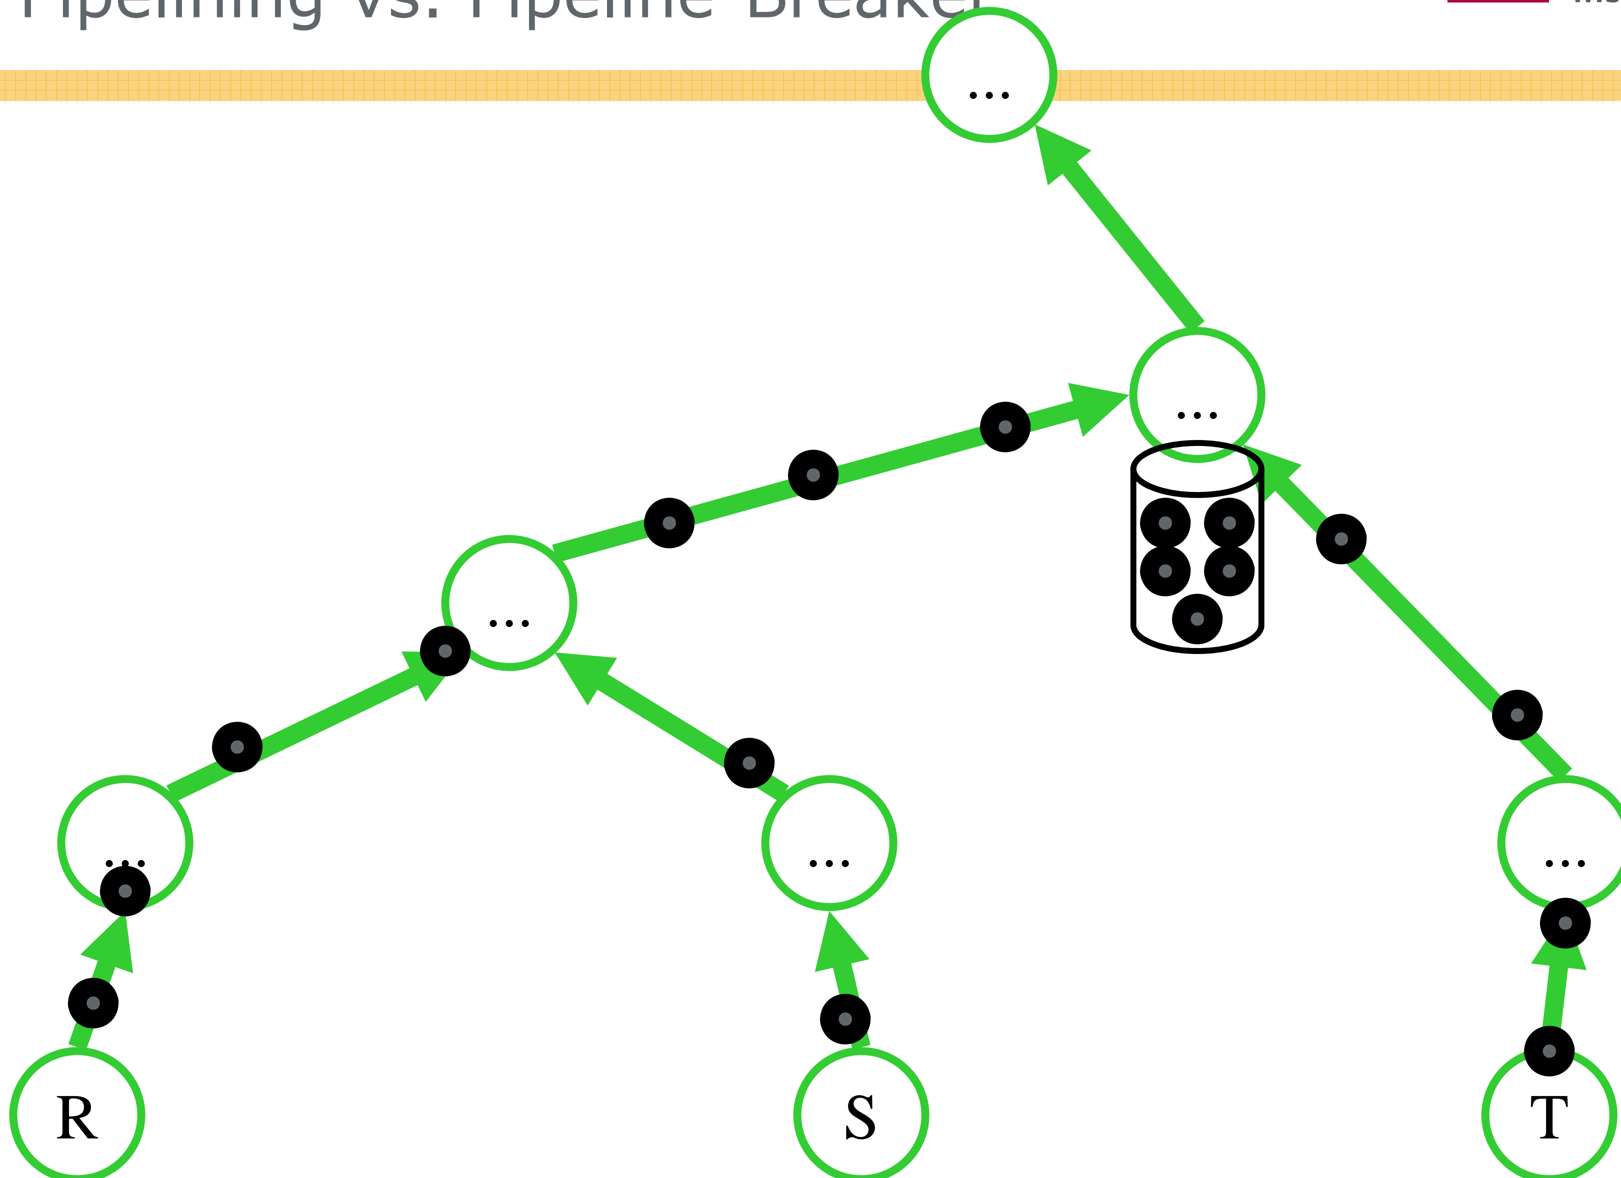

Folie: Alfons Kemper, TU München

Iterator – Beispiele

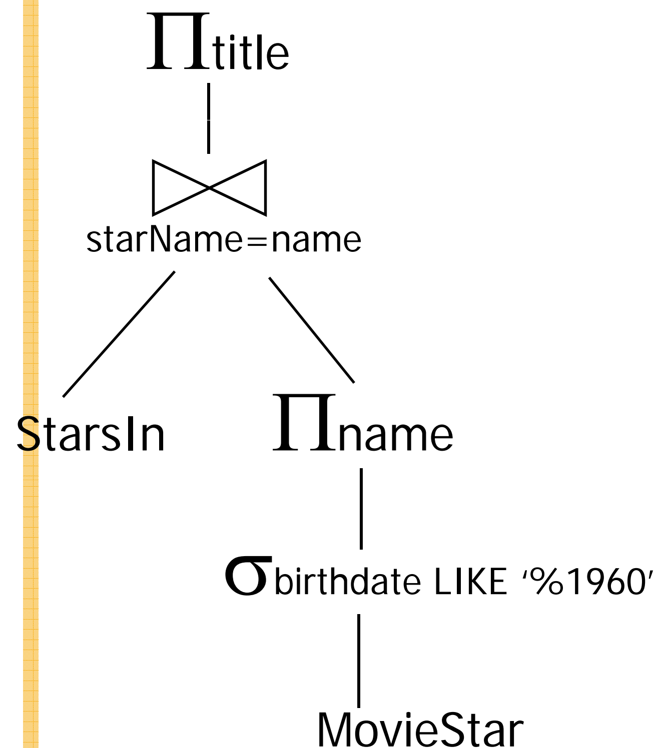


```
p = projection.Open();
while (t <> NotFound)
  t = p.GetNext()
  return t;
p.Close();

Class projection {
Open() {
  j = join.Open();
}
GetNext() {
  t =  j.GetNext();
  return t.title
}
close() {
  j.Close();
}
}
```

```
Class join {
Open() {
  l = table.Open();
  r = projection.Open()
  tl = l.GetNext();
}
GetNext() {
  tr = r.GetNext();
  if (tr <> NotFound)
    if tl.starname=tr.name
      return tl⋈tr;
    else
    tl = l.GetNext()
    if (tl <> NotFound)
       return GetNext();
    else
      return NotFound;
}
Close() {
  l.Close;
  r.Close();
}
}
```

Folie: Ulf Leser, HU Berlin

Überblick über das Weitere

- Drei Klassen von Algorithmen
  - Sort-basierte Algorithmen
  - Hash-basierte Algorithmen
  - Index-basierte Algorithmen
- Drei Schwierigkeitsgrade von Algorithmen
  - One-Pass Algorithmen
    - Daten nur einmal von Disk lesen
    - Mindestens ein Argument passt in Hauptspeicher
      - außer Selektion und Projektion
  - Two-Pass Algorithmen
    - Meist einmal lesen, einmal schreiben, nochmal lesen
    - TPMMS
    - Gewisse Größenbeschränkung auf Input
  - Multipass Algorithmen
    - Unbeschränkt in Inputgröße
    - Rekursive Erweiterungen von Two-Pass Algorithmen
  - U.a. abhängig vom Operator

Überblick

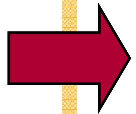

- Physische Operatoren
- One-Pass Algorithmen
- Nested Loop Join
- Sort-basierte Two-Pass Algorithmen
- Hash-basierte Two-Pass Algorithmen
- Index-basierte Algorithmen
- Puffermanagement

Operatorklassen

- Tupel-basierte unäre Operatoren
  - Benötigen jeweils nur sehr kleinen Teil des Input gleichzeitig im Hauptspeicher
  - Projektion, Selektion, Multimengen-Vereinigung
- Relationen-basierte unäre Operatoren
  - Benötigen gesamte Relation im Hauptspeicher
  - Deshalb Beschränkung der Inputgröße auf Hauptspeichergröße
  - Gruppierung, Duplikateliminierung
- Relationen-basierte binäre Operatoren
  - Benötigen mindestens eine gesamte Relation im Hauptspeicher
    - Falls sie one-pass sein sollen
  - Alle Mengenoperatoren (außer Multimengen-Vereinigung)

Tupel-basierte unäre Operatoren

- Algorithmus für Selektion und Projektion offensichtlich
  - Unabhängig von Hauptspeichergröße
- Speicherkosten: 1
- I/O Kosten: Wie table-scan oder index-scan
  - B, falls geclustert
  - T, falls nicht geclustert
  - Weniger, falls Selektion auf Suchschlüssel eines Index
- Puffer > 1 nützlich. Wieso?
  - „Daten gemäß Zylinder organisieren"
  - Alle Blocks eines Zylinders gleichzeitig lesen.

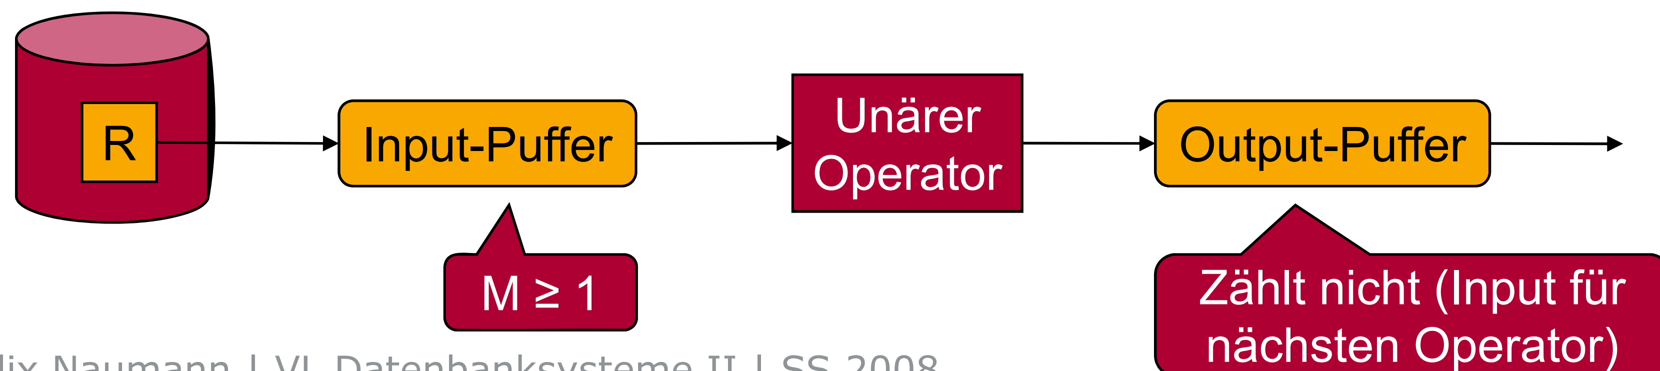

Relationen-basierte unäre Operatoren

- Operatoren: Duplikateliminierung und Gruppierung
  - Ganze Relation muss in den Hauptspeicher passen
- Genereller „Trick": Bewahre nur „Repräsentanten" im Hauptspeicher
  - Duplikateliminierung: Eindeutige Repräsentation schon gesehener Tupel
  - Gruppierung: Gruppierungsattribute und aggregierte Teilergebnisse

Duplikateliminierung

- Tupel für Tupel einlesen
  - Erstes Mal dieses Tupel gesehen -> Ausgabe
  - Schon mal gesehen -> nix tun
- Puffer merkt sich welche Tupel bereits gesehen wurden
  - Datenstruktur wichtig (trotz I/O Dominanz)
    - Einfügen eines Tupels und Finden eines Tupels in fast konstanter Zeit
    - Z.B. Hashtabelle, balancierter Binärbaum
    - Geringer Speicher-overhead
- Wahl von M: $B(\delta(R)) \leq M$

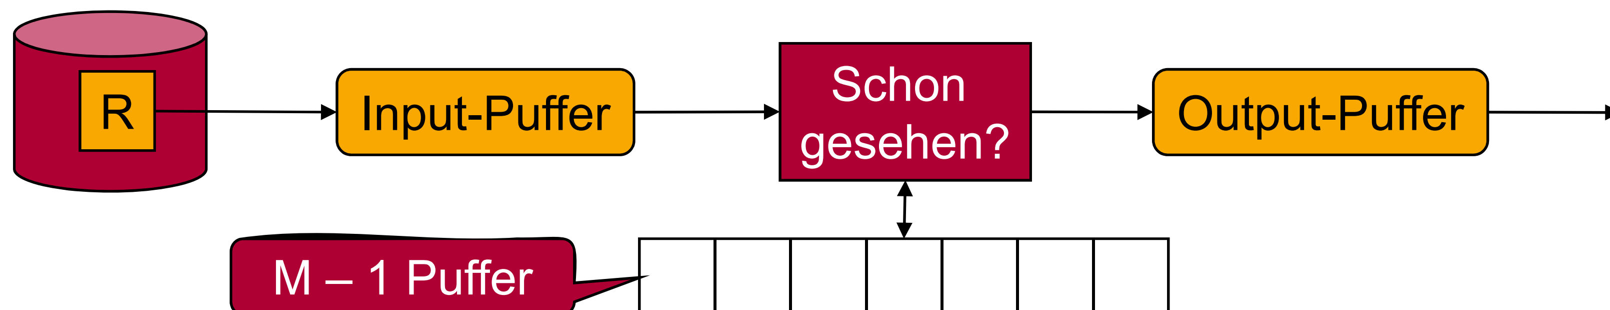

Gruppierung

- Idee: Erzeuge im Hauptspeicher einen Eintrag pro Gruppe
- Also ein Eintrag pro Gruppierungswert
- Dazu: Kumulierte Werte für aggregierte Attribute
  - Einfach: MIN/MAX, COUNT, SUM
  - Schwerer: AVG (Warum?)
    - AVG ist nicht assoziativ.
    - Merke COUNT und SUM
    - AVG erst am Ende berechnen
- Wieder: Datenstruktur im Hauptspeicher ist wichtig.
- Output: Ein Tupel pro Eintrag
  - Output erst nachdem letzter Input gesehen wurde (Blockierend)
- Hautspeicherkosten: Schwer abzuschätzen
  - Einträge selbst können größer oder kleiner als Tupel sein
  - Anzahl der Einträge höchstens so groß wie T
  - Meistens M << B

Relationen-basierte binäre Operatoren

- Vereinigung, Schnittmenge, Differenz, Kreuzprodukt, Join
  - Annahme: Eine Inputmenge passt in Hauptspeicher
    - Außer $\cup_B$
    - Wieder: Effiziente Datenstruktur sinnvoll
    - Hauptspeicherbedarf: $M \geq \min(B(R), B(S))$
      - Hier: $B(S) < B(R)$
  - Unterscheidung: Multimengensemantik (z.B. $\cup_B$) vs. Mengensemantik ($\cup_S$)
- $R \cup_B S$ trivial
  - I/O-Kosten: $B(R) + B(S)$
  - Hauptspeicherbedarf: 1

Relationen-basierte binäre Operatoren

- $R \cup_S S$
  - Lese alle Tupel aus S und baue Datenstruktur auf
    - Schlüssel ist gesamtes Tupel
  - Gebe alle diese Tupel aus
  - Lese R ein
    - Falls schon vorhanden: Nix tun
    - Fall nicht: Ausgeben
- $R \cap_S S$
  - Zunächst wie $R \cup_S S$ aber keine Tupel ausgeben
  - Lese R ein
    - Falls vorhanden: Ausgabe
    - Falls nicht vorhanden: Nix tun
  - Annahme: R und S sind Mengen

Relationen-basierte binäre Operatoren

- Mengen-Differenz
  - Nicht kommutativ!
  - Annahme:
    - R und S sind Mengen
    - S ist kleiner als R
  - Zunächst: Lese S in effiziente Datenstruktur ein
    - Gesamtes Tupel ist Schlüssel
- $R -_S S$
  - Lese R ein
    - Falls Tupel schon vorhanden: Nix tun
    - Falls nicht vorhanden: Ausgabe
- $S -_S R$
  - Lese R ein
    - Falls Tupel schon vorhanden: Lösche aus Datenstruktur
    - Falls nicht vorhanden: Nix tun
  - Gebe übrig gebliebenen Tupel aus.

Relationen-basierte binäre Operatoren

- $R \cap_B S$
  - Lese S ein
    - Merke einen COUNT-Wert pro Tupel
    - Kann etwas mehr Speicher kosten (i.d.R. weniger)
  - Lese R ein
    - Falls nicht bereits vorhanden: Nix tun
    - Falls vorhanden und COUNT > 0: Ausgabe und COUNT reduzieren
    - Sonst: Nix tun

Relationen-basierte binäre Operatoren

- Multimengendifferenz
  - $S -_B R$
    - Lese S ein und speichere einen COUNT-Wert
    - Lese R ein
      - Falls Tupel schon vorhanden: Verringere COUNT
      - Falls nicht vorhanden: Nix tun
    - Gebe Tupel mit COUNT > 0 entsprechend oft aus.
  - $R -_B S$
    - Lese S ein und speichere einen COUNT-Wert (c)
      - c Gründe ein Tupel aus R nicht auszugeben
    - Lese R ein
      - Falls Tupel schon vorhanden und COUNT > 0: COUNT verringern
      - Falls Tupel schon vorhanden und COUNT = 0: Ausgabe
      - Falls nicht vorhanden: Ausgabe

Relationen-basierte binäre Operatoren

- $R \times S$
  - Lese S in Hauptspeicher ein
    - Datenstruktur egal
  - Lese R ein
    - Konkateniere mit jedem Tupel aus S
    - Ausgabe
  - Rechenzeit pro Tupel lang: Ausgabe ist eben groß
- $R(X,Y) \bowtie S(Y,Z)$ (natural join)
  - Lese S in Hauptspeicher ein
    - Y als Suchschlüssel
  - Lese R ein
    - Für jedes Tupel, suche passende Tupel aus S und gebe aus
  - I/O Kosten: $B(R) + B(S)$
  - Annahme: $B(S) \leq M-1$ bzw. vereinfacht: $B(S) \leq M$
  - Equi-join analog
  - Theta-join: Kreuzprodukt + Selektion

Überblick

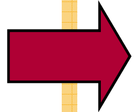

- Physische Operatoren
- One-Pass Algorithmen
- Nested Loop Join
- Sort-basierte Two-Pass Algorithmen
- Hash-basierte Two-Pass Algorithmen
- Index-basierte Algorithmen
- Puffermanagement

Nested-Loop-Join-Algorithmen (NLJ)

- 1,5-pass Algorithmen
  - Eine Relation nur einmal einlesen
  - Die andere Relation mehrfach einlesen
- Größe beider Relationen beliebig
- Tupel-basierte Variante – Naïv
  - ```
    FOR EACH TUPLE s IN S DO
            FOR EACH TUPLE r IN R DO
                    IF (r.Y = s.Y) THEN OUTPUT (r ⋈ s)
    ```
  - I/O-Kosten: $T(S) \cdot T(R)$
  - Verbesserungen
    - Index auf Joinattribut in R (später)
    - Aufteilung der Tupel auf Blöcke berücksichtigen (gleich)
    ```

Iterator für Tupel-basierten NLJ


- ```
  Open(R,S) {
    R.Open();
    S.Open();
    s := S.GetNext();
  }
  ```
- ```
  Close(R,S) {
    R.Close();
    S.Close();
  }
  ```
- ```
  GetNext(R,S) {
  REPEAT {
   r := R.GetNext();
   IF (NOT Found ) {
   /* R is exhausted for the current s */
     R.Close();
     s := S.GetNext();
     IF (Not Found) RETURN;
   /* both R and S are exhausted */
     R.Open();
     r := R.GetNext();
     }
   }
  UNTIL( r.Y = s.Y )
  RETURN join of r and s;
  }
  ```

Vorteil: Pipelining
  ```

Block-basierter NLJ

Ideen

- Organisiere Tupel nach Blöcken
    - Sinnvoll für innere Schleife
- Nutze Hauptspeicher
    - So viel wie möglich von S (äußere Schleife) halten
    - => Ein R-Tupel wird nicht nur mit einem, sondern mit vielen S-Tupeln verjoint.
- Annahmen
    - $B(S) \leq B(R)$ (wie bisher)
    - $B(S) > M$ (schwieriger als bisher in 1-pass)
    - Effiziente Datenstruktur für S im Hauptspeicher

Block-basierter NLJ


```
FOR EACH chunk of M-1 blocks of S DO BEGIN
        read blocks into main memory;
        organize tuples into efficient data structure;
        FOR EACH block b of R DO BEGIN
                read b into main memory;
                FOR EACH tuple t of b DO BEGIN
                    find tuples of S in main memory that join;
                    output those joined tuples;
                END;
        END;
END;
```

Drei Schleifen?

Block-basierter NLJ – Kosten

- B(R) = 1.000
- B(S) = 500
- M = 101
- => 5x äußere Schleife á 100 I/O
- => jeweils 1.000 I/O für R
- = 5.500 I/O

- Nun: R in äußerer Schleife
  - => 10x äußere Schleife á 100 I/O
  - => jeweils 500 I/O für S
  - = 6.000 I/O

- => Kleinere Relation sollte außen sein.

```
FOR EACH chunk of M-1 blocks of S DO
 BEGIN
  read blocks into main memory;
  organize tuples into data structure;
  FOR EACH block b of R DO BEGIN
    read b into main memory;
    FOR EACH tuple t of b DO BEGIN
       find tuples of S in memory that join;
       output those joined tuples;
    END;
  END;
END;
```

- Extremfall 1
  - B(S) = 100
  - B(R)= 1.000.000
  - 10.000x äußere Schleife á 100 + 100 I/O
  - = 10.000 x 200 = 2.000.000 I/O
- Extremfall 2
  - 1x äußere Schleife á 100 + 1.000.000 I/O
  - = 1x 1.000.100 I/O

Block-basierter NLJ – Kosten

- Allgemeinere Berechnung
  - Äußere Schleife: B(S)/(M-1)-fach
  - Jeweils
    - M-1 Blöcke von S
    - B(R) Blöcke von R
  - Zusammen

$$\frac{B(S)}{M-1}(M-1+B(R))$$

$$= B(S) + \frac{B(S)B(R)}{M-1}$$

$$\approx B(S)B(R)/M$$

```
FOR EACH chunk of M-1 blocks of S DO BEGIN
  read blocks into main memory;
  organize tuples into data structure;
  FOR EACH block b of R DO BEGIN
    read b into main memory;
    FOR EACH tuple t of b DO BEGIN
       find tuples of S in memory that join;
       output those joined tuples;
    END;
  END;
END;
```

Zusammenfassung bisheriger Algorithmen

Operator	Nötiger Hauptspeicher M	I/O	Algorithmus
σ, π	1	B	1-pass, tupel-basiert
γ, δ	$\approx$ B	B	1-pass, relationen-basiert
$\cup, \cap, -, \times, \bowtie$	min(B(S), B(R))	B(R) + B(S)	1-pass, relationen-basiert binär
$\bowtie$	$M \geq 2$	B(R)B(S)/M	Block-basierter NLJ

Überblick

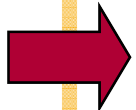

- Physische Operatoren
- One-Pass Algorithmen
- Nested Loop Join
- Sort-basierte Two-Pass Algorithmen
- Hash-basierte Two-Pass Algorithmen
- Index-basierte Algorithmen
- Puffermanagement

1-, 2-, Mehr-Phasen

- Bisher: One-Pass Algorithmen; eine Relation passt in Hauptspeicher
- Nun: Two-Pass Algorithmen; keine Relation passt in Hauptspeicher
- Zwei Phasen
  - Einlesen der Daten
  - Verarbeitung der Daten (hier: Sortierung von Teillisten)
  - Schreiben der Daten
  - Wiedereinlesen der Daten (hier: Merging der Teillisten)
    - Hier unterscheiden sich die Algorithmen
- Mehr-Phasen?
  - Zwei Phasen reichen meist
  - Verallgemeinerung zu Mehr-Phasen einfach

Duplikateliminierung

Idee: Ähnlich wie TPMMS

- …
- Ein Block pro sortierter Teilliste
  - Betrachte jeweils erstes Tupel
  - Suche kleinstes Tupel
  - Gib ein dieses Tupel aus; verwerfe alle anderen identischen Tupel
- Beispiel
  - M = 3 + 1; 2 Tupel pro Block
  - 17 Tupel: 2, 5, 2, 1, 2, 2, 4, 5, 4, 3, 4, 2, 1, 5, 2, 1, 3
  - Phase 1: 3 sortierte Teillisten
  - Phase 2: s.o.

Duplikateliminierung – Kosten

- Wie TPMMS
  1. B(R) für Einlesen in Phase 1
  2. B(R) für Schreiben der Teillisten
  3. B(R) für Lesen der Teillisten
  - Zusammen: 3·B(R)
- One-pass Algorithmus: 1·B(R)
- Aber hier größerer Input möglich
  - One-pass: $B \leq M$
  - Two-pass: $B \leq M^2$

Gruppierung und Aggregation

Hasso Plattner Institut

- Phase 1
  1. Lese R ein (jeweils M Blöcke)
  2. Sortiere M Blöcke nach Gruppierungsattribut(en)
  3. Schreibe sortierte Teillisten
- Phase 2
  1. Lade jeweils einen Block jeder Teilliste
  2. Suche kleinste Schlüssel (neue Gruppe)
  3. Aggregiere alle Tupel mit diesem Schlüssel
     - Gegebenenfalls Blöcke nachladen
  4. Gebe ein Tupel mit aggregierten Werten (und gegebenenfalls Gruppierungsattribut) aus.
  5. Suche nächst kleineren Schlüssel
- I/O-Kosten: 3B(R)   Maximale Größe: $B(R) \leq M^2$

Vereinigung (binär)

1. Lese R ein und schreibe sortierte Teillisten
   - Sortierschlüssel ist gesamtes Tupel
2. Lese S ein und schreibe sortierte Teillisten
   - Sortierschlüssel ist gesamtes Tupel
3. Lese jeweils einen Block aus beiden Mengen sortierter Teillisten
4. Suche kleinste Tupel aus allen Blöcken
   - -> Ausgabe
   - Entfernung aus allen anderen Teillisten
     - Zur Not: Blöcke nachladen
5. Suche nächstes kleinstes Tupel

- Funktioniert für Mengen und Multimengen
  - Bei Multimengen ist one-pass Algorithmus besser
- I/O-Kosten: $3(B(R) + B(S))$
- Maximale Größe: $B(R) + B(S) \leq M^2$

Schnittmenge und Differenz

1. Sortierung und Laden der Teillisten wie bei Vereinigung
2. Suche kleinstes Tupel *t*
3. Zählen
   - count(R, *t*) = Anzahl der Vorkommen von *t* in R
   - count(S, *t*) analog
   - Gegebenenfalls nachladen

- $\cap_S$: Ausgabe von *t* falls count(R, *t*) > 0 und count(S, *t*)>0
- $\cap_B$: Ausgabe von *t* min(count(R, *t*), count(S, *t*)) mal
  - Gegebenenfalls nicht ausgeben (wenn ein count = 0)
- $R -_S S$: Ausgabe von *t* falls count(R, *t*) > 0 und count(S, *t*) = 0
- $R -_B S$: Ausgabe von *t* count(R, *t*) – count(S, t) mal
- I/O-Kosten: 3(B(R) + B(S))
- Maximale Größe: $B(R) + B(S) \leq M^2$

Einfacher, Sort-basierter Join Algorithmus

- Neues Problem: Alle Tupel mit gleichem Joinattributwert müssen gleichzeitig im Hauptspeicher sein.
- Lösungsidee: Reserviere so viel Speicher wie möglich für aktuelle Jointupel
  - Reduziere Speicherbedarf anderer Algorithmusteile
- $R(X, Y) \bowtie S(Y, Z)$
- Sortiere R und S jeweils gemäß Y mit TPMMS
  - Inkl. letzter Phase (Schreiben des sortierten Ergebnisses)
- Merge R und S
  1. Jeweils ein Block
  2. Suche insgesamt kleinstes Y in beiden Blocks
  3. Falls nicht in anderem Block vorhanden: Entferne alle Tupel mit diesem Y
  4. Falls vorhanden: Identifiziere alle Tupel mit diesem Y
     - Gegebenenfalls nachladen
  5. Gebe alle Kombinationen aus
  6. Lade gegebenenfalls Tupel nach

Einfacher, Sort-basierter Join Algorithmus – Kosten

- R: 1000 Blocks; S: 500 Blocks; M = 101
- TPMMS: $4(B(R) + B(S)) = 4 \cdot 1500 = 6000$ I/O
- Merging: Nochmals R und S lesen: 1500 I/O
  - Nur 2 Blocks werden benötigt
  - Aber: Alle Tupel mit einem bestimmten Y-Wert müssen in 99 Blöcke passen
- I/O: $5(B(R) + B(S))$; Hauptspeicher: $B(R) \leq M^2$ und $B(S) \leq M^2$
- Vergleich zu nested loops: 5500 I/O
  - Aber nested loops ist quadratisch: $B(R)B(S)/M$
  - Sort-based join ist linear
  - Gleich noch Verbesserung auf $3(B(R) + B(S))$

Einfacher Sort-basierter Join Algorithmus – Erweiterung

- Falls alle Tupel mit einem bestimmten Y-Wert nicht in Hauptspeicher passen
  - Falls alle solche Tupel einer Relation in M-1 Blöcke passen
    - One-pass join
  - Falls nicht
    - Nested loop join
- Fallunterscheidung kann überflüssiges I/O kosten.
- Analyse
  - Y ist oft in einer Relation ein Schlüssel => leicht
  - Oft sind viele Speicherblöcke übrig, da $B(R)+B(S) << M^2$

Sort-basierter Join Algorithmus – Verbesserung

- Idee: Kombiniere 2te Phase des TPMMS mit dem Joinen
  - => „sort-join", „merge-join", „sort-merge-join"
- Annahmen
  - Anzahl aller Teillisten (aus R und S) ≤ M
  - Tupel mit gemeinsamen Y-Werten passen zusammen in verbleibenden Hauptspeicher
- R: 1000 Blocks; S: 500 Blocks; M = 101
  - Phase 1: 10 Teillisten für R, 5 Teillisten für S
  - Phase 2: 15 Blöcke gleichzeitig im Hauptspeicher
    - => 86 freie Blöcke für aktuelle Join-Tupel
  - Zusammen 3(B(R)+ B(S)) = 4500 I/O

Zusammenfassung – sortbasierte, two-pass Algorithmen

Operator	Nötiger Hauptspeicher M	I/O
γ, δ	$\sqrt{B}$	3B
∪, ∩, −	$\sqrt{B(R)+B(S)}$	3(B(R) + B(S))
⋈	$\sqrt{\max(B(R),B(S))}$	5(B(R) + B(S))
⋈	$\sqrt{B(R)+B(S)}$	3(B(R) + B(S))

Überblick

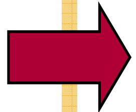

- Physische Operatoren
- One-Pass Algorithmen
- Nested Loop Join
- Sort-basierte Two-Pass Algorithmen
- Hash-basierte Two-Pass Algorithmen
- Index-basierte Algorithmen
- Puffermanagement

Grundidee

- Input passt nicht in Hauptspeicher.
- Hashe alle Inputargumente.
  - Tupel, die gemeinsam betrachtet werden müssen, erhalten gleichen Hashwert.
  - Landen also in einem Bucket
- Unäre Operatoren: Bearbeite einen Bucket nach dem anderen
- Binäre Operatoren: Bearbeite Paare von Buckets
- Oft: Mehr als ein Block pro Bucket

- Reduktion des Speicherbedarfs um Faktor M im Vergleich zu Relationen
  - Verwende M Buckets
  - Mindestens ein Bucket muss in Hauptspeicher passen.

Partitionierung mittels Hashing

Hasso Plattner Institut

- Grundalgorithmus
- Gegeben M Puffer, verteile R auf M-1 Buckets
  - Möglichst gleicher Größe
- Ein Bucket pro Puffer
- Letzter Puffer für Einlesen der Tupel aus R
- Idee
  - Für jedes Tupel aus R berechne h(t) und kopiere Tupel in entsprechenden Bucket.
  - Falls voll: Schreibe auf Overflowblock auf Disk
  - Am Ende: Schreibe auch alle Buckets auf Disk

Partitionierung mittels Hashing


```
initialize M-1 ??? buckets using M-1 empty buffers;
FOR each block b of R DO BEGIN
  read block b into M-th buffer
  FOR each tuple t in b DO BEGIN
        IF buffer for bucket h(t) has no room for t THEN
               BEGIN
                 copy the buffer to disk;  /* overflow */
                 initialize a new empty block in that buffer;
               END;
        copy t to buffer for bucket h(t);
  END;
END;
FOR each bucket DO
  IF the buffer for this bucket is not empty THEN
        write the buffer to disk;
```

Duplikateliminierung $\delta(R)$

- Algorithmus wie eben:
  - Ganzes Tupel als Hash-Input (ist das nötig?)
- Duplikate landen im gleichen Bucket.
- Betrachte jeden Bucket einzeln.
  - Duplikateliminierung innerhalb des Buckets
  - Danach Bucket ausgeben
    - (Vereinigung aller Buckets)
- Annahme: Alle Blöcke eines Buckets passen in Hauptspeicher
  - => One-pass Algorithmus funktioniert pro Bucket
  - Bei Gleichverteilung durch *h*: Bucket hat B(R)/(M-1) Blöcke
  - => R darf bis zu M(M-1) viele Blöcke umfassen
  - Vermutlich noch besser (wie zuvor): Es müssen nur *distinct* Tupel in Hauptspeicher passen
- I/O-Kosten: 3·B(R)

Gruppierung und Aggregation $\gamma_L(R)$

Hasso Plattner Institut

- Grundalgorithmus wie zuvor
- Aber: Hashfunktion hängt nur von Gruppierungsattributen ab.
- Dann: One-pass Algorithmus für Gruppierung auf jedem Bucket
- Hauptspeicherbedarf: $B(R) \leq M^2$
  - Vermutlich viel besser: Nur ein Tupel pro Gruppe im Hauptspeicher
- I/O-Kosten: $3 \cdot B(R)$

Mengenoperationen

- Bei binären Operationen: Gleiche Hashfunktion für beide Inputs!
- Mengenvereinigung:
  - Hashe R und S jeweils auf M-1 Buckets
  - Bilde Mengenvereinigung passender Bucketpaare
- Multimengenvereinigung: Voriger Algorithmus
- Wieder: Jeweils One-pass Algorithmus anwenden
- Speicherbedarf: $\min(B(R), B(S)) \leq M(M-1)$
  - Warum?
  - Da bei One-pass Varianten kleinere Relation in Hauptspeicher passen muss
- I/O-Kosten: $3 \cdot (B(R) + B(S))$

Hashjoin

- Algorithmus wie zuvor
- Aber: Hashschlüssel sind Joinattribute
  - Tupel mit gleichen Joinattributwerten landen im gleichen Bucket.
- Danach One-pass Join Variante für jeden Bucket
- Beispiel von zuvor: B(R) = 1000, B(S) = 500, M = 101
- Hashing
  - Ca. 10 R-Blocks pro Bucket
  - Ca. 5 S-Blocks pro Bucket
- Min(10, 5) = 5 => One-pass Algorithmus klappt (5 < 101)
  - Hole S-Bucket in Hauptspeicher; Joine Blöcke des passenden R-Buckets hinzu
- 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)

I/O Einsparungen

- Grundidee: Nutze nicht verwendeten Speicher
  - Idee 1: Verwende mehr als 1 Block 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

I/O Einsparungen

- Idee 2: Hybrid Hashjoin
  - Beim Hashen von S: Behalte m Buckets komplett im Speicher
  - Falls k Buckets insgesamt für S nötig sind: Verwende für die übrigen
    k – m Buckets nur einen Block im Hauptspeicher.
  - Es muss gelten: $(m \cdot B(S)/k) + k - m \leq M$
  - Beim Hashen von R sind im Hauptspeicher:
    - m Buckets für S
    - je ein Block für die k-m Buckets von R, deren korrespondierenden S-Buckets auf Disk sind
  - Falls t in einen der m Buckets gehasht wird
    - Joinpartner suchen
    - Gegebenenfalls direkte Ausgabe
  - Falls t in einen der k-m Buckets gehasht wird
    - Verfahre wie zuvor: Auf Disk schreiben
  - Phase 2 dann nur noch auf den k-m Buckets

Hybrid Hashjoin – Analyse

- Einsparungen
  - 2 I/Os für jeden Block, der im Hauptspeicher gehalten werden kann (nämlich m/k aller Buckets)
  - Einsparung also $2(m/k)$ (B(R) + B(S))
- => Maximiere (m/k), gegeben ($m \cdot B(S)/k$) + k – $m \leq M$
  - Lösung: Wähle $m = 1$ und minimiere k.
    - Intuition: Alle Puffer bis auf k – m werden verwendet, um Tupel im Hauptspeicher zu halten; davon bitte möglichst viele
- Minimierung von k (gesamte Anzahl der Buckets): Wähle Bucketgröße so, dass ein Bucket gerade eben in Hauptspeicher passt.
  - Bucketgröße M
  - => k = B(S) / M
    - => nur ein Bucket passt in Hauptspeicher (=> $m = 1$)
  - Bucketgröße eigentlich etwas kleiner, damit die übrigen Buckets durch mindestens einen Block repräsentiert werden können
- => Einsparungen $(2M / B(S)) \cdot (B(R) + B(S))$
- => I/O-Kosten: $(3 - (2M/B(S))) \cdot (B(R) + B(S))$

Wähle wenige große Buckets statt viele kleine.

Hybrid Hashjoin – Beispiel

- B(R) = 1000, B(S) = 500, M = 101
- Wähle k = B(S) / M = 500 / 101 ≈ 5
  - => Ein Bucket hat ca. 100 Blocks
  - => 104 Hauptspeicher nötig (> 101)
    - +1 für Lesen der Relation
  - => Besser k = 6
- Je 1 Puffer für erste 5 Buckets und 96 Puffer für letzten Bucket
  - +1 für Lesen der Relation
  - Erwartete Größe: 500/6 ≈ 83
- Phase 1
  - I/O-Kosten für S: 500x lesen und 417x schreiben
  - I/O-Kosten für R: 1000x lesen und 833x schreiben (5 der 6 Buckets)
- Phase 2
  - Alle geschriebenen Blöcke wieder lesen: 417 + 833 = 1250
- Zusammen: 500 + 1000 + 2·(417 + 833) = 4000 I/Os
  - < 4500 bei einfachen Hash-Join bzw. Sort merge Join!

Zusammenfassung Hash-basierter Verfahren

Operatoren	Hauptspeicher-bedarf	I/O-Kosten
γ, δ	$\sqrt{B}$	3B
$\cup$, $\cap$, $-$	$\sqrt{B(S)}$	3(B(R) + B(S))
$\bowtie$	$\sqrt{B(S)}$	3(B(R) + B(S))
$\bowtie$	$\sqrt{B(S)}$	(3 – (2M/B(S))) · (B(R) + B(S))

Wdh.: **Sort**-basierte, two-pass Algorithmen

Operators	Approximate M required	Disk I/O
γ, δ	$\sqrt{B}$	3B
∪,∩, -	$\sqrt{B(R)+B(S)}$	3(B(R) + B(S))
$\bowtie$	$\sqrt{\max(B(R),B(S))}$	5(B(R) + B(S))
$\bowtie$	$\sqrt{B(R)+B(S)}$	3(B(R) + B(S))

Vergleich Hash-basierte und Sort-basierte Algorithmen

- Speicherbedarf und I/O-Kosten ähnlich
- Speicherbedarf Hash-basierter Verfahren hängt nur vom kleineren der beiden Inputs statt Summe der beiden Inputs ab.
- Sortier-basierte Verfahren produzieren oft einen sortierten Output
  - Vorteile später im Plan
- Sortierbasierte Verfahren können sortierte Teilliste hintereinander auf Disk schreiben
  - Spart bei einer I/O-Operation Seektime
  - Bei großem M: Auch mehrere Blöcke einer Liste auf einmal lesen
- Gleiches auch bei Hash-basierten Verfahren möglich, falls Anzahl Buckets kleiner als M

Überblick

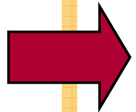

- Physische Operatoren
- One-Pass Algorithmen
- Nested Loop Join
- Sort-basierte Two-Pass Algorithmen
- Hash-basierte Two-Pass Algorithmen
- Index-basierte Algorithmen
- Puffermanagement

Grundidee

Indizes ermöglichen manchmal andere Algorithmen.

- Insbesondere Selektion
- Aber auch: Joins und andere binäre Operatoren

Stichwort „Clustering"

- Clustered Relation
  - Tupel auf so wenig wie möglich Blöcken auf Disk
- Clustering Index
  - Tupel mit gleichem Schlüsselwert sind auf so wenig wie möglich Blöcken
  - Voraussetzung: Relation ist clustered
- Eine clustered Relation kann auch non-Cluster-Indizes haben.

Index-basierte Selektion

- Basisalgorithmus: Lese gesamte Relation ein und prüfe Bedingung
  - Ohne Index ist dies die beste Methode
  - I/O-Kosten: B(R) bzw. T(R) falls R nicht clustered
- Besser: Selektionsbedingung a=v und a ist Suchschlüssel eines Cluster-Indexes
  - I/O-Kosten: B(R)/V(R,a)
    - Reminder: V(R,L) = Anzahl distinct Werte von $\pi_L(R)$
  - Eventuell mehr
    - I/O-Kosten für Index
    - Tupel nicht perfekt auf Blöcke verteilt: 1 Block extra
    - Blöcke nicht absolut vollgepackt
    - Fremde Tupel auf Blöcken
    - Aufrunden
      - Z.B. a ist Schlüssel => V(R,a) = T(R) >> B(R)
      - Dennoch mindestens 1 Block

Index-basierte Selektion

- Selektionsbedingung a=v und a ist Suchschlüssel eines nicht-Cluster-Indexes
- => Jedes Tupel auf anderen Block (vermutlich)
- I/O-Kosten: T(R) / V(R,a)
  - Wieder zusätzliche I/O-Kosten: Indizes
  - Etwas besser, falls zufällig mehr als ein Tupel auf dem Block

Index-basierte Selektion – Beispiel

- Beispiel: B(R) = 1000, T(R) = 20000 (=> 20 Tupel pro Block)
  - Anfrage: $\sigma_{a=0}(R)$; Index auf a
  - R ist clustered; Index wird nicht verwendet:
    - 1000 I/Os
  - R nicht clustered; Index wird nicht verwendet:
    - 20000 I/Os
  - V(R,a)=100; Index ist clustering:
    - 1000/100 = 10 I/Os
  - V(R,a) = 10; Index ist nicht clustering:
    - 20000/10 = 2000 I/Os
    - Falls R clustered: Lieber ganz R einlesen (1000 I/O)
  - V(R,a) = 20000 (d.h. a ist Schlüssel):
    - 1 I/O

Joining mit Index

- Natural Join: $R(X,Y) \bowtie S(Y,Z)$
- Algorithmus
  - S habe Index auf Y.
  - Lese jeden Block in R.
  - Für jedes Tupel: Extrahiere Y-Wert und verwende Index um entsprechendes S-Tupel zu finden
- Kosten
  - Falls R clustered: B(R)
  - Für jedes der T(R) Tupel muss man durchschnittlich T(S)/V(S,Y) Tupel lesen.
    - Falls Index nicht clustering ist: $T(R) \cdot T(S)/V(S,Y)$
    - Falls Index clustering: $T(R) \cdot B(S)/V(S,Y)$
      bzw. genauer: $T(R) \cdot \max[\,1\,,\,B(S)\,/\,V(S,Y)]$
    - Dominiert Kosten B(R) bzw. T(R)

Joining mit Index – Beispiel

- B(R) = 1000, B(S) = 500, T(R) = 10000, T(S) = 5000
  - 10 Tupel pro Block
- V(S,Y) = 100 (also 100 distinct Y-Werte in S)
- R sei clustered; Index auf S[Y] sei clustering
- I/O-Kosten:
  - 1000 zum Lesen von R
  - $10000 \cdot 500/100 = 50000$ I/Os zum Vergleich mit S
- Diskussion
  - Klappt besser falls R sehr klein => Viele Blöcke von S werden nie angefasst
  - Bei Hash- und Sort-basierten Methoden werden hingegen immer *ganz* R und *ganz* S betrachtet

Joining mit sortiertem Index

- Sortierter, dichtbesetzter Index, z.B. B-Baum
- Idee 1: Sort-Merge-Join, aber nur eine Relation muss vorher sortiert werden.
- Idee 2: Falls beide Relationen sortierten Index auf Y haben: Nur noch Merge-Phase
  - „Zig-Zag-Join"
  - Tupel aus R ohne Joinpartner in S werden nie gelesen (und umgekehrt)

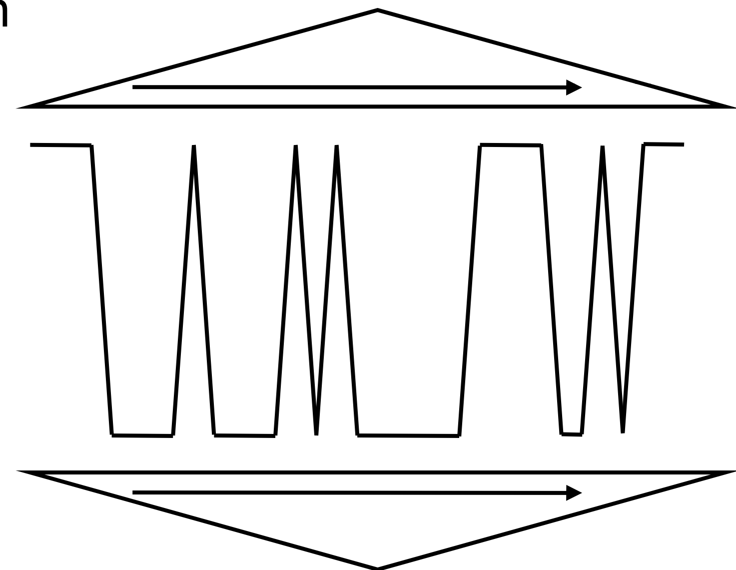

Zig-Zag-Join – Beispiel

- Y-Werte in R: 1, 3, 4, 4, 4, 5, 6
- Y-Werte in S: 2, 2, 4, 4, 6, 7

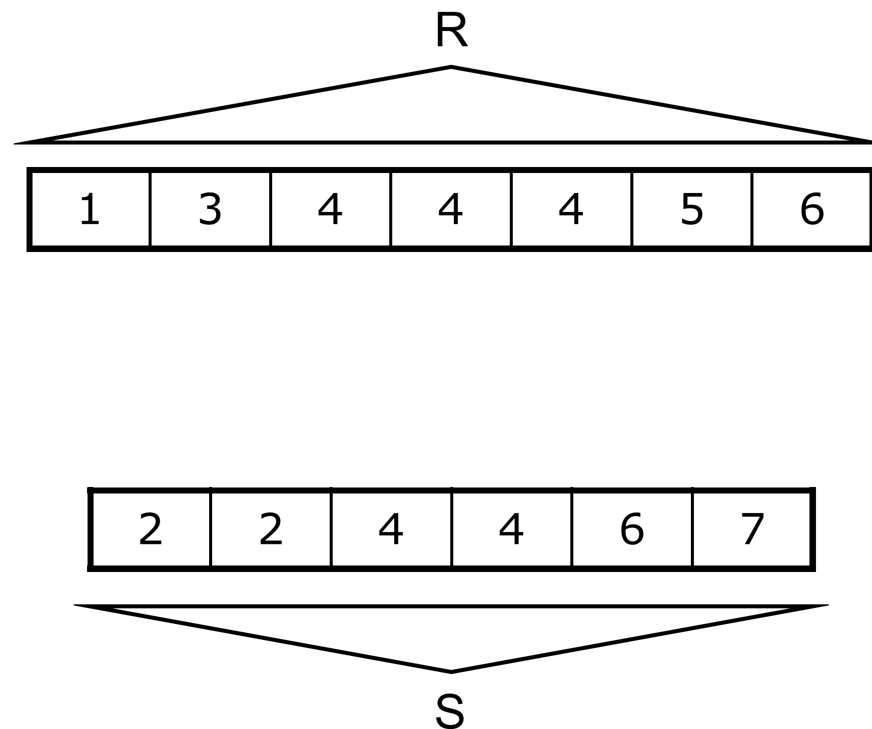

Joining mit Indizes – Beispiel Idee 1

- B(R) = 1000, B(S) = 500, T(R) = 10000, T(S) = 5000
- Seien R und S clustered; S habe sortierten Index auf Y; R habe keinen Index
- 10 sortierte Teillisten für R: 2000 I/Os
- Nun 11 Puffer: Einen für jede Teilliste, einen für Blöcke aus S
  - Ganz R und ganz S werden gelesen: 1500 I/Os
- Zusammen 3500 I/O
  - Wieder weniger als bisher!
    - Aber sortierter Index wird vorausgesetzt…

- Idee 2: Nun habe R auch einen Index
  - Sortierung der Relationen ist unnötig: Zig-Zag-Join
  - Schlimmstenfalls nur ganz R und ganz S lesen: 1500 I/O
  - Bei wenigen Joinpartnern: Viel weniger I/Os

Überblick

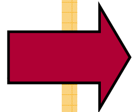

- Physische Operatoren
- One-Pass Algorithmen
- Nested Loop Join
- Sort-basierte Two-Pass Algorithmen
- Hash-basierte Two-Pass Algorithmen
- Index-basierte Algorithmen
- Puffermanagement

Puffermanager

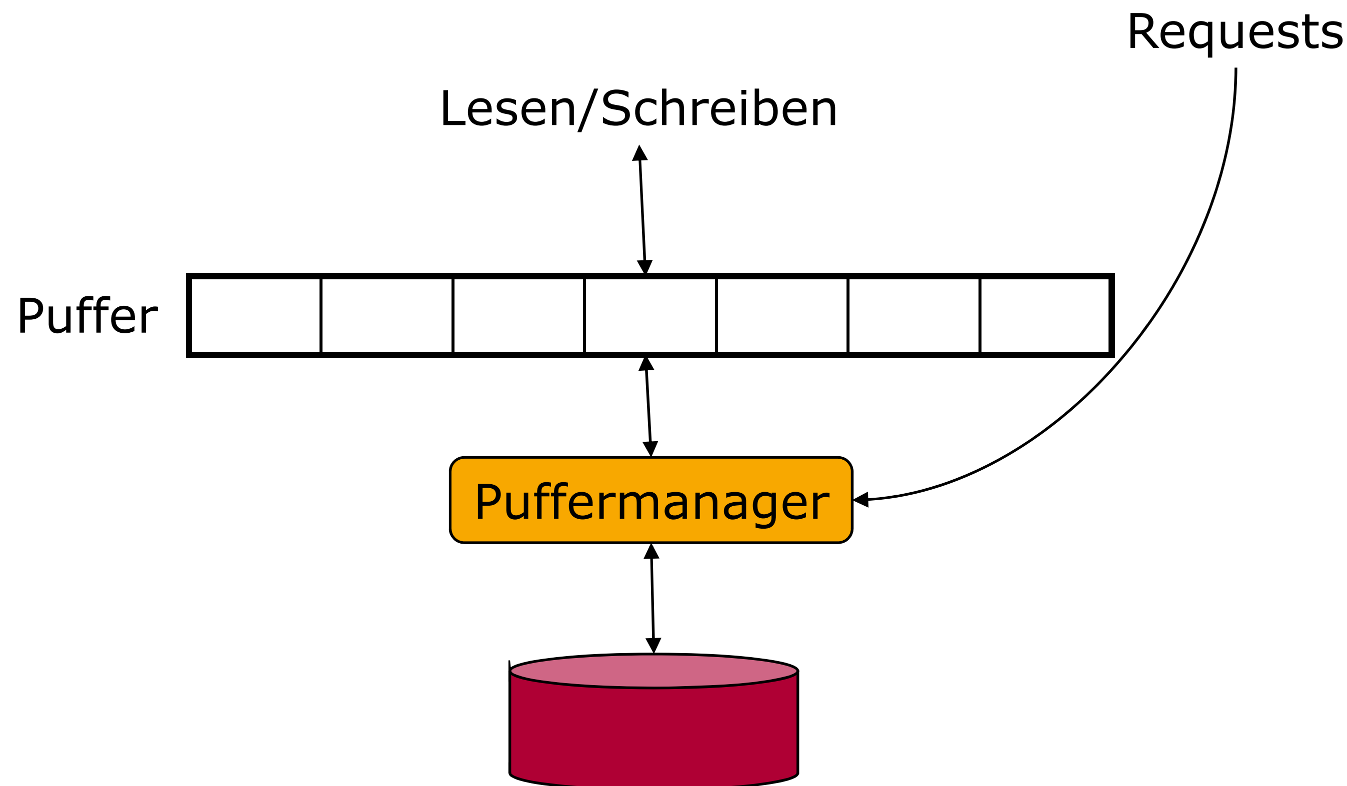

Variante 1: Puffermanager verwaltet Hauptspeicher direkt.
Variante 2: Puffermanager verwaltet virtuellen Speicher und OS verwaltet physischen Hauptspeicher.

Puffermanager – Aufgaben

- Gesamtspeicher darf nicht überschritten werden
  - Verwaltung eines Bufferpools
  - Größe des Bufferpool bei Initialisierung festgelegt
- Gegebenenfalls Block im Speicher verwerfen
  - Löschen
  - Gegebenenfalls auf Disk schreiben
  - Verdrängungsstrategie

Verdrängungsstrategien

- LRU – Least Recently Used
  - Verwirft Block, der am längsten weder gelesen noch geschrieben wurde.
  - Verwaltung der Lese- und Schreibzeiten mit jedem Zugriff nötig: Aufwändig!
- FIFO – First-In-First-Out
  - Puffer, der am längsten gleichen Block enthält wird geleert.
  - Verwaltung einfacher: Nur erste Zeit muss gemerkt werden
  - Aber „fehler"-anfällig. Wieso?
    - Wurzel eines B-Baums
- Clock Algorithmus
  - Häufig verwendet; approximiert LRU

Clock Algorithmus

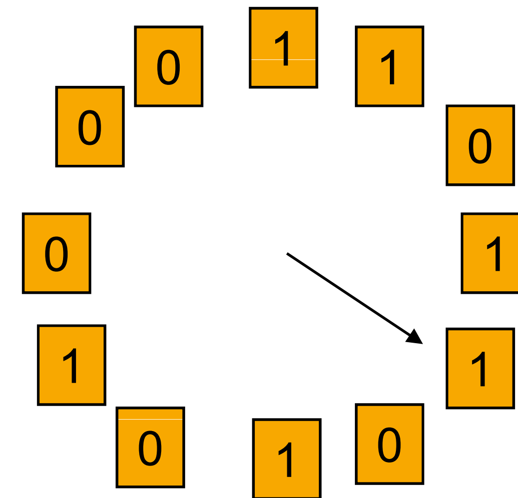

- Auch „Second Chance"
- Puffer im „Kreis" angeordnet
- Jeder Puffer hat ein Bit als flag
  - 0: Puffer kann entleert werden
  - 1: Puffer kann nicht entleert werden
- Beim ersten Befüllen des Puffers: 1
- Bei Zugriff auf den Puffer: 1
- „Zeiger" wandert im Uhrzeigersinn, wenn neuer Puffer benötigt wird
  - Falls flag = 1: Setzte Flag auf 0 und wandere weiter
  - Falls flag = 0: Entleere Puffer
- Variationen mit anderen Werten als 0 und 1
  - Hohe Werte für besonders wichtige Seiten

Zusammenfassung

Hasso Plattner Institut

- Physische Operatoren
- One-Pass Algorithmen
- Nested Loop Join
- Sort-basierte Two-Pass Algorithmen
- Hash-basierte Two-Pass Algorithmen
- Index-basierte Algorithmen
- Puffermanagement