6. Implementierung relationaler Operationen

- Selektion
- Verbundalgorithmen
  - Nested-Loop-Join / Nested-Block-Join
  - Sort-Merge-Join
  - Hash-Join und Varianten
  - Mehrwege-Joins
- Sortierung
- Weitere Operationen

Implementierung der Selektion

- Relationen-Scan (Scan-Operator)
  - immer möglich
  - Definition von einfachen Suchargumenten
  - Start- und Stop-Bedingungen für Bereichsanfragen
  - Attributprojektion (ohne Duplikateliminierung)
- Index-Scan
  - Auswahl des kostengünstigsten Index
  - Spezifikation des Suchbereichs (Start-, Stop-Bedingungen)
- TID-Algorithmus
  - Auswertung aller "brauchbaren" Indexstrukturen
  - Auffinden von variabel langen TID-Listen
  - Boole'sche Verknüpfung der einzelnen Listen
  - Zugriff zu den Tupeln entsprechend der Zielliste
  - bei Plattenspeichern TID-Sortierung zur Minimierung von Plattenzugriffsarmbewegungen sinnvoll
- Boole'sche Verknüpfung von Bit-Indizes

Join-Algorithmen

- Verbund (Join)
  - satztypübergreifende Operation: gewöhnlich sehr teuer
  - häufige Nutzung: wichtiger Optimierungskandidat
  - typische Anwendung: Gleichverbund
  - allgemeiner Θ-Verbund selten
- Implementierung der Verbundoperation kann gleichzeitig Selektionen auf den beteiligten Relationen R und S ausführen

```
SELECT   *
FROM     R, S
WHERE    R.VA Θ S.VA AND P_R AND P_S
```

```
SELECT P.*
FROM PERS P, ABT A
WHERE P.ANR=A.ANR AND
P.Alter<30 AND A.Ort=„Leipzig“
```

  - VA: Verbundattribute
  - P_R und P_S: Prädikate definiert auf Selektionsattributen (SA) von R und S

- mögliche Zugriffspfade
  - Scans über R und S (immer möglich)
  - Scans über I(R(VA)), I(S(VA)) (wenn vorhanden) → liefern Sortierreihenfolge nach VA
  - Scans über I(R(SA)), I(S(SA)) (wenn vorhanden) → ggf. schnelle Selektion für P_R und P_S
  - Scans über andere Indexstrukturen (wenn vorhanden) → ggf. schnelleres Auffinden aller Sätze

Nested-Loop-Join

- Annahme:
  - Sätze in R und S sind nicht nach den Verbundattributen geordnet oder
  - es sind keine Indexstrukturen I(R(VA)) und I(S(VA)) vorhanden
- Berechnung allgemeiner Θ-Joins

Algorithmus

Scan über R,
für jeden Satz r, falls P_R:
  Scan über S,
  für jeden Satz s,
    falls P_S AND (r.VA Θ s.VA)
    führe Verbund aus, d.h. übernehme
    kombinierten Satz (r, s) in Resultatmenge

Beispiel: Gleichverbund zwischen PERS und ABT über ANR

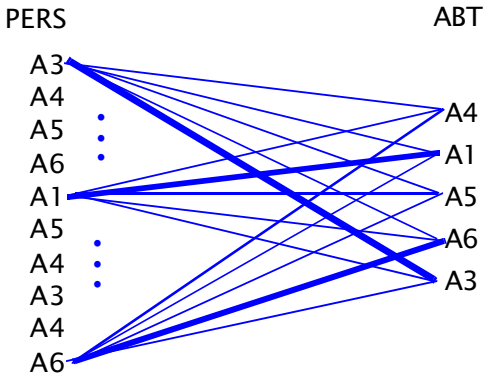

- **quadratische Komplexität**: O (N^2) (Kardinalität N für R und S)

Nested-Loop-Join: Varianten

- Nested-Loop-Join mit Indexzugriff auf innere Relation S (Gleichverbund)

Scan über R,
für jeden Satz r, falls P_R:
    ermittle mittels Indexzugriff für S alle TIDs für Sätze s mit s.VA = r.VA
    für jedes TID,
        hole Satz s,
        falls P_S: übernehme kombinierten Satz (r, s) in die Resultatmenge

Nested-Block-Join

Scan über R,
für jede **Seite** (bzw. Menge benachbarter Seiten) von R:
  Scan über S,
  für jede **Seite** (bzw. Menge benachbarter Seiten) von S:
    für jeden Satz r der R-Seite, falls P_R:
      für jeden Satz s der S-Seite,
        falls P_S AND (r.VA Θ s.VA):
        übernehme kombinierten Satz (r, s) in die Resultatmenge

- Beispiel: R 1 Million Sätze; S 20.000 Sätze; Blockungsfaktor B =50
  - 20 Milliarden Satzvergleiche wenn keine Reduktion über Selektionsprädikate
  - Anzahl Blöcke: n = |R| / B = 20 000, m = |S| / B = 400

#Blockzugriffe abhängig von nutzbarer Hauptspeichergröße

  - nutzbare Hauptspeichergröße **M**=2 Blöcke
    - n*m Blockzugriffe -> 20000 *400=8 Millionen Blockzugriffe
  - M= 101 Seiten
    - 100 Seiten für S, 1 Seite für R
    - -> 4 * (100 +20 000) = 80 400 Seiten
  - M=m+1 (401 Seiten): m+ n Seitenzugriffe -> 20 400 Zugriffe (lineare Kosten für E/A)

(Sort-) Merge-Join

- nur für Gleichverbund
- Algorithmus besteht aus 2 Phasen:
  - Phase 1: Sortierung von R und S nach R(VA) und S(VA), falls nicht bereits vorhanden. dabei frühzeitige Eliminierung nicht benötigter Sätze ($\rightarrow P_R, P_S$)
  - Phase 2: schritthaltende Scans über sortierte R- und S-Sätze mit Durchführung des Verbundes bei r.VA = s.VA

Beispiel: Gleichverbund zwischen PERS und ABT über ANR

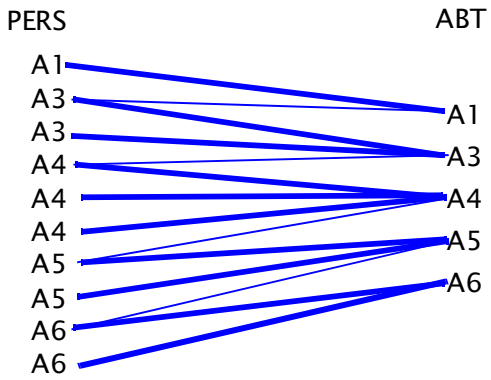

- **Komplexität**: O (N) bei vorliegender Sortierung, ansonsten O (N log N)
- Spezialfall: Ausnutzung von Indexstrukturen auf Verbundattributen

  (Annahme: I(R(VA)) und I(S(VA)) vorhanden)
  - schritthaltende Scans über I(R(VA)) und I(S(VA))
  - falls R(VA) = S(VA), Überprüfung von P_R und P_S in den zugehörigen Sätzen
  - falls P_R und P_S, Bildung des Verbundes

Hash-Join

- nur für Gleichverbund
- Idealfall: kleinere (innere) Relation S passt vollständig in Hauptspeicher
  - Building-Phase: Einlesen von S und falls P_S Speicherung in einer Hash-Tabelle unter Anwendung einer Hash-Funktion h auf dem Join-Attribut
  - Probing-Phase: Einlesen von R und falls P_R Überprüfung für jeden Join-Attributwert, ob zugehörige S-Tupel vorliegen (wenn ja, erfolgt Übernahme ins Join-Ergebnis)
- Vorteile
  - lineare Kosten O (N)
  - Partitionierung des Suchraumes: Suche nach Verbundpartnern nur innerhalb 1 Hash-Klasse
  - Nutzung großer Hauptspeicher
  - auch für Joins auf Zwischenergebnissen gut nutzbar

Hash-Join: Multi-Core Optimierung

- parallele Build- und Probing-Phasen durch p Threads
- Zerlegung beider Eingabetabellen in p gleich große Partitionen
- Schreibsynchronisation auf gemeinsame Hash-Tabelle in Build-Phase
  - Semaphor (Latch) pro Hash-Klasse
  - geringe Konfliktgefahr vbei vielen (Millionen) von Hash-Klassen
- paralleles Probing (nur Lesezugriffe auf Hash-Tabelle)
- Partitionierung der Eingabetabellen ermöglicht auch bessere Cache-Tefferraten

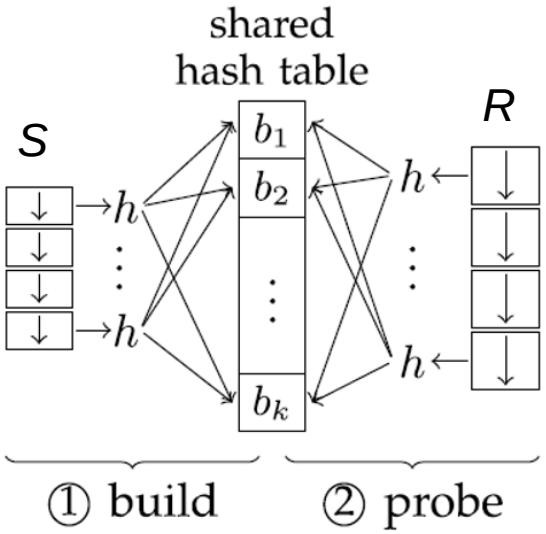

Hash-Join (2)

- allgemeiner Fall: kleinere Relation passt nicht vollständig in Hauptspeicher => Überlaufbehandlung durch Partitionierung der Eingaberelationen
  - Partitionierung von S und R in q Partitionen über (Hash-)Funktion g auf dem Join-Attribut, so dass jede S-Partition in den Hauptspeicher passt
  - q-fache Anwendung des Basisalgorithmus' auf je zwei zusammengehörigen Partitionen
- rund 3-facher E/A-Aufwand gegenüber Basisverfahren ohne Überlauf
  - Lesen und partitioniertes Zurückschreiben von S und R, Lesen von S und R zur Join-Berechnung

Partitionierungs-Phase für S und R

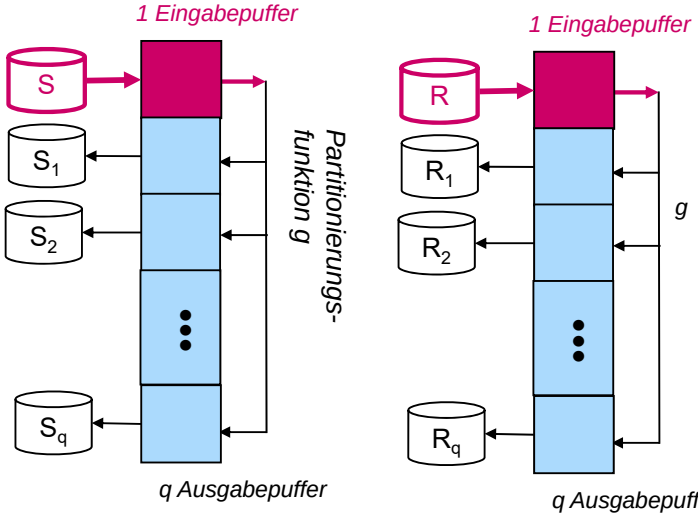

für jedes S_i/R_i (i = 1..q):

Building-Phase für Si

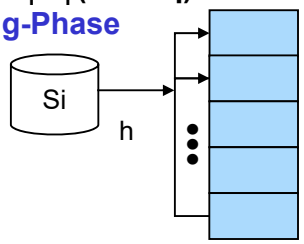

Probing-Phase für Ri

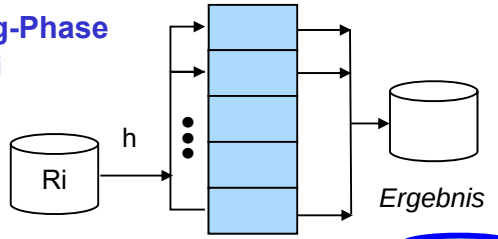

Hash-Join: Varianten (1)

- TID-Hash-Join
  - zur Platzersparnis werden in Hash-Tabelle nur Kombinationen: (Verbundattributwert, TID) gespeichert
  - Idealfall ohne Überlaufbehandlung wird eher erreicht (bzw. weniger Partitionen)
  - separate Materialisierungsphase für Ergebnistupel erforderlich

- Nutzung von Bitvektoren (Hash-Filter)
  - während Partitionierung von S wird Bitvektor erstellt, in dem über Hash-Funktion vorhandenen Join-Attributwerten zugeordnete Bits gesetzt werden
  - nur solche R-Tupel werden weiter berücksichtigt (während Partitionierung von R), für deren Join-Attributwert zugehöriges Bit gesetzt ist
  - kleinere R-Partitionen beschleunigen Join-Verarbeitung

Hash-Filter: Beispiel

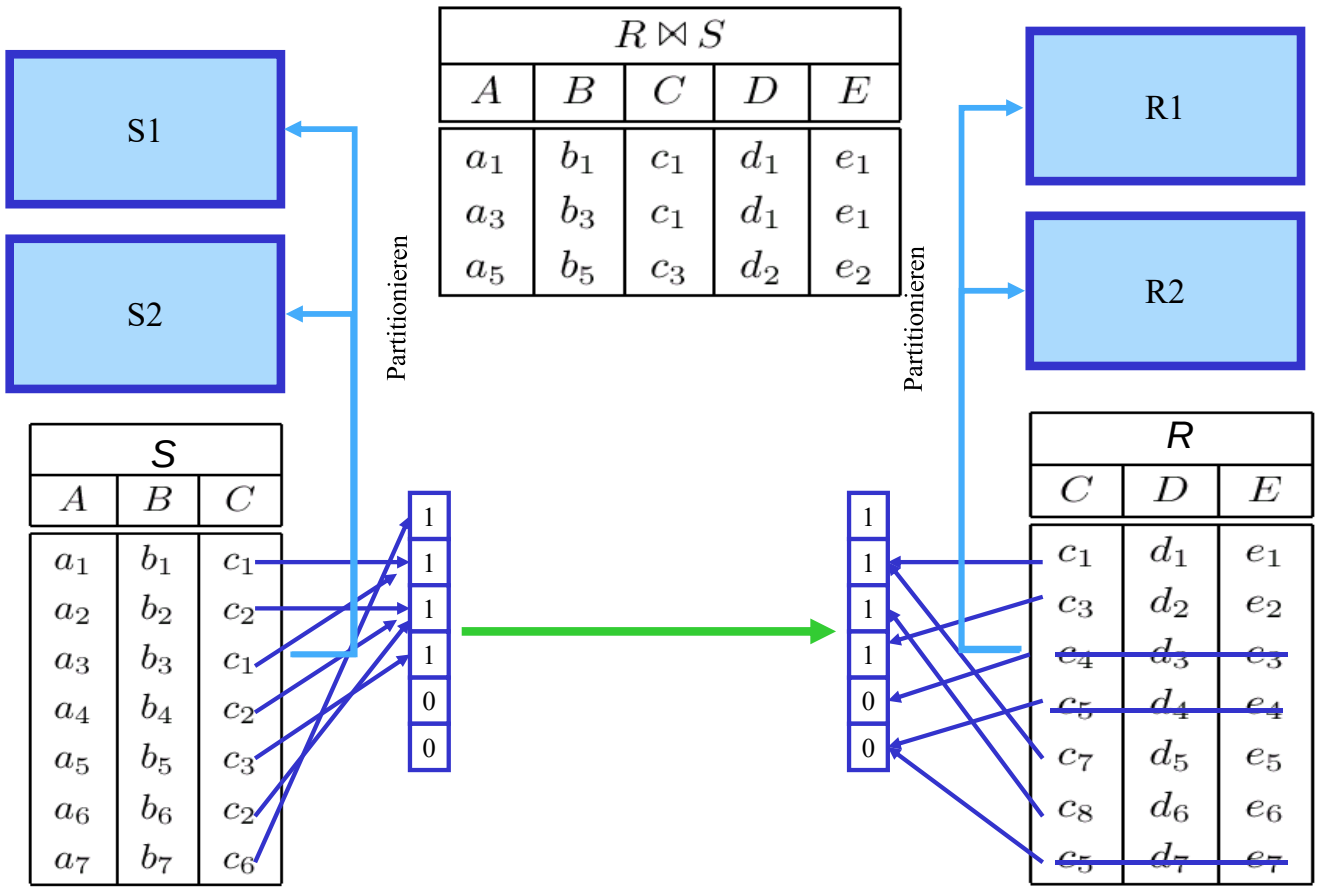

Hash-Join: Varianten (2)

- symmetrischer Hash-Join (double-pipelined Hash Join)
  - Hash-Tabellen für beide Tabellen
  - Nutzung für Joins auf Zwischenergebnissen im Operatorbaum
  - Pipelining: inkrementeller Aufbau der Hash-Tabellen und Test auf Verbundpartner
  - keine Blockierung der Operator-Pipeline bis Eingabedaten für Building-Phase vollständig vorliegen

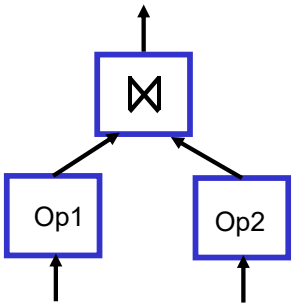

Symmetrischer Hash-Join

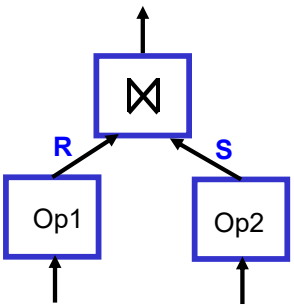

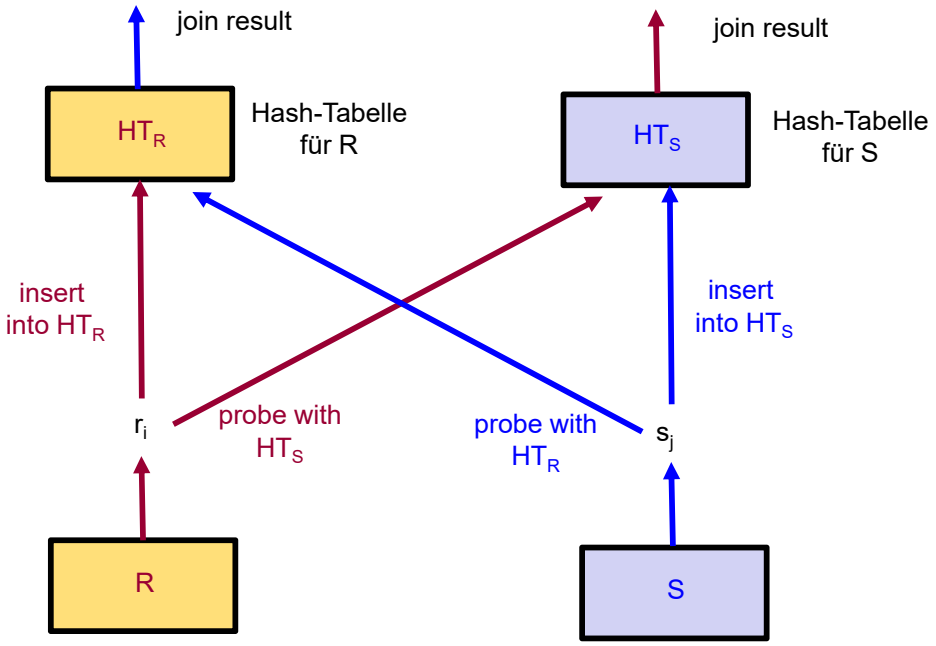

Verbundalgorithmen - Vergleich

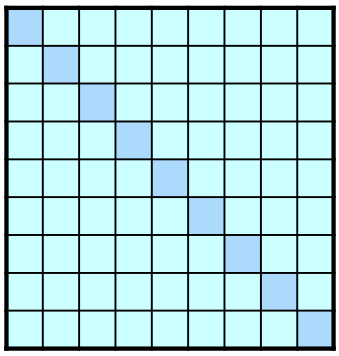

Nested-Loop

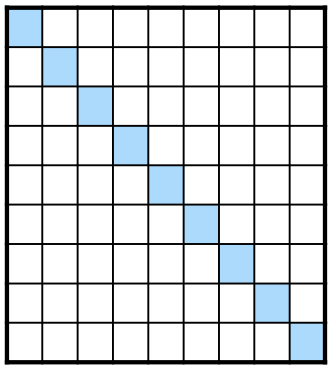

Merge

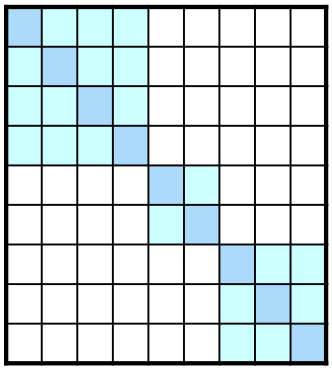

Hash-Join

Elementvergleich

Elementvergleich, der zu Join-Ergebnis führt

- Nested-Loop-Join: immer anwendbar, vollständiges Durchsuchen des gesamten Suchraums
- Sort-Merge-Join: geringste Suchkosten für Gleichverbund, falls Indexstrukturen auf beiden Verbundattributen vorhanden. Sortieren beider Relationen nach Verbundattributen reduziert ansonsten den Kostenvorteil erheblich
- Hash-Join: Partitionierung des Suchraums für Gleichverbund

Mehrwege-Join

- N-Wege-Verbund (N Relationen) kann durch N-1 2-Wege-Joins realisiert werden

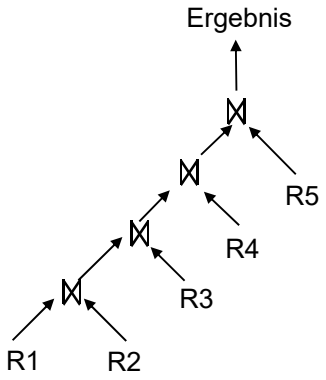

linear tree

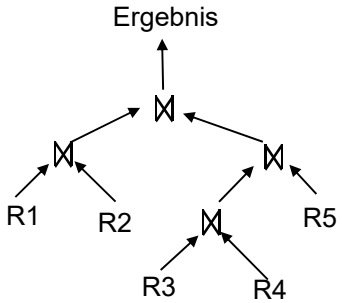

bushy tree

- komplexe Optimierung
  - N! mögliche lineare Verbundreihenfolgen
  - lineare (left-deep, right-deep) vs. unbeschränkte (bushy) Join-Bäume
  - Festlegung von N-1 Verbundmethoden
  - Nutzung von Pipelining, um Speicherung temporärer Zwischenergebnisse zu reduzieren

Externes Sortieren: Merge-Sort

- große Datenmengen können nicht im Hauptspeicher sortiert werden
  - Einlesen und Zerlegung der Eingabe in m Läufe (runs)
  - Sortieren und Zwischenspeichern (Zurückschreiben) der sortierten Läufe
  - Einlesen und sukzessives Mischen der Läufe bis 1 sortierter Lauf entsteht
- optimaler Fall: nur 1 Misch-Durchgang

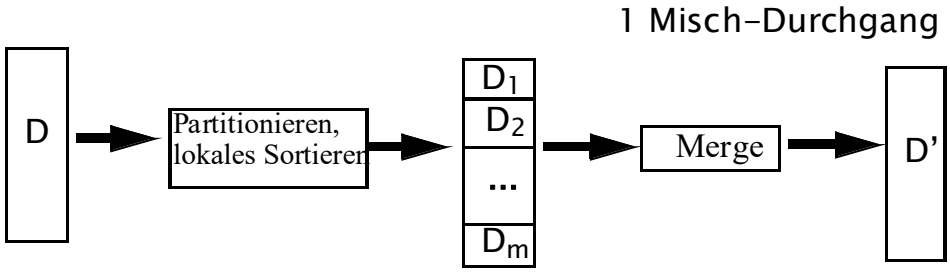

- allgemeiner Fall: k-Wege-Merge-Sort

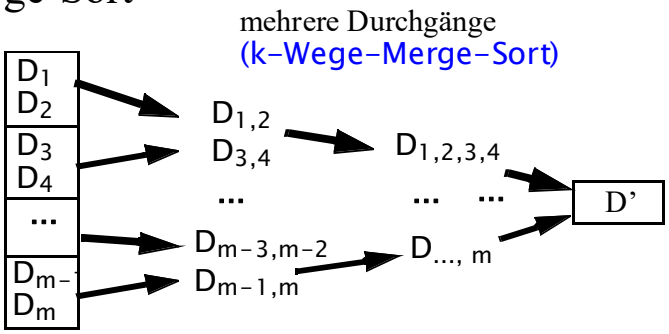

Mischen: Beispiel

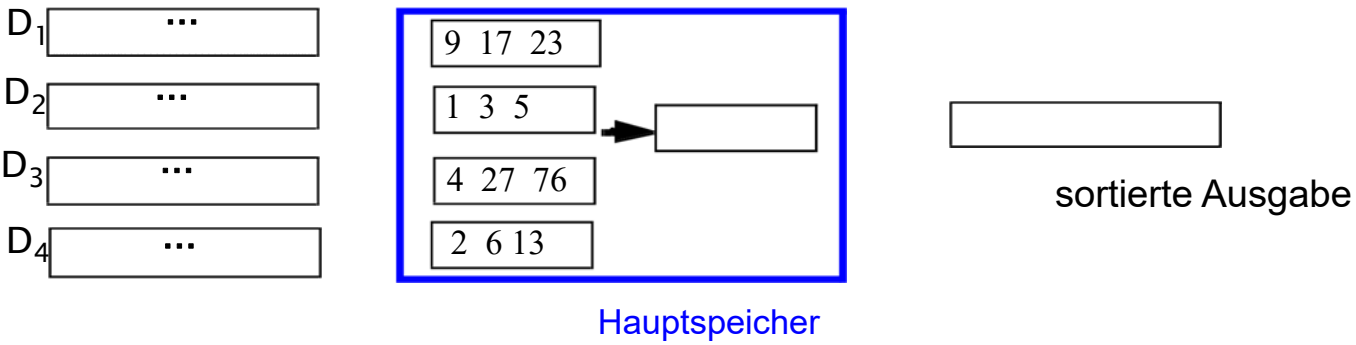

Externes Sortieren (3)

- Anzahl der initialen Läufe m hängt vom verfügbaren Hauptspeicher (HS) ab
  - bei M+1 HS-Seiten können M Läufe gemischt werden (1 Seite zur Generierung der Ausgabe)
  - der Umfang eines initialen Laufes kann höchstens M Seiten umfassen, um eine interne Sortierung zu ermöglichen $m \geq N/M$ (N = #Seiten der Eingaberelation)
- wünschenswert (1 Misch-Durchgang, #Durchgänge d=1): Zerlegung der unsortierten Eingabe in höchstens M Läufe ($m \leq M$):
  - $M \geq m \geq N/M$ -> $M^2 \geq N$
- Idealfall: $M \geq \sqrt{N}$, $m = \sqrt{N}$ => 1 Misch-Durchgang ausreichend (d=1)
  - linearer E/A-Aufwand für Partitionierung und Mischen
- allgemein gilt für k=M Seiten: $d = \log_M N - 1$

Externes Sortieren (4)

- Beispiele für M=4

a) N=16 : m=4

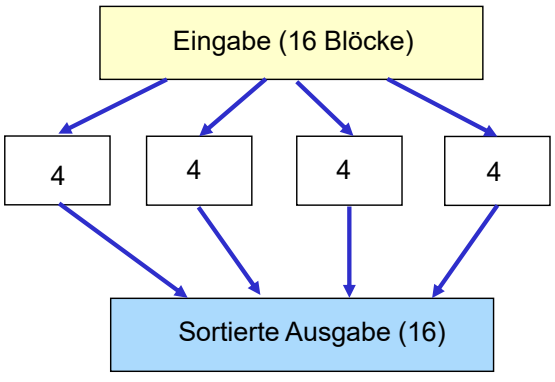

b) N=64: m=16

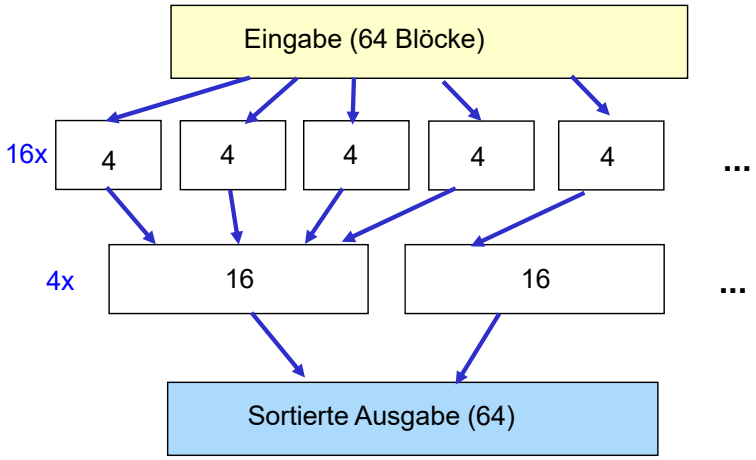

- Sortieren von 1 TB Daten:
  - N = 125 Millionen Seiten , $\sqrt{N}$ = 11 180 Seiten

Weitere Operationen

- skalare Aggregatberechnungen: MIN, MAX, COUNT, SUM, AVG
  - Nutzung von Indexstrukturen bzw. sequentielle Abarbeitung
- Kreuzprodukt: Realisierung gemäss Nested-Loop Join
- Durchschnitt / Vereinigung / Differenz: als Spezialfälle von Join realisierbar
  - Beispiel: innere Relation S in Hauptspeicher-Hash-Tabelle
  - modifiziertes Probing mit R zur Bestimmung von Duplikaten und des Ergebnisses
- Duplikat-Eliminierung
  - 1 Eingaberelation
  - Realisierung über Sortierung oder Hash-basierte Strategien
- Gruppierung
  - Sortierung bzw. Hashing bezüglich Gruppierungsattribut
  - pro Attributwert Bestimmung der in Anfrage geforderten Aggregatwerte (SUM, COUNT, MAX etc.)

Zusammenfassung

- Join-Algorithmen
  - Nested-Loop-Join: Basisverfahren, allgemein einsetzbar (Theta-Join; keine Voraussetzungen bezüglich Indexierung)
    - E/A-Reduzierung über Nested-Block-Join (Nutzung größerer Hauptspeicher)
  - Sort-Merge-Join: effizienter Gleichverbund bei Vorliegen einer Sortierung / Indexierung auf Verbundattribut
  - Hash-Join: schneller Gleichverbund mit linearer Komplexität; effiziente Nutzung großer Hautspeicher
  - zahlreiche Varianten, u.a. zur TID-Optimierung, Indexnutzung, Hash-Filter, kombinierte Auswertung von Selektionen ...
- externe Sortierung
  - O (N log N), aber lineare Komplexität falls nur 1 Misch-Durchgang
  - möglich falls bei N zu sortierenden Blöcken Hauptspeicher-Seitenzahl M $> \sqrt{N}$
- Implementierung Mengenoperationen, Duplikateliminierung etc.
  - abbildbar auf Join-artige Verfahren
  - Einsatz von Sortierung oder Hashing