6 Anfragebearbeitung

Übersicht

6.6 Implementierung der Joinoperation

Einfacher Nested-Loop-Join

- Algorithmus

```
for each Tupel r ∈ R do
    for each Tupel s ∈ S do
        if r.A = s.B then
            result := result ∪ (r × s)
```

- Matrixnotation

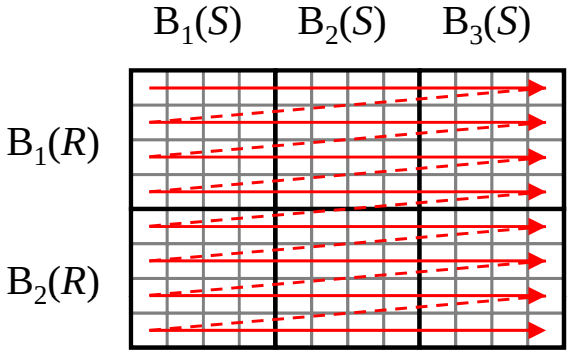

- Der einfache Nested-Loop-Join entspricht der Bildung des kartesischen Produktes in kanonischer Ordnung mit anschließender Selektion.
- Die Relation *S* wird |*R*| mal eingelesen: Performanz ist deshalb inakzeptabel
- *S* wird als innere Relation und *R* als äußere Relation bezeichnet

6.6 Implementierung der Joinoperation

Nested-Block-Loop-Join

- Algorithmus

for each Block $B_R \in R$ do
  lade Block B_R
  for each Block $B_S \in S$ do
    lade Block B_S
    for each Tupel $r \in B_R$ do
      for each Tupel $s \in B_S$ do
        if $r.A = s.B$ then
          $result := result \cup (r \times s)$

- Matrixnotation

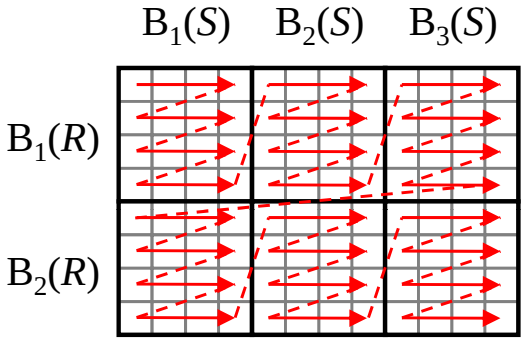

6.6 Implementierung der Joinoperation

Nested-Block-Loop-Join (cont.)

- Beispiel:

S	Angestellter	Gehaltsgruppe	
	Müller	1	$B_S(1)$
	Schneider	2	
	Schuster	1	$B_S(3)$
	Schmidt	2	
	Schütz	1	$B_S(3)$

R	Gehaltsgruppe	Gehalt	
	1	10.000	$B_R(1)$
	2	20.000	
	3	30.000	$B_R(2)$

- Anzahl Blockzugriffe: $B_R + B_S \cdot B_R = 8$ Blockzugriffe ohne Cache
  (B_R = Anzahl Blöcke der Relation R)

- D.h. die kleinere Relation sollte die äußere sein

6.6 Implementierung der Joinoperation

Cache Strategien für Nested-Block-Loop-Join

1. Seiten der inneren Relation im Cache halten

– Cache wird überhaupt nicht ausgenutzt, wenn Cache kleiner als Relation *S* ist

– Beispiel: 2 Seiten Cache für *S*, 1 Seite Cache für *R*
(Zugriff Platte)

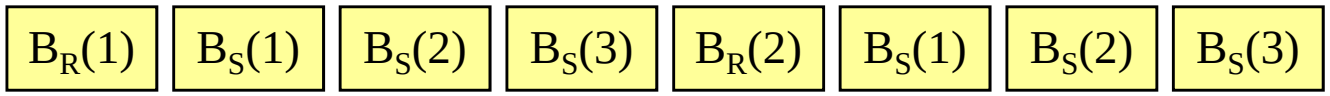

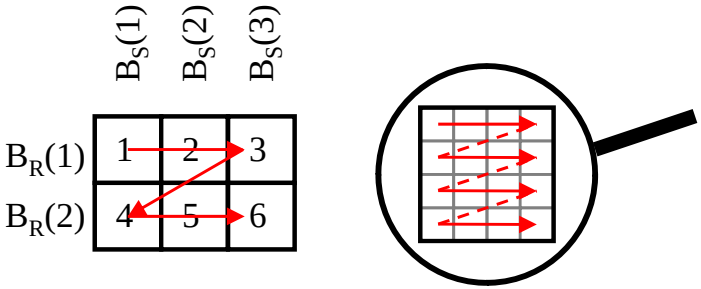

6.6 Implementierung der Joinoperation

Cache Strategien für NBL-Join (cont.)

2. Seiten der inneren Relation im Cache, aber innere Relation jedes zweite mal rückwärts

- Pro Durchlauf der äußeren Schleife werden ($|C|$-1) Blockzugriffe eingespart (ab 2. Durchlauf)
- $|C|$ = Anzahl Blöcke, die in den Cache passen, ein Cache-Block wird jeweils für R-Relation benötigt
- Blockzugriffe: $B_R + B_R \cdot (B_S - |C| + 1) + |C| - 1$
- Beispiel: 2 Seiten Cache für S, 1 Seite Cache für R

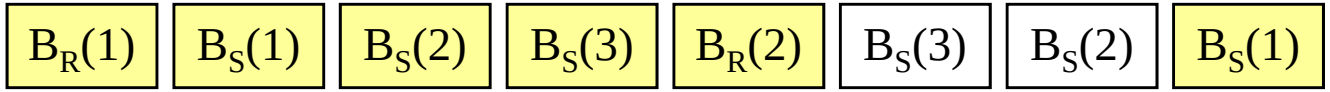

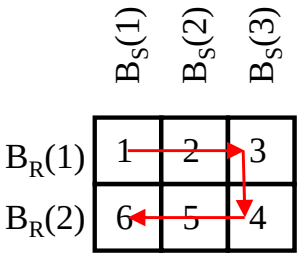

6.6 Implementierung der Joinoperation

Cache Strategien für NBL-Join (cont.)

3. $|C|$-*1* Blöcke der äußeren Relation werden in den Cache eingelesen, zu jedem Block der inneren Relation werden diese Blöcke gejoint

– Blockzugriffe: $B_R + B_S \cdot \left\lceil \frac{B_R}{|C|-1} \right\rceil$

– Beispiel: 2 Seiten Cache für *R*, 1 Seite Cache für *S*

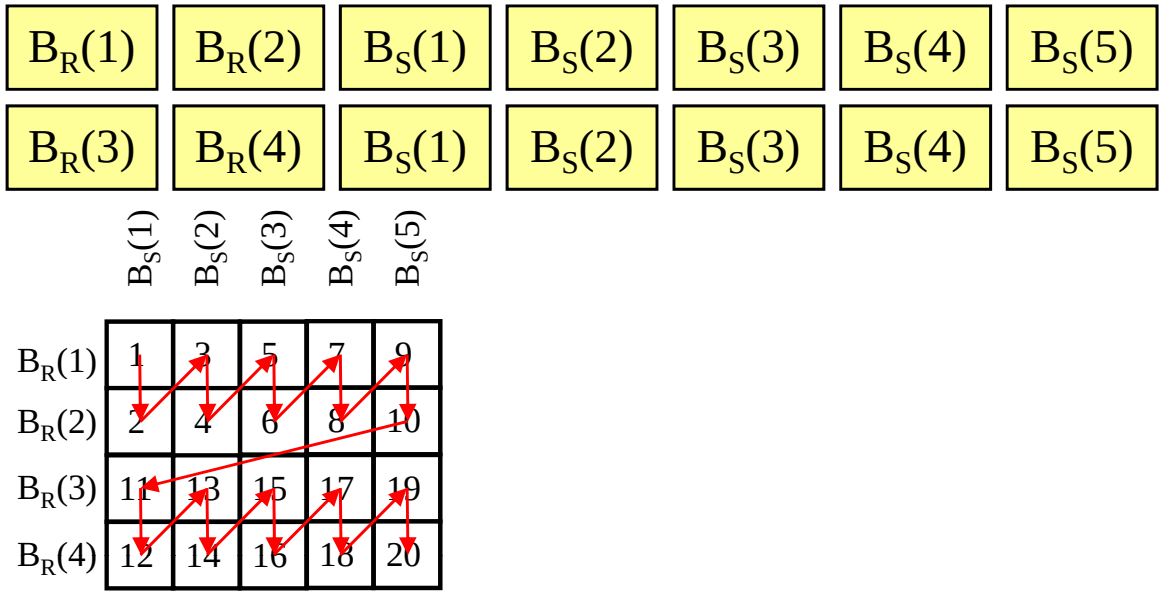

6.6 Implementierung der Joinoperation

Cache Strategien für NBL-Join (cont.)

- Algorithmus für Strategie 3:

```
for i := 1 to B_R step |C| − 1 do
  lade Block B_R(i) ... B_R(i + |C| − 2)
  for each Block B_S ∈ S do
    lade Block B_S
    for each Tupel r ∈ B_R(i) ... B_R(i + |C| − 2) do
      for each Tupel s ∈ B_S do
        if r.A = s.B then
          result := result ∪ (r × s)
```

- Leistung:
  - |R|*|S| Vergleiche von Tupel (ist nur bei schlechter Selektivität gerechtfertigt)
  - Effizienteste Ausführung von θ–Joins mit θ ≠ ‘=‘

6.6 Implementierung der Joinoperation

Blockgrößen-Optimierung NBL-Join

Problem:

- Zu kleine Blockgröße:
  - Innere Relation wird in sehr kleinen Schritten eingelesen
  - Bei jedem I/O-Auftrag Latenzzeit des Plattenlaufwerks

- Zu große Blockgröße (z.B.: Cache wird in 2-3 Blöcke geteilt):
  - Zu wenig Cache steht für die äußere Relation zur Verfügung
  - Innere Relation muss öfter gescanned werden

Äquivalente Frage:

Wie viel vom Cache für äußere/innere Relation?

6.6 Implementierung der Joinoperation

Blockgrößen-Optimierung NBL-Join (cont.)

I/O-Kosten für den gesamten Join:

$$t_{NL-Join} \approx \left\lceil \frac{B_R}{|C|-1} \right\rceil \cdot (2t_{seek} + t_{lat} + b \cdot (|C|-1) \cdot t_{tr}) + B_S \cdot \left\lceil \frac{B_R}{|C|-1} \right\rceil \cdot (t_{lat} + b \cdot t_{tr})$$

- f_R bzw. f_S: Größe der Relationen in Bytes
- c: Größe des Cache in Bytes
- t_{tr}: Transferzeit pro Byte
- t_{lat}: durchschnittliche Latenzzeit des Disk-Laufwerkes
- b: Blockgröße (Parameter, der optimiert wird)

– Vernachlässigung des B_R-Scans (da nur 1 mal und in großen Blöcken)

$$t_{NL-Join} \approx \left(\left\lceil \frac{f_s}{b} \right\rceil \cdot \left\lceil \frac{\lceil f_R / b \rceil}{\lfloor c / b \rfloor - 1} \right\rceil \right) \cdot (t_{lat} + b \cdot t_{tr})$$

6.6 Implementierung der Joinoperation

Blockgrößen-Optimierung NBL-Join (cont.)

	Äußere Relation R	**Innere Relation S**
Anzahl Block-zugriffe	B_R	$B_R + B_S \cdot \left\lceil \frac{B_R}{\lvert C \rvert - 1} \right\rceil$
	Suchen zum aktuellen Block von R + Suchen zum Start von S	
$t_{NL-Join} \approx$	$\left\lceil \frac{B_R}{\lvert C \rvert - 1} \right\rceil \cdot (2t_{seek} + t_{lat} + b \cdot (\lvert C \rvert - 1) \cdot t_{tr})$	$+ \quad B_S \cdot \left\lceil \frac{B_R}{\lvert C \rvert - 1} \right\rceil \cdot (t_{lat} + b \cdot t_{tr})$
	in einer Leseoperation werden |C|-1 Blöcke der äußeren Relation gelesen	Jeweils ein Block wird gelesen, aber nächster Block startet meist auf gleicher Spur
$t_{NL-Join} \approx$	*ignorieren, da nur 1x und in großen Blöcken*	$\left(\left\lceil \frac{f_s}{b} \right\rceil \cdot \left\lceil \frac{\lceil f_R / b \rceil}{\lfloor c / b \rfloor - 1} \right\rceil \right) \cdot (t_{lat} + b \cdot t_{tr})$

f_R bzw. f_S: Größe der Relationen in Bytes
c: Größe des Cache in Bytes
t_{tr}: Transferzeit pro Byte

6.6 Implementierung der Joinoperation

Blockgrößen-Optimierung NBL-Join (cont.)

– Weglassen der Rundungsfunktion (unproblematisch für f_R, f_S >> b, d.h. relativer Fehler ist vernachlässigbar) ergibt stückweise differenzierbaren Term

$$t_{NL-Join} \approx \left(\frac{f_S \cdot f_R}{b^2 \cdot (\lfloor c/b \rfloor - 1)} \right) \cdot \left(t_{lat} + b \cdot t_{tr} \right)$$

– Optimierung der Hüllfunktion

$$t_{hull} \approx \left(\frac{f_S \cdot f_R}{b^2 \cdot ((c/b) - 1)} \right) \cdot \left(t_{lat} + b \cdot t_{tr} \right)$$

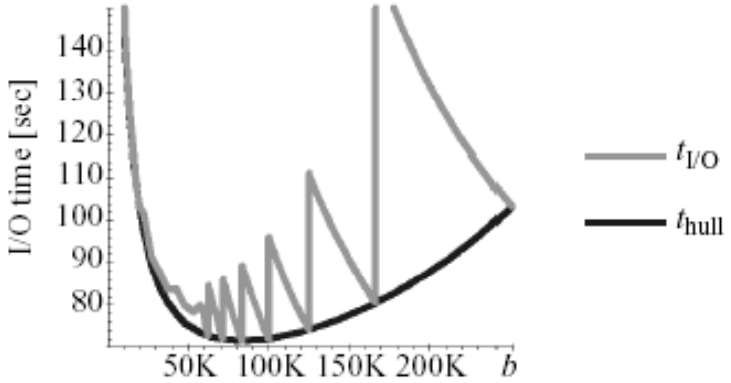

Joinkosten bei

- $f_R = f_S$ = 10MByte
- c = 500 KByte
- t_{lat} = 5 ms
- t_{tr} = 0,25 s /MByte
- b_{opt} = 85 KByte

6.6 Implementierung der Joinoperation

Blockgrößen-Optimierung NBL-Join (cont.)

- **Optimierung durch Differenzieren**
  - Gleichsetzen der 1. Ableitung mit 0
  - 2 Lösungen, von denen nur eine positiv ist

$$0 = \frac{\partial}{\partial b} t_{hull} \Rightarrow b_{opt} = \frac{\sqrt{t_{lat}^2 + t_{tr} \cdot t_{lat} \cdot c} - t_{lat}}{t_{tr}}$$

  - Lösung ist Minimum (s. 2. Ableitung)
  - An den Stellen, an denen $\lfloor c/b \rfloor$ konstant ist, ist t_{NLJoin} streng monoton fallend (negative Ableitung)
  - Deshalb kann das Minimum von t_{NLJoin} nur an der ersten Sprungstelle links oder rechts vom Minimum von t_{hull} sein:

$$b_1 = c / \left\lfloor \frac{c}{b_{opt}} \right\rfloor, \quad b_2 = c / \left\lceil \frac{c}{b_{opt}} \right\rceil$$

Blockgrößen-Optimierung NBL-Join (cont.)

CPU-Kosten

- Im wesentlichen müssen |*S*|*|*R*| Vergleiche durchgeführt werden
- Bei 0.1 µs pro Vergleich und 100.000 Tupel pro Relation ergibt sich eine Bearbeitungszeit von 1000 s.
- D.h. wesentlich mehr als die 75 s I/O-Zeit
- Der NLB-Join ist also *CPU-bound*
- Maßnahmen zur Senkung des CPU-Aufwands später

6.6 Implementierung der Joinoperation

Sort-Merge-Join

- **Zweistufiger Algorithmus**
  - 1.Schritt:

sortiere R bzgl. Attribut A

sortiere S bzgl. Attribut B

  - 2.Schritt:

```
j = 1;
s = erstes Tupel von S;
for i = 1 to |R| do
   r = i - tes Tupel von R;
   while s.B < r.A
      j = j + 1;
      s = j - tes Tupel von S;
   if r.A = s.B then
         result := result ∪ ((r − r.A) × s);
```

Achtung: Dieser Algorithmus funktioniert nur, falls R und S auf dem Joinattribut keine Duplikate enthalten.
Wie muss der Algorithmus erweitert werden um Duplikate zu erfassen?

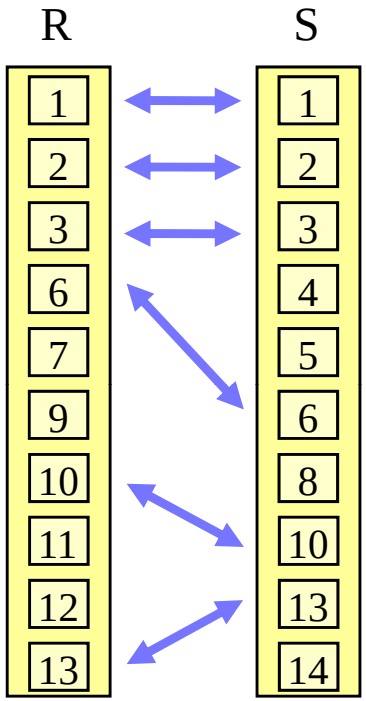

- **Matrixnotation**

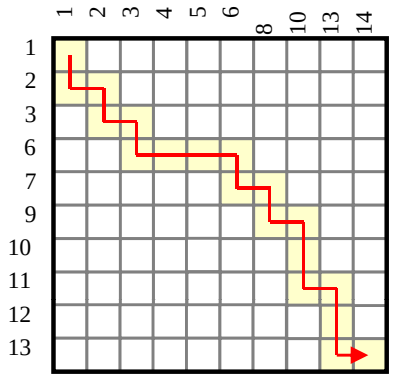

6.6 Implementierung der Joinoperation

Sort-Merge-Join (cont.)

Leistung

- Jede Relation wird genau einmal durchlaufen: $O(|R| + |S|)$ Vergleiche
- Sortieren der Relation kostet $O(|R| \cdot \log |R| + |S| \cdot \log |S|)$
- Sortieren ist nicht notwendig, wenn bereits ein Index existiert
- Verfahren versagt, wenn in beiden Relationen sehr viele Duplikate (d.h. mehr als in den Puffer passen) auftreten. In diesem Fall muss auf Nested-Loop-Join umgeschaltet werden

6.6 Implementierung der Joinoperation

Einfacher Hash-Join

Reduktion des CPU-Aufwandes bei der Join-Berechnung

- Der Join-Partner eines *S*-Tupels wird gezielt mit Hilfe eines Hash-Verfahrens gesucht, anstatt das *S*-Tupel sequentiell mit jedem Tupel der Relation *R* zu vergleichen.
- Zu diesem Zweck wird die Relation *R* gehasht, d.h. es wird zu allen Tupeln der Hash-Key bestimmt und die Tupel in einer Tabelle unter diesem Key eingetragen.
- Nicht alle *R*-Tupel, die den passenden Hash-Key haben, sind Join-Partner eines *S*-Tupels, aber alle Join-Partner haben denselben Hash-Key.
- Im Idealfall soll der Join im Hauptspeicher ablaufen: die Hashtabelle soll für die kleinere Relation erzeugt werden.
- Hash-Join Verfahren können nur für Equi-Join und Natürlichen Join effizient genutzt werden.

Leistung

- hängt stark ab von der Güte der Hashfunktion: $O(|R| + |S|)$ im Idealfall
- verschlechtert sich, wenn Werte ungleichmäßig belegt sind
- Modifikation ist notwendig, wenn Hauptspeicher zu klein (kleiner als *R*)

6.6 Implementierung der Joinoperation

Einfacher Hash-Join (cont.)

- **Algorithmus**

for each Tupel $r \in R$ do
  berechne $adr = hash(r)$;
  speichere r in $HT[adr]$ ab;
for each Tupel $s \in S$ do //prüfe in der Hashtabelle HT
  berechne $adr = hash(s)$;
  for each Tupel $r \in HT[adr]$ do
    if $r.A = s.B$ then
      $result := result \cup ((r - r.A) \times s)$

- **Matrixnotation**

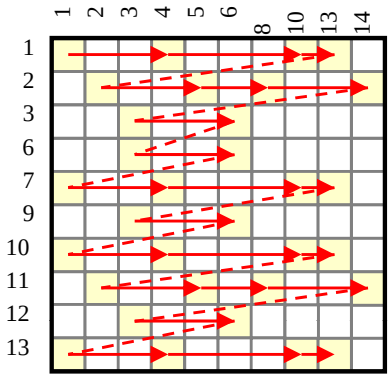

$hash(x)$ = MOD 3

6.6 Implementierung der Joinoperation

Hashed-Loop-Join

- Kombination aus dem Nested-Loop-Join und dem einfachen Hash-Join
- Relation *R* wird in große Blöcke eingeteilt, deren Hashtabellen in den Puffer passen
- Für jeden dieser Blöcke wird die Relation *S* gescannt und ein einfacher Hash-Join durchgeführt
- **Algorithmus**

repeat
  lese soviel Tupel von R in Hauptspeicher bis der Platz aufgebraucht ist;
  erzeuge für diese Tupel eine Hashtabelle HT;
  for each Tupel $s \in S$ do
    berechne $adr = hash(s)$;
    for each Tupel $r \in HT[adr]$ do
      if $r.A = s.B$ then
        $result := result \cup ((r - r.A) \times s)$
until alle Tupel der Relation R sind eingelesen;

6.6 Implementierung der Joinoperation

Hashed-Loop-Join (cont.)

- **Matrixnotation**

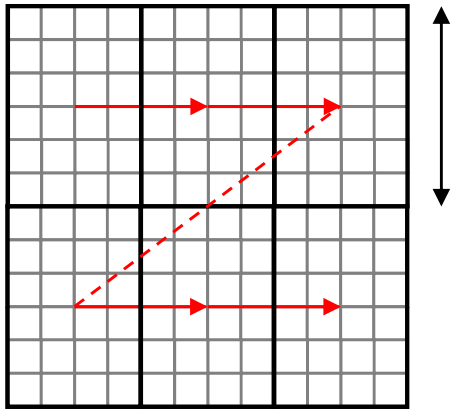

R-Tupel, die in den Puffer passen

auf den einzelnen Blöcken: Hash-Join

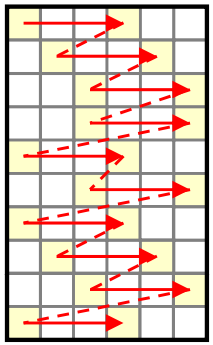

- **Ablauf**

Schritt A:

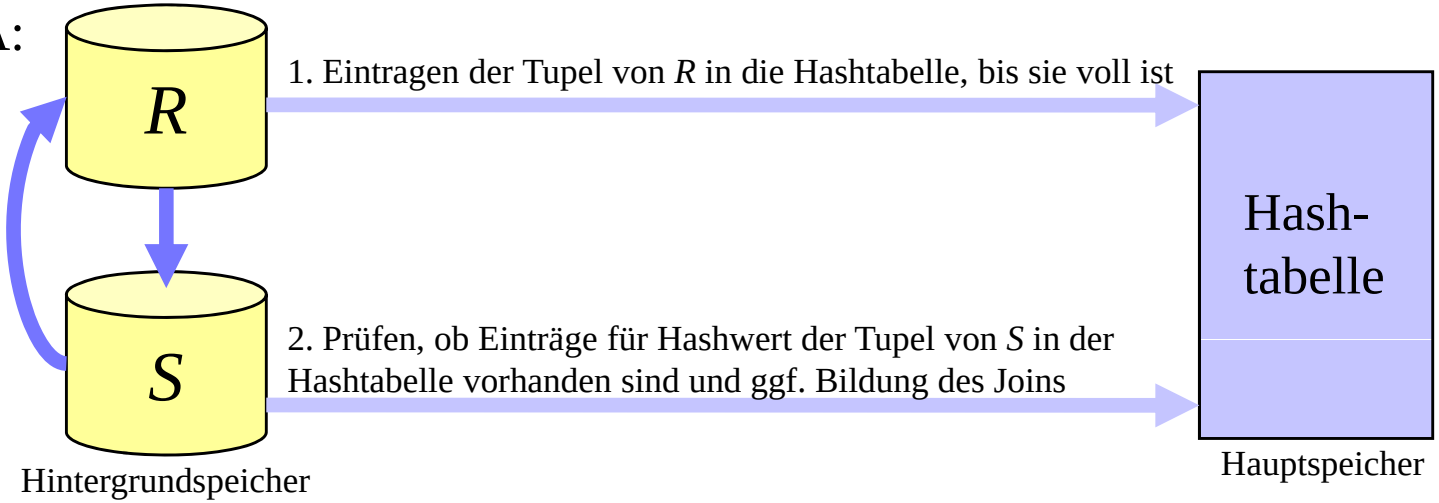

Schritt B: Wiederhole Schritt A für die restlichen Tupel von *R*

6.6 Implementierung der Joinoperation

Hash-Partitioned-Join (GRACE)

- Der Hashed-Loop-Join zerlegt die Relationen willkürlich in Blöcke, jeder Block der *R*-Relation muss mit jedem Block der *S*-Relation kombiniert werden
- Idee: Zerlege die Relationen *R* und *S* mit Hilfe einer Hashfunktion in Partitionen, so dass nur Partitionen mit demselben Hash-Key kombiniert werden müssen
- Zweistufiges Verfahren

1. Partitioniere die Relationen *R* und *S* in $R_1,\ldots,R_N$ und $S_1,\ldots,S_N$
2. Berechne den Join der einzelnen Partitionen R_i und S_i mit einem beliebigen Join Verfahren (z.B. einfacher Hash-Join oder Hashed-Loop-Join wenn Partition zu groß)

Matrixnotation

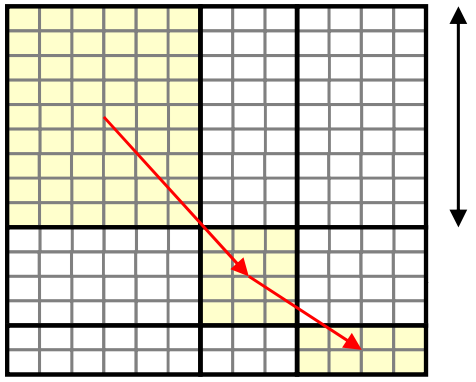

6.6 Implementierung der Joinoperation

Hash-Partitioned-Join (GRACE) (cont.)

- **Ablauf**
  - **Partitionierungsphase**

    Schritt A:

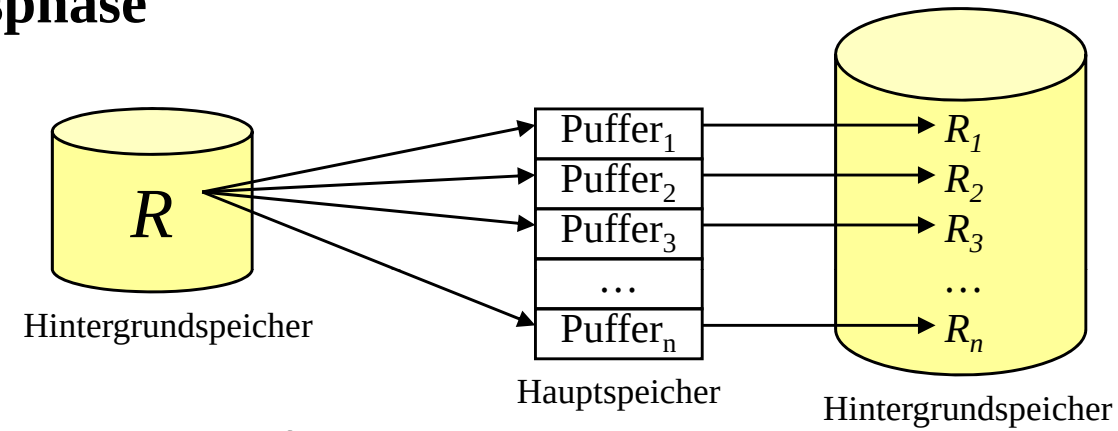

    Schritt B: Wiederhole Schritt A für *S*

  - **Join-Phase**

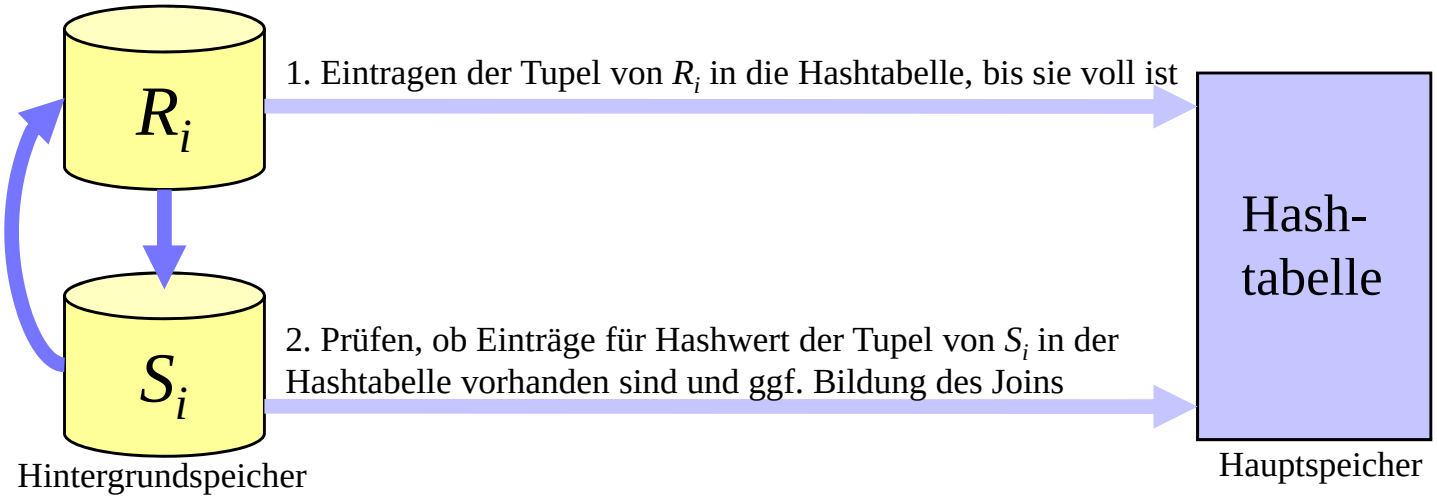

6.6 Implementierung der Joinoperation

Hybrid Hash-Join

- **Algorithmus**

for each Tupel $r \in R$ do
  berechne $adr = hash(r)$;
  if $(adr = 1)$ then
    füge r in eine Hashtabelle HT ein (bzgl. neuer Hashfkt.);
  else
    speichere r in einem Puffer BR_{adr}
    /* wenn der Puffer voll ist, wird er stets auf Platte geschrieben */
for each Tupel $s \in S$ do
  berechne $adr = hash(s)$;
  if $(adr = 1)$ then
    suche in HT nach entsprechenden Tupel r mit $r.A = s.B$;
  else
    speichere s in einem Puffer BS_{adr}
for $i = 2$ to N do
  berechne den Join der Partitionen R_i und S_i mit dem Hashed - Loop - Join

6.6 Implementierung der Joinoperation

Hybrid Hash-Join (cont.)

Ablauf der Partitionierungsphase:

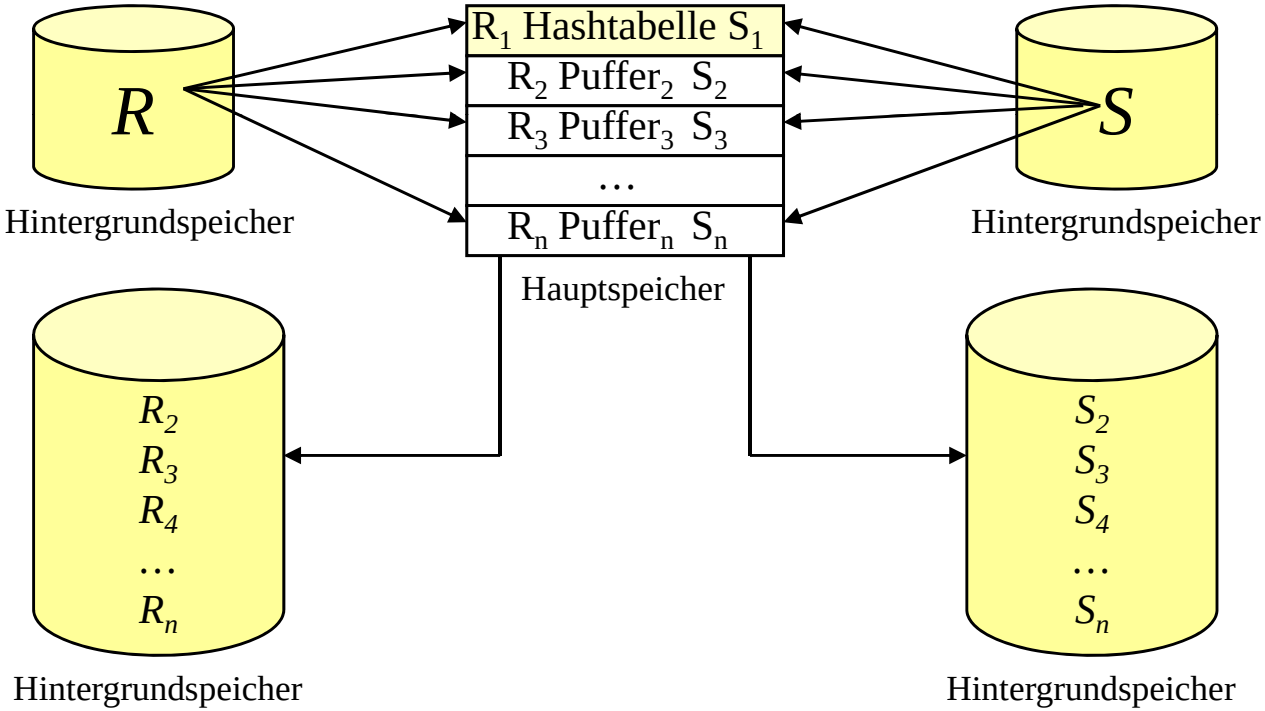

6.6 Implementierung der Joinoperation

Hybrid Hash-Join (cont.)

- **Leistung**
  - Reduzierung der I/O-Kosten (im Vergleich zu GRACE), da eine Partition im Hauptspeicher gehalten wird
  - vorteilhaft, wenn viel Hauptspeicher zur Verfügung steht, aber die Relation *R* nicht komplett im Hauptspeicher gehalten werden kann

- **Probleme aller Hash-Join-Verfahren**
  - ungleiche Datenverteilung (extrem hohe Belegung eines Wertes durch Datensätze)
  - Wie wird die Hashfunktion (und damit die Partitionen) der einzelnen Verfahren gewählt?