5. Verteilte und parallele Anfragebearbeitung

- **Einführung**
- **Verteilte Anfragebearbeitung: Teilschritte**
  - Anfragetransformation
  - Daten-Lokalisierung
  - Globale Optimierung
- **Verteilte / parallele Verarbeitung von Selektion, Projektion, Aggregationen**
- **Verteilte Join-Verarbeitung**
  - Einfache Strategien (Ship Whole, Fetch as Needed)
  - Semi-Join und Bitvektor-Join
- **Parallele Join-Verarbeitung**
  - Dynamische Replikation und Partionierung der Eingaberelationen
  - Paralleler Hash-Join
- **Mehr-Wege-Joins**
- **Parallele Sortierung**

Problemstellung

- **Ziel:**

  Bestimmung eines Ausführungsplanes einer verteilten Anfrage in Abhängigkeit zur Datenverteilung, so daß eine Zielfunktion optimiert wird (z. B. Antwortzeit)

- **Kostenfaktoren:**
  - Nachrichtenanzahl
  - Nachrichtengröße
  - E/A
  - CPU-Bedarf
  - Hauptspeicherbedarf
- **Optimierungsentscheidungen:**
  - Query-Zerlegung in lokal ausführbare Teilanfragen
  - Ausführungsreihenfolge für Restriktion, Projektion und Join
  - Nutzung von Indexstrukturen
  - Parallelisierung von Teilanfragen
  - Auswahl der globalen und lokalen Join-Strategie (Nested-Loop, Sort-Merge, Hash-Join)
  - Rechnerauswahl, z.B. zur Join-Berechnung
  - Auswahl der Replikate
- **Berücksichtigung des aktuellen Systemzustandes zur Laufzeit wünschenswert**

Anfrageoptimierung: Problemstellung

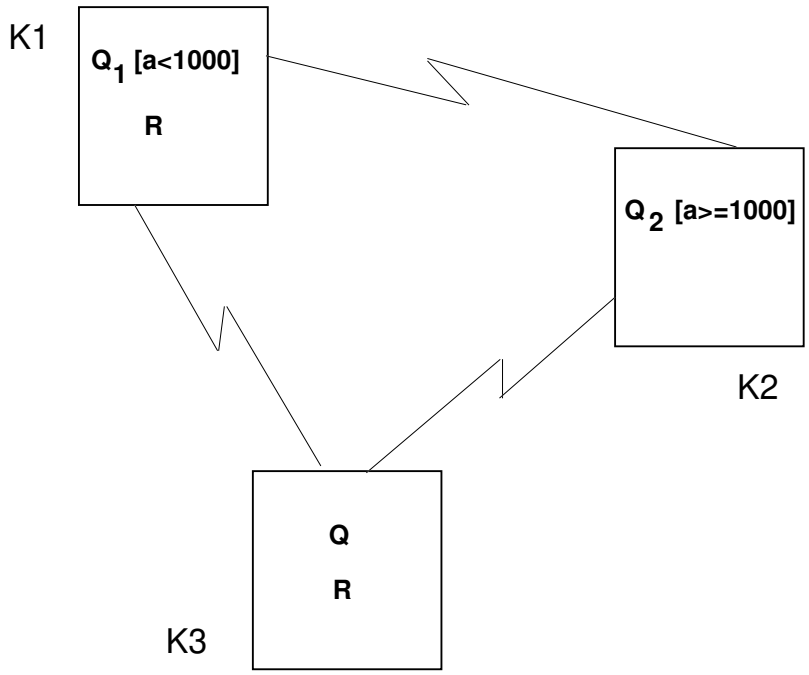

■ **Anfrage in K3:**

SELECT * FROM Q WHERE a IS IN (482, 517, 763);

- lokale Ausführung in K3 oder
- Ausführung in K1 mit (kleinerem) Fragment Q1

■ **Anfrage in K2:**

SELECT x, y, z FROM Q, R WHERE Q.j = R.k;

- Sende Anfrage zur Ausführung nach K3 oder
- Sende Fragment Q2 zur Join-Berechnung nach K1

Anfrage-Optimierung - Beispiel

■ ABT (ANR, AORT,...)
PERS (PNR, PNAME, ANR, ...)

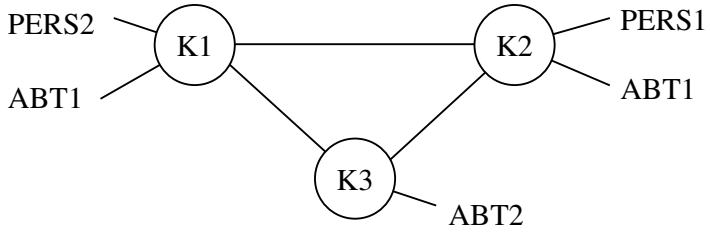

➥ Fragmentierung durch Prädikate
ABT1: AORT = 'Stuttgart' OR AORT = 'München'
ABT2: AORT = 'Frankfurt'
PERS1: ANR ≤ 'K50'
PERS2: ANR > 'K50'

■ **Anfrage in K3:**
Finde die Namen aller Angestellten,
die in Stuttgarter Abteilungen arbeiten

■ **Operatorbaum (Relationenalgebra)**

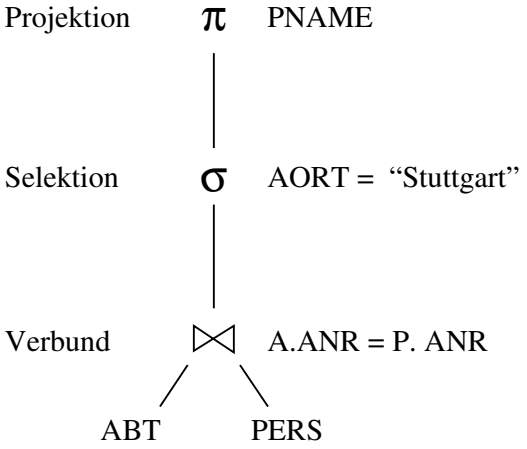

Anfrage-Optimierung - Beispiel (2)

■ **Algebraische Optimierung**

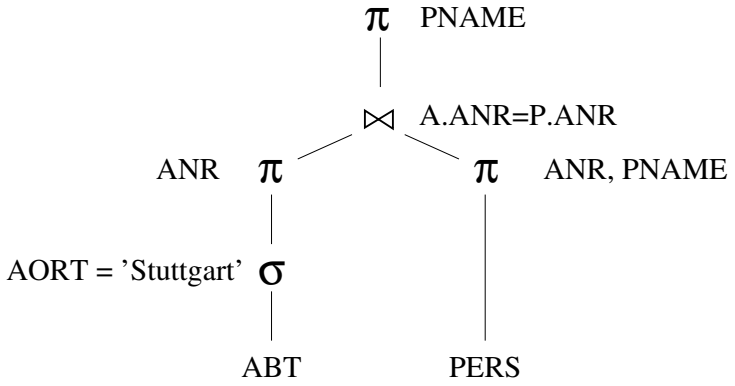

➥ Optimaler Operatorbaum für ein zentralisiertes DBS

■ **Im zentralisierten wie im verteilten Fall:** Fatale Annahmen

- Gleichverteilung aller Attributwerte eines Attributes
- Unabhängigkeit der Attributwerte untereinander
- weitere Annahme: gleichmäßige Belastung des Netzes

➥ Berechnung der erwarteten Anzahl der Nachrichten von obigen Annahmen abhängig

■ **Fragmentierungstransformation**

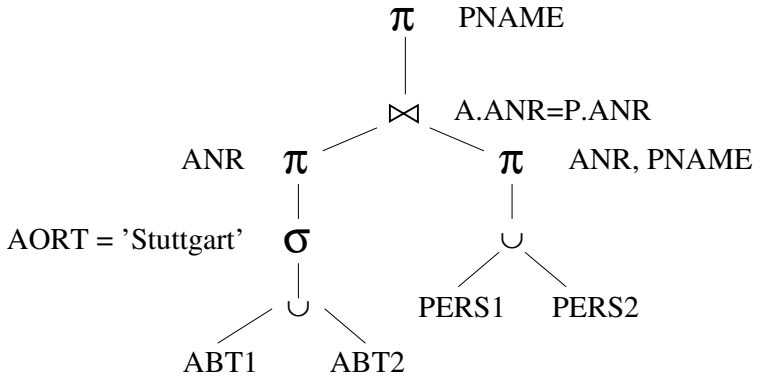

ABT und PERS sind mit Hilfe von Prädikaten fragmentiert

Anfrage-Optimierung - Beispiel (3)

■ **Optimierung und Verteilungstransformation**

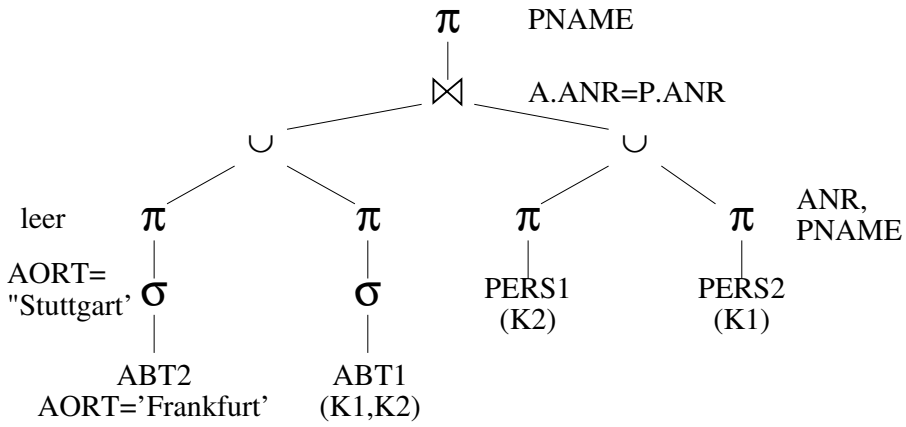

➥ PERS1 und ABT1 in K2
PERS2 und ABT1 in K1
} **erst** ⋈ , **dann** ∪

■ **Verteilungsoptimierung**

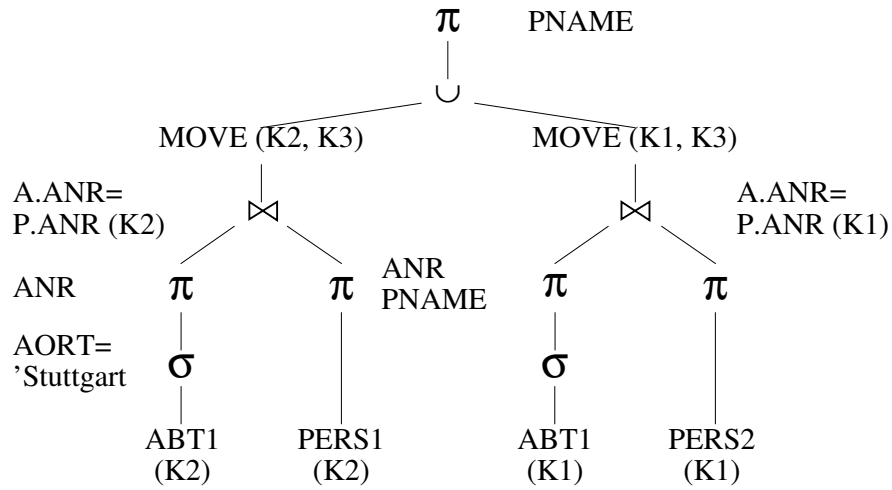

➥ Minimierung des Kommunikationsaufwandes

Phasen der verteilten Anfragebearbeitung

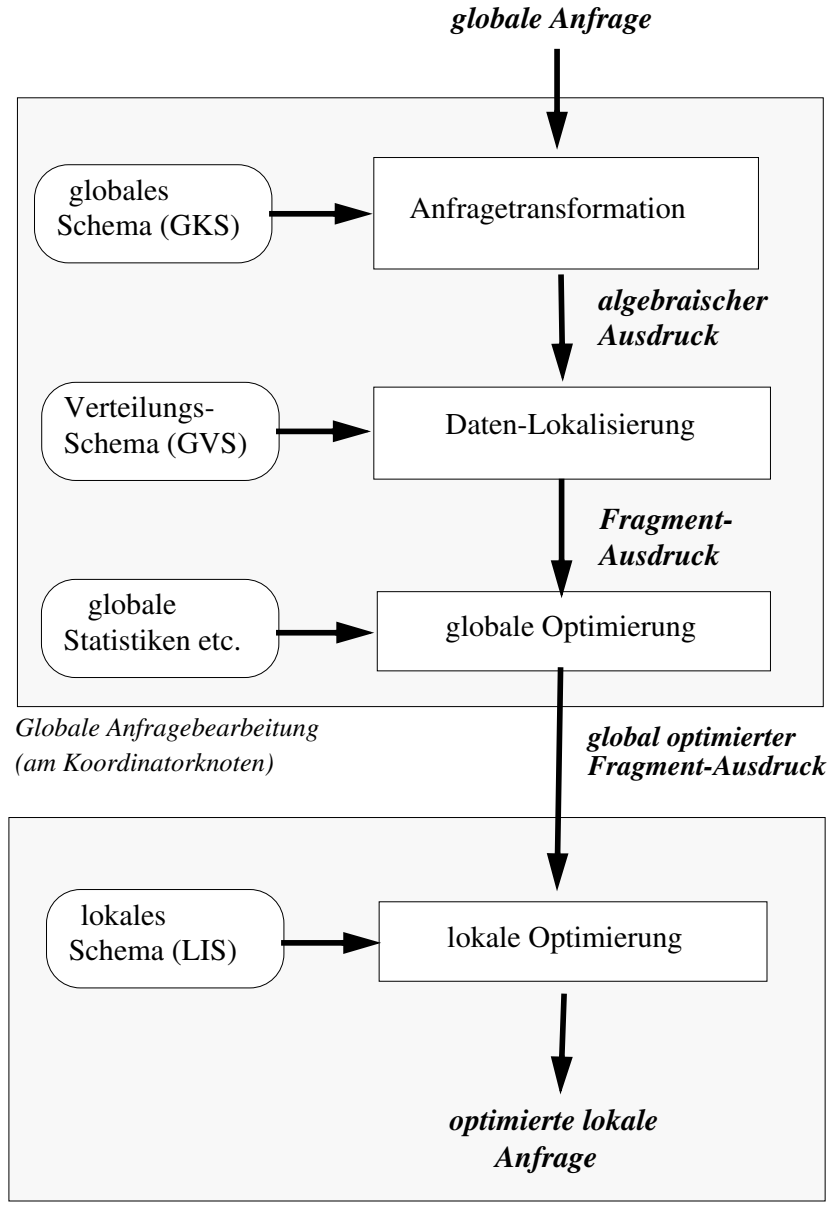

Anfragetransformation

- **Erzeugung einer Interndarstellung für die Anfrage:**
  Anfragegraph (AG) oder Operatorgraph
  (z.B. in Relationenalgebra)

- **Einzelschritte**
  - Lexikalische uns syntaktische Analyse (Parsing)
  - Semantische Analyse und Namensauflösung
  - Zugriffs- und Integritätskontrolle
  - Standardisierung und algebraische Vereinfachung
  - Restrukturierung und Transformation

- **Algebraische Vereinfachung**
  (z.B. Eliminierung redundanter Teilausdrücke)

- **Anwendung von Idempotenz-/Äquivalenzregeln für logische Operationen**

1. $p \wedge p \Leftrightarrow p$
2. $p \vee p \Leftrightarrow p$
3. $p \wedge \text{TRUE} \Leftrightarrow p$
4. $p \vee \text{FALSE} \Leftrightarrow p$
5. $p \wedge \text{FALSE} \Leftrightarrow \text{FALSE}$
6. $p \vee \text{TRUE} \Leftrightarrow \text{TRUE}$
7. $p \wedge \neg p \Leftrightarrow \text{FALSE}$
8. $p \vee \neg p \Leftrightarrow \text{TRUE}$
9. $p1 \wedge (p1 \vee p2) \Leftrightarrow p1$
10. $p1 \vee (p1 \wedge p2) \Leftrightarrow p1$

Anfragetransformation (2)

■ **Überführung der Anfrage in Operatorbaum**

■ Umstrukturierungen zur effizienteren Auswertbarkeit durch Nutzung von Äquivalenzbeziehungen für relationale Operatoren

$\sigma_{P1}(\sigma_{P2}(R)) \Leftrightarrow \sigma_{P1 \wedge P2}(R)$

$\pi_A(\pi_{A,B}(R)) \Leftrightarrow \pi_A(R)$

$\sigma_P(\pi_A(R)) \Leftrightarrow \pi_A(\sigma_P(R))$ *falls P nur Attribute aus A umfaßt*

$\sigma_P(\pi_A(R)) \Leftrightarrow \pi_A(\sigma_P(\pi_{A,B}(R)))$ *falls P auch Attribute aus B umfaßt*

$\sigma_{P(R1)}(R1 \bowtie R2) \Leftrightarrow \sigma_{P(R1)}(R1) \bowtie R2$ *(P(R1) sei Prädikat auf R1)*

$\pi_{A,B}(R1 \bowtie R2) \Leftrightarrow \pi_A(R1) \bowtie \pi_B(R2)$ *(A /B seien Attributmengen aus R1 / R2 inklusive Join-Attribut)*

$\sigma_P(R1 \cup R2) \Leftrightarrow \sigma_P(R1) \cup \sigma_P(R2)$

$\pi_A(R1 \cup R2) \Leftrightarrow \pi_A(R1) \cup \pi_A(R2)$

■ **Heuristiken**

- frühzeitige Ausführung von Selektionsoperationen
- frühzeitige Durchführung von Projektionen (ohne Duplikateliminierung)
- Zusammenfassung mehrerer Selektionen und Projektionen auf demselben Objekt
- Bestimmung gemeinsamer Teilausdrücke

■ **Beispiel**

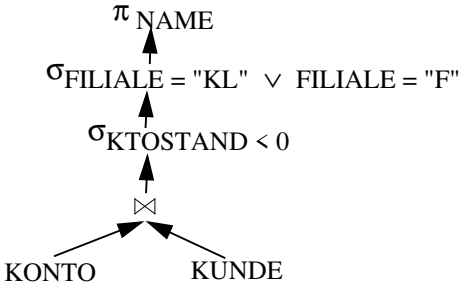

Erzeugung von Fragment-Anfragen (Daten-Lokalisierung)

■ **Relationen im Operatorbaum müssen auf Fragmente abgebildet werden**

- Ersetze Relationen durch Rekonstruktionsanweisungen auf Fragmenten
- Führe algebraische Vereinfachungen durch

■ **Fall 1: Horizontale Fragmentierung**

KONTO sei horizontal in drei Fragmente zerlegt (Fragmentierungsattribut KNR)

Bestimmung aller Konten von Kunde K5

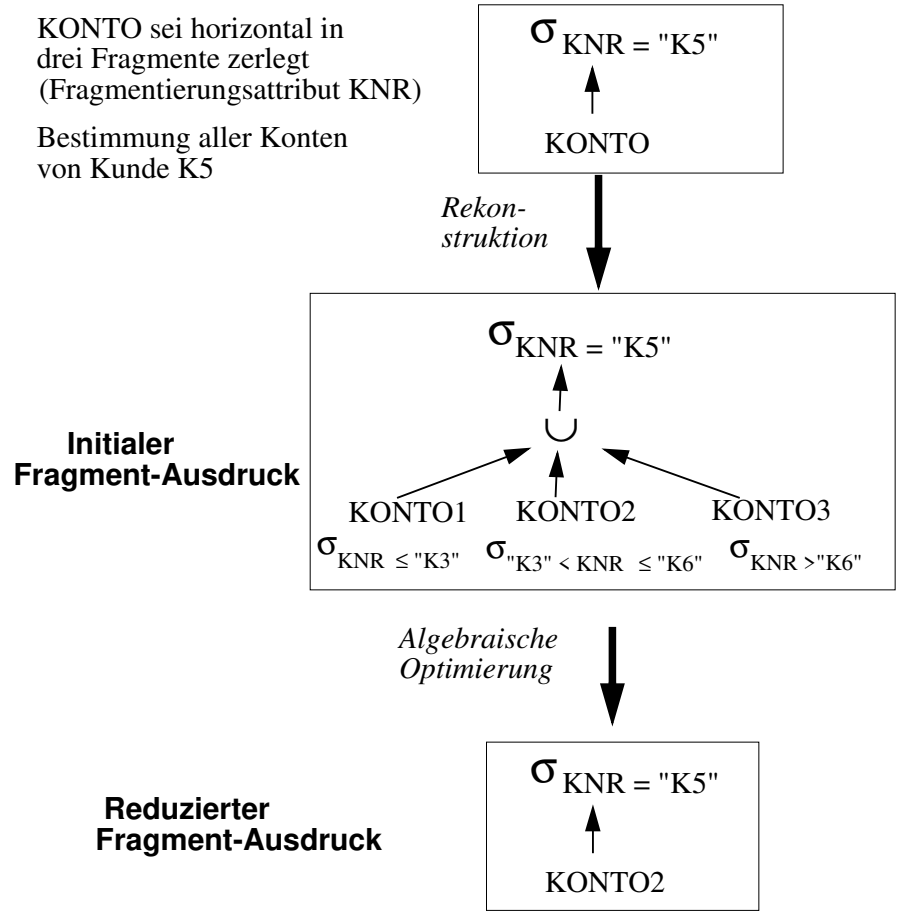

Erzeugung von Fragment-Anfragen (2)

■ **Join-Berechnung bei horizontaler Fragmentierung**

- reduzierter Kommunikations- und Verarbeitungsumfang für Joins auf Fragmentierungsattribut
- Unterstützung paralleler Join-Berechnung

KONTO und KUNDE seien horizontal über KNR zerlegt (unterschiedl. Bereiche)

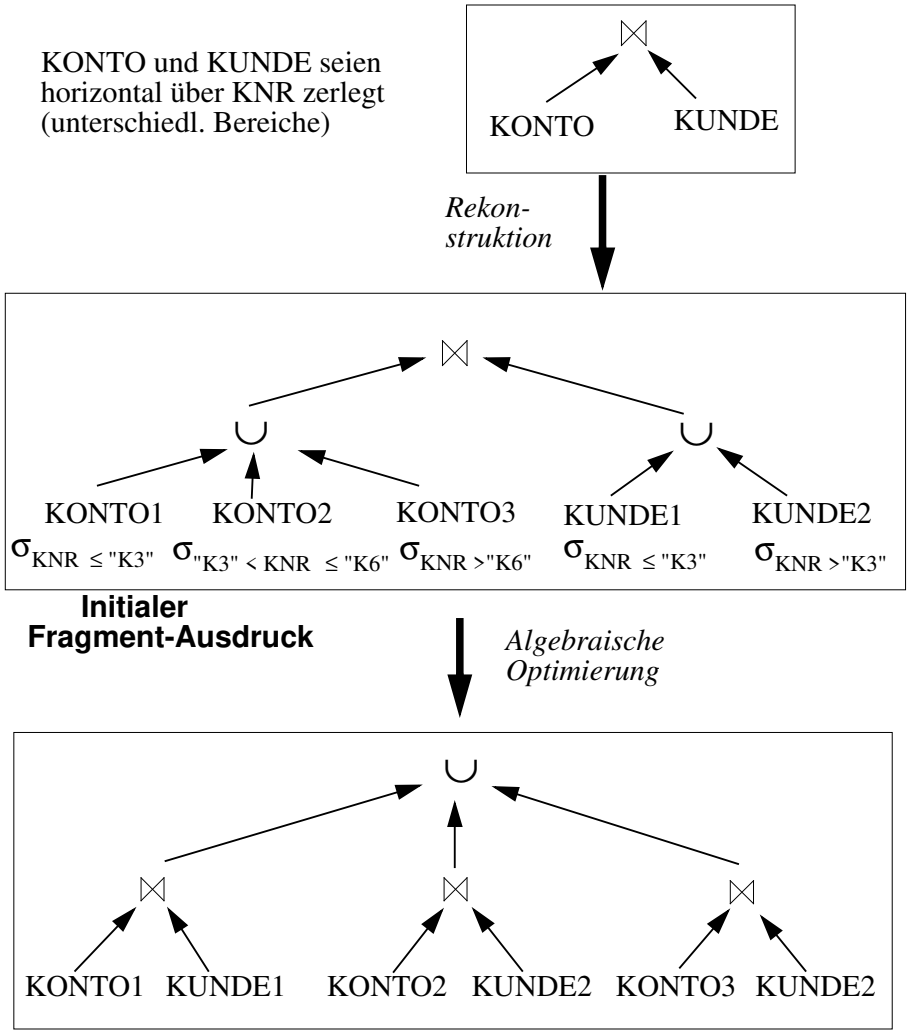

Erzeugung von Fragment-Anfragen (3)

■ **Fall 2: Abhängige horizontale Fragmentierung**

Horizontale Fragmentierung von KUNDE über Filiale,

abhängige Fragmentierung von KONTO

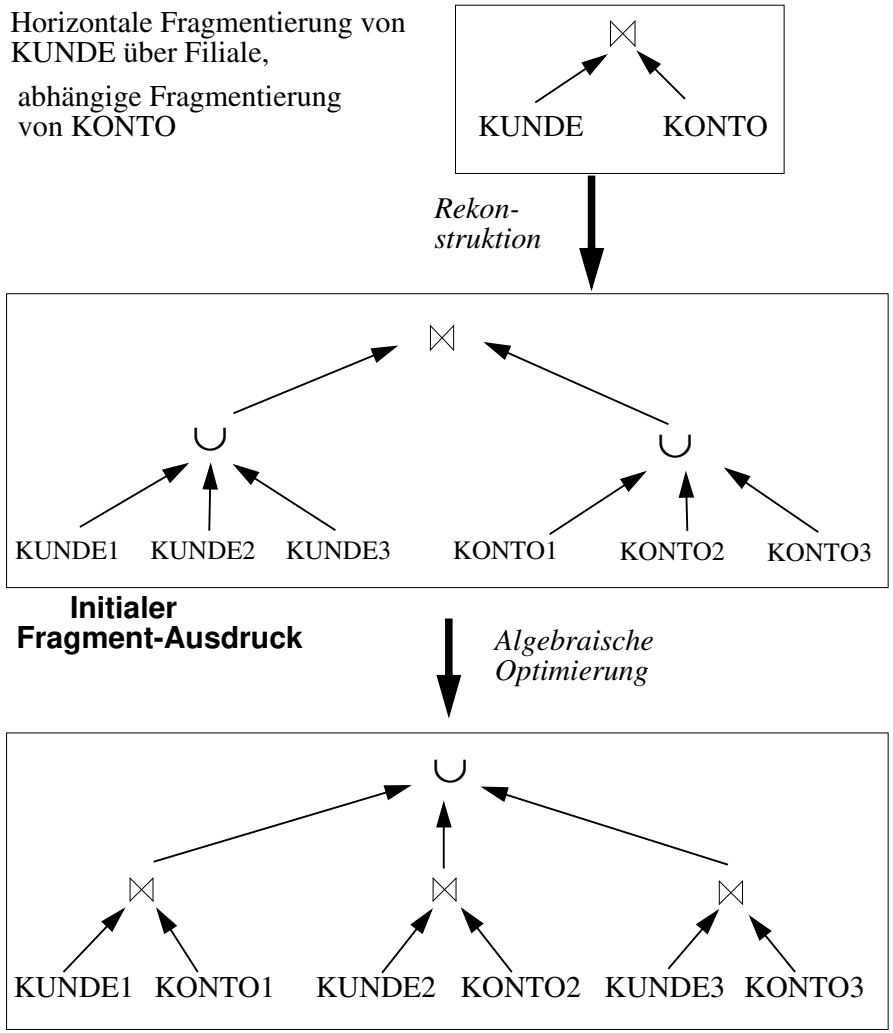

➥ Vollkommen lokale und parallele Join-Berechnung möglich

Erzeugung von Fragment-Anfragen (4)

■ **Fall 3: Vertikale Fragmentierung**

PERS1 (PNR, NAME); PERS2 (PNR, ANR)

Bestimme alle Angestelltennamen

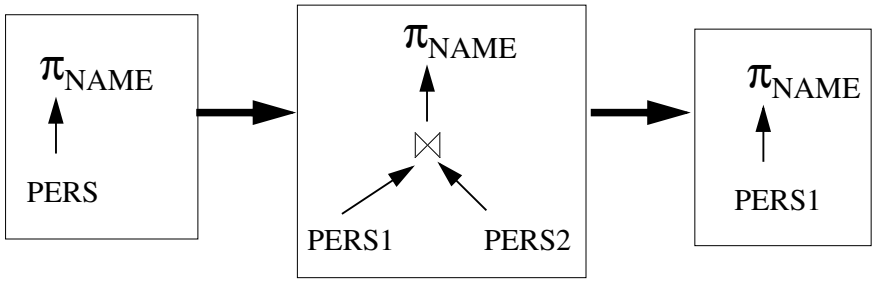

■ **Fall 4: Hybride Fragmentierung**

PERS1 = $\sigma_{PNR<1003}(\pi_{PNR, NAME}\ PERS)$

PERS2 = $\sigma_{PNR>=1003}(\pi_{PNR, NAME}\ PERS)$

PERS3 = $\pi_{PNR, ANR}\ PERS$

Bestimme den Namen von Angestelltem mit PNR 1004

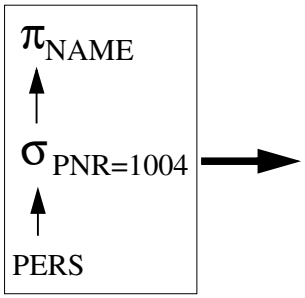

Globale Optimierung

■ **Bestimmung eines Ausführungsplanes mit minimalen globalen Kosten**

- Bestimmung der Ausführungsknoten
- Festlegung der Ausführungsreihenfolge (sequentiell, parallel)
- Alternative Strategien zur Join-Berechnung bewerten (z.B. mit Semi-Join)

■ **Trennung zwischen globaler und lokaler Optimierung kann zur Auswahl suboptimaler Pläne führen**

■ **Kostenmodell**

Berücksichtigung von CPU-, E/A- und Kommunikationskosten

Gesamtkosten = W_{CPU} * #Instruktionen +
$W_{I/O}$ * #E/A +
W_{Msg} * #Nachrichten +
W_{Byt} * #Bytes

Globale Optimierung (2)

■ **Benötigte Statistiken**

- Kardinalitäten von Relationen und Fragmenten
- Tupel- und Attributgrößen
- Häufigkeitsverteilung von Attributwerten, • • •

■ **Abschätzung von *Selektivitätsfaktoren SF***
(Größe von Zwischenergebnissen)

$Card(\sigma_p(R)) = SF(p) \cdot Card(R)$

- $SF(A = k) = 1 / Card(\pi_A(R))$
- SF (A > k) = Max (A) - k / Max (A) - Min (A)
- SF (A < k) = k - Min (A) / Max (A) - Min (A)
- $SF(p(A) \wedge p(B)) = SF(p(A)) \cdot SF(p(B))$
- $SF(p(A) \vee p(B)) = SF(p(A)) + SF(p(B)) - SF(p(A)) \cdot SF(p(B))$
- $SF(\neg p(A)) = 1 - SF(p(A))$

■ **Join-Selektivitätsfaktor (JSF)**

- Card (R ⋈ S) = JSF ∗ Card(R) ∗ Card(S)
- bei (N:1)-Joins (verlustfrei): $Card(R \bowtie S) = Max(Card(R), Card(S))$

Parallele Berechnung von Selektion und Projektion

■ **Datenlokalisierung führt zu Selektions- und Projektionsoperationen auf Fragmenten**

■ **Effektive Parallelisierung bei horizontaler Fragmentierung**

R = ∪ (R1, R2, ... , Rn)

Selektion: σ (R) ➥ ∪ (σ (R1), σ (R2), ... , σ (Rn))

Projektion: π (R) ➥ ∪ (π (R1), π (R2), ... , π (Rn))

- Datenverteilung gestattet parallele Berechnung der lokalen Teilselektionen/-projektionen
- Mischen der Teilergebnisse (Vereinigung)
- Projektion: ggf. Duplikateliminierung (z.B. durch Sortierung)

■ **Shared Nothing**

- Ausführung auf den Datenknoten
- Rechner und Parallelitätsgrad (n) durch Datenverteilung bestimmt (Ausnahme: bestimmte Anfragen auf dem Verteilattribut)
- auch Index-Scans i. allg. auf allen n Rechnern auszuführen

■ **Shared Disk / Shared Everything**

- Datenverteilung auf Platte bestimmt nur maximalen Parallelitätsgrad
- selektive Anfragen lassen sich auf einen Prozessor beschränken (➥ min. Kommunikationsaufwand)
- Relationen-Scans können von n Prozessoren bearbeitet werden
- Auswahl der Rechner kann zur Laufzeit erfolgen (➥ dynamische Lastbalancierung)
- Parallelitätsgrad kann nicht nur vom Anfragetyp, sondern auch von der aktuellen Auslastung abhängig gemacht werden

Parallele Berechnung von Aggregatfunktionen

Sei Q(R) ein Attribut von R, auf das Built-in-Funktionen angewendet werden sollen

■ **Parallele Berechnung für MIN, MAX immer möglich:**

MIN (Q(R)) ➥ MIN (MIN (Q(R1)), ... , MIN (Q(Rn))
MAX (Q(R)) ➥ MAX (MAX (Q(R1)), ... , MAX (Q(Rn))

- parallele Berechnung der lokalen Minima/Maxima
- Bestimmung des globalen Extremwerts

■ **Für SUM, COUNT, AVG parallele Berechnung nur anwendbar, falls keine *Duplikateliminierung* erforderlich ist**

SUM (Q(R)) ➥ Σ SUM ($Q(R_i)$)

COUNT (Q(R)) ➥ Σ COUNT ($Q(R_i)$)

AVG (Q(R)) ➥ SUM (Q(R)) / COUNT (Q(R))

Join-Berechnung

■ **Join (Verbund)**

- satztypübergreifende Operation: gewöhnlich sehr teuer
- häufige Nutzung: wichtiger Optimierungskandidat
- typische Anwendung: Gleichverbund; allgemeiner Θ-Verbund selten

■ **Implementierungsalternativen in zentralisierten DBS**

- Nested Loop:
  - jeder Satz der ersten wird mit jedem Satz der zweiten Relation abgeglichen
  - für alle Join-Arten nutzbar
- Sort-Merge:
  - Eingaberelationen sind auf Join-Attribut sortiert (bzw. haben Index auf Join-Attribut)
  - Gleichverbund über schritthaltenden Durchgang und Abgleich der Relationen
- Hash-Join:
  - kleinere Relation wird in Hauptspeicher-Hash-Tabelle gebracht (Hash-Funktion auf Join-Attribut)
  - Prüfung für jeden Satz der zweiten Relation, ob Wert des Join-Attributs in Hash-Tabelle (Relation 1)
  - nur für Gleichverbund

■ **Optimierungsziele in VDBS/PDBS:**

- Reduzierung der Kommunikationskosten sowie Nutzung von Parallelverarbeitung
- Mehr-Wege-Joins: Wahl der Ausführungsreihenfolge; Einsatz von Inter-Operator-Parallelität

Join-Berechnung in Verteilten DBS

■ **Anfrage in Knoten K, die Join zwischen**

- (Teil-)Relation R an Knoten K_R und
- (Teil-)Relation S an K_S erfordert

■ **Festlegung des Ausführungsknotens:** K, K_R oder K_S

■ **Bestimmung der Auswertungsstrategie**

a) Sende beteiligte Relationen vollständig an einen Knoten und führe lokale Join-Berechnung durch (*"Ship Whole"*)

- minimale Nachrichtenanzahl
- sehr hohes Übertragungsvolumen

b) Fordere für jeden Verbundwert der ersten Relation zugehörige Tupel der zweiten an (*"Fetch as Needed"*)

- hohe Nachrichtenanzahl
- nur relevante Tupel werden berücksichtigt

c) Kompromißlösung:
Semi-Join bzw. Erweiterungen (*Hash-Filter-Join*)

■ **Mehr-Wege-Joins: Wahl der Ausführungsreihenfolge !**

Kommunikationskosten der Join-Berechnung

■ **Hier: Verwendung von zwei Kostenfaktoren**

- K_N = Kommunikationskosten pro Nachricht
- K_A = Kommunikationskosten für Übertragung eines Attributwerts

■ **Beispiel:**

R

A	B
1	7
2	2
3	7
4	8
5	6
6	3
7	9

S

B	C	D
1	6	4
2	5	1
1	4	2
5	3	3
5	2	5
6	1	8

$R \bowtie S$

A	B	C	D
2	2	5	1
5	6	1	8

■ **Strategie 1:**

- Übertragung von R und S nach Knoten K
- Join-Berechnung an Knoten K

■ **Strategie 2:**

- Übertragung von R nach Knoten K_S
- Join-Berechnung an Knoten K_S

■ **Strategie 3:**

- Join-Berechnung an Knoten K_S
- pro S-Tupel sukzessive Anforderung von zugehörigen R-Tupeln

Semi-Join (1)

■ **Reduzierung des Kommunikationsaufwandes**

- alle Verbundpartner können auf einmal angefordert werden
- Wegfiltern von Attributen, die für Join nicht benötigt werden

■ **Entspricht Anwendung des Semi-Joins:**

Semi-Join von R auf S entspricht dem Verbund zwischen R und S, wobei Attribute von S im Ergebnis nicht enthalten sind

$$R \ltimes S = \pi_{Attr(R)} R \bowtie S = R \bowtie \pi_v S$$

(v = Verbundattribut)

$$R \ltimes S \Leftrightarrow R \bowtie (S \ltimes R) \Leftrightarrow R \bowtie (S \bowtie \pi_v (R))$$

■ **Nutzung zur Join-Berechnung an Knoten K_R:**

1. Bestimme R' = π_v R in K_R und sende R' an Knoten K_S
2. In K_S bestimme S' =(S $\bowtie$ R') = S $\ltimes$ R und sende S' an K_R
3. K_R berechnet den Join zwischen R und S' (entspricht R $\bowtie$ S)

Beispiel:

1) Bestimme R' = π_B R

2) Bestimme S' = S $\bowtie$ R'

3) Bestimme R $\bowtie$ S'

Kosten:

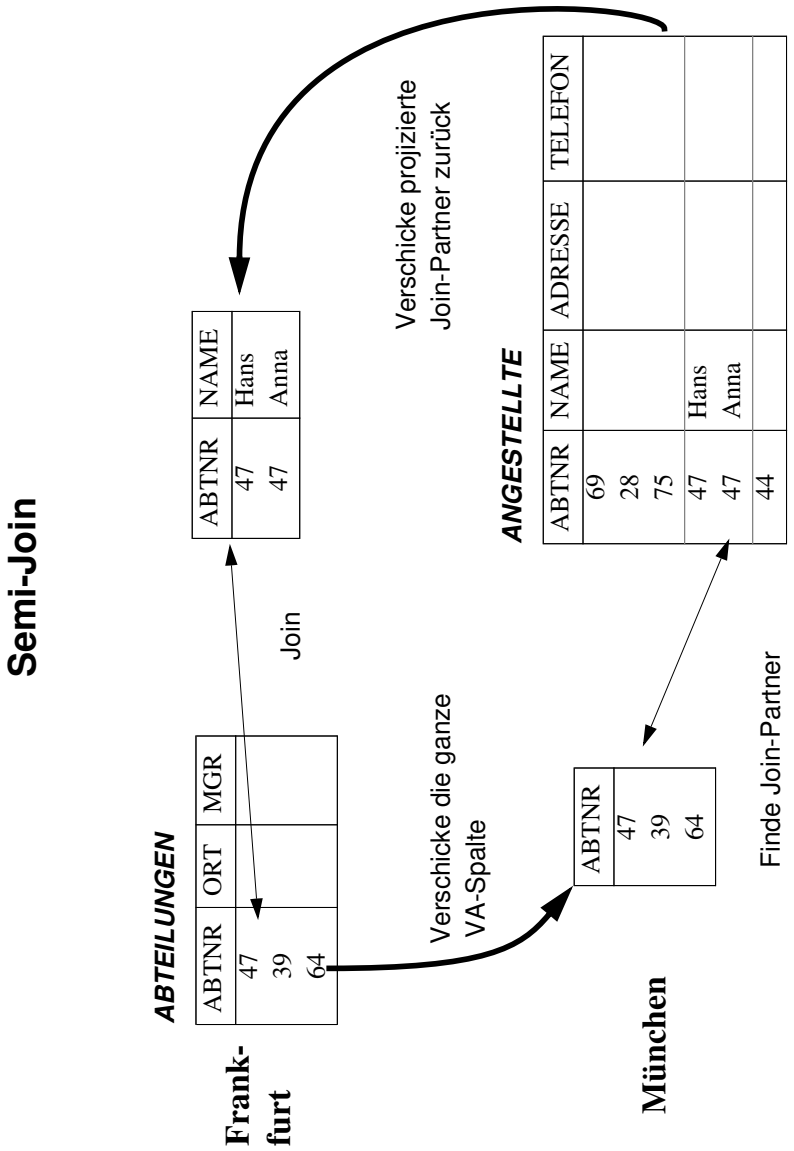

Semi-Join (2)

■ **Nutzung zur Join-Berechnung an drittem Knoten K:**

1. Bestimme R' = π_V R in K_R und sende R' an Knoten K_S
2. In K_S bestimme Semi-Join S' = S $\ltimes$ R' und sende S' an K
3. In K_S ermittle außerdem S'' = π_V S' und sende S'' an K_R
4. In K_R berechne Semi-Join R'' = R $\ltimes$ S'' und schicke R'' an K.
5. K berechnet das Ergebnis durch R'' $\ltimes$ S'

Beispiel:

1) Bestimme R' = π_B R

2) Bestimme S' = S $\ltimes$ R'

3) Bestimme S'' = π_B S'

4) Bestimme R'' = R $\ltimes$ S''

5) Bestimme R'' $\ltimes$ S'

■ **Semi-Join besonders wirksam,** wenn sich wenige Tupel qualifizieren
(sonst schlechtere Ergebnisse als mit einfacher Join-Auswertung möglich)

Bitvektor-Join (Hash-Filter-Join)

■ **weitergehende Reduzierung des Übertragungsvolumens**
als bei Semi-Join durch gröberen Filter

■ **Abbildung von Werten des Join-Attributes auf Bitvektor mittels Hash-Funktion**
Übertragung des Bitvektors anstatt von Attributwerten

■ **Nutzung zur Join-Berechnung an Knoten K_S:**

1. In K_R setze für jeden Wert in π_V R zugehöriges Bit im Bitvektor und sende diesen an Knoten K_S
2. In K_S bestimme S' = {s ∈ S | Bit für s.v im Bitvektor gesetzt} und sende S' an K_R
3. K_R berechnet den Join zwischen R und S'

■ Teilrelation R' in Schritt 2 i. allg. größer als bei Semi-Join, dafür Bit-Vektor kompakter als Menge der Attributwerte

Hash-Filter (Bit-Vektor)-Join

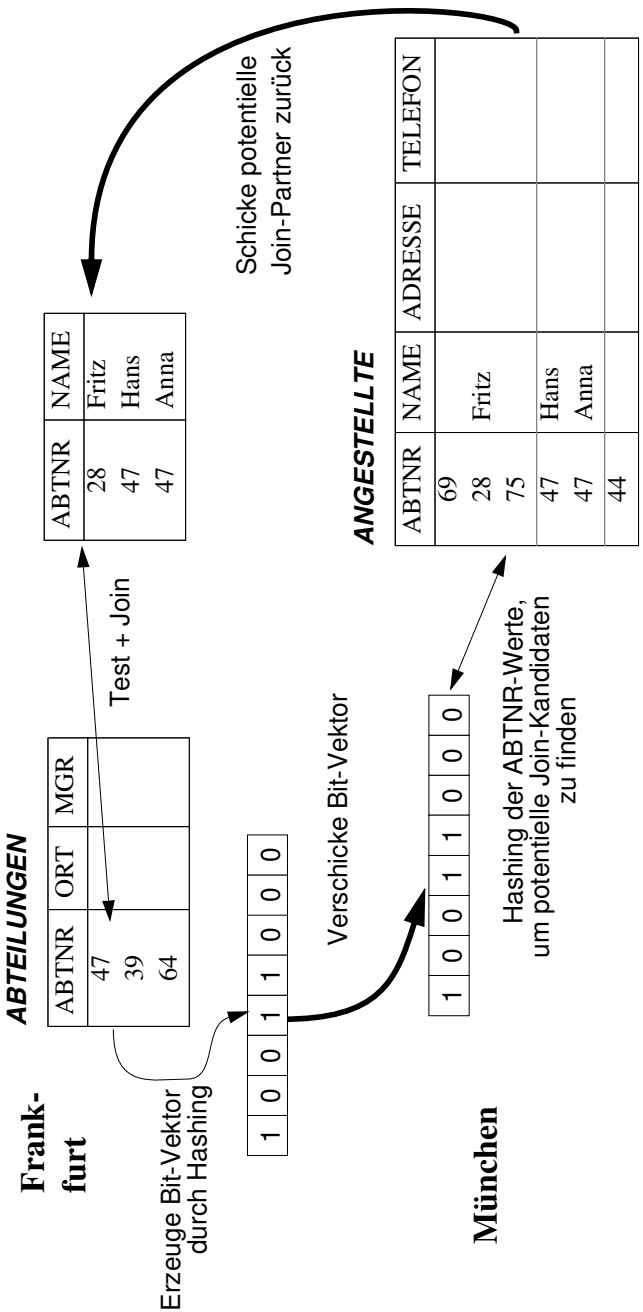

Parallele Join-Berechnung durch dynamische Replikation der kleineren Relation

■ **Join zwischen R und S:**

R = ∪ (R1, R2, ... , Rn) und S = ∪ (S1, S2, ... , Sm), S sei kleiner als R

■ **Algorithmus**

1. *Koordinator: initiiere Join auf allen R_i (i=1 ... n) und allen S_j (j =1 .. m)*
2. *Scan-Phase: in jedem S-Knoten führe parallel durch:*
   lies lokale Partition S_j und sende sie an jeden Knoten R_i (i= 1.. n)
3. *Join-Phase: in jedem R-Knoten mit Partition R_i führe parallel durch:*
   - *$S := \cup S_j$ (j=1..m)*
   - berechne $T_i := R_i \bowtie S$ (impliziert Lesen von R_i)
   - schicke T_i an Koordinator
4. *Koordinator: empfange und mische alle T_i*

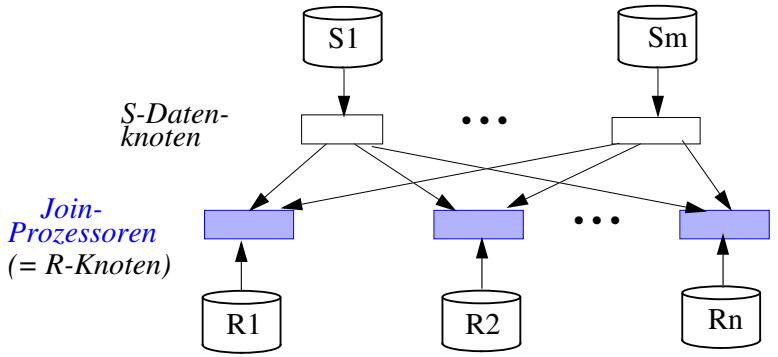

Eigenschaften:

- für alle Join-Prädikate einsetzbar
- lokale Join-Berechnung mit beliebiger Strategie möglich

Parallele Join-Berechnung durch dynamische Partitionierung

- **Voraussetzung: Gleichverbund !**
- Allgemeiner Fall:
  - Umverteilung beider Relationen unter p Join-Prozessoren
  - Verteilungsfunktion (Hash- oder Bereichspartitionierung) auf dem Join-Attribut

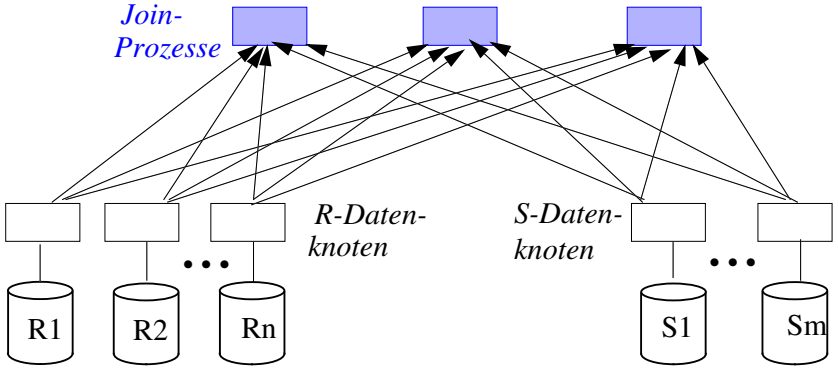

- **Bewertung:**
  - jeder **lokale** Join-Algorithmus anwendbar
  - reduzierter Join-Aufwand gegenüber dynamischer Replikation
  - hohe Flexibilität zur dynamischen Lastbalancierung (Wahl des Parallelitätsgrades p sowie der Join-Prozessoren)
  - hoher Kommunikationsaufwand

Dynamische Partitionierung (2)

- **Spezialfall 1:**
  Verteilungsattribut = Join-Attribut für eine Relation
  - nur eine Relation braucht umverteilt zu werden
  - Potential zur dynamischen Lastbalancierung entfällt

- **Spezialfall 2:**
  Beide Relationen besitzen Join-Attribut als Verteilattribut und identische Verteilfunktion (m=n, R und S an denselben Rechnern)
  - entspricht abhängiger horizontaler Fragmentierung
  - keinerlei Umverteilung erforderlich !

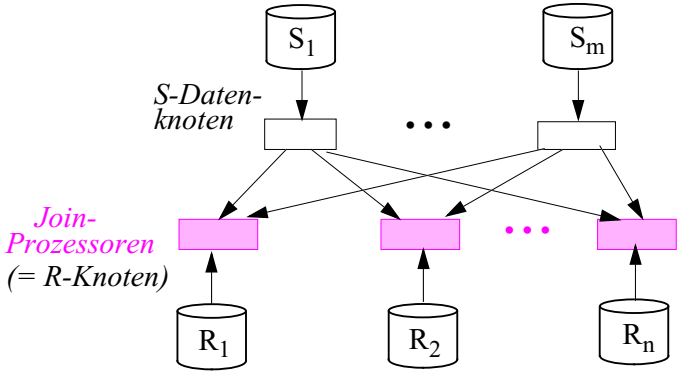

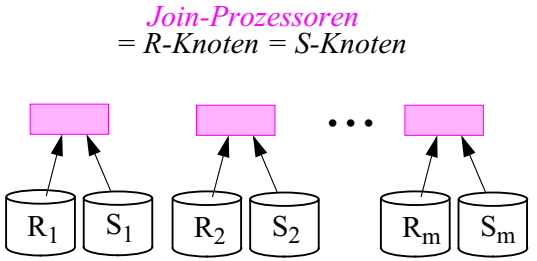

Hash-Join (zentralisierter Fall)

- **nur für Gleichverbund**
- **Idealfall: kleinere (innere) Relation S paßt vollständig in Hauptspeicher**
  - Building-Phase:
    Einlesen von S und Speicherung in HT im Hauptspeicher unter Anwendung einer Hash-Funktion h auf dem Join-Attribut
  - Probing-Phase:
    Einlesen von R und Überprüfung für jeden Join-Attributwert, ob zugehörige S-Tupel vorliegen (wenn ja, erfolgt Übernahme ins Join-Ergebnis)

Building-Phase

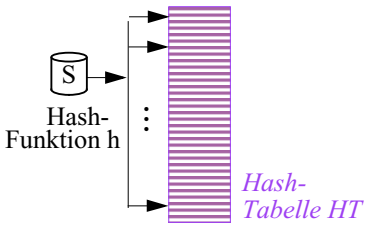

Probing-Phase

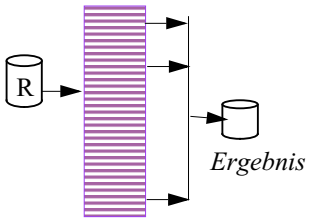

- **Vorteile**
  - lineare Kosten O (N)
  - Hashing reduziert Suche nach Verbundpartnern auf Sätze einer Hash-Klasse (Partitionierung des Suchraumes)
  - Nutzung großer Hauptspeicher
  - auch für Joins auf Zwischenergebnissen gut nutzbar

Hash-Join (2)

- **Allgemeiner Fall:**
  kleinere Relation paßt nicht vollständig in Hauptspeicher
  ➥ Überlaufbehandlung erforderlich
- **Lösung: Partionierung der Eingaberelationen**
  - Partitionierung von S und R in q Partitionen über (Hash-)Funktion g auf dem Join-Attribut, so daß jede S-Partition in die HT paßt
  - q-fache Anwendung des Basisalgorithmus' auf je zwei zusammengehörigen Partitionen

Partitionierungs-Phase

(für R analog)

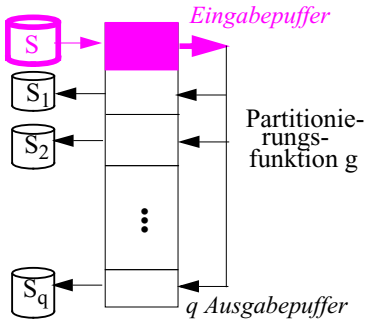

Building-Phase

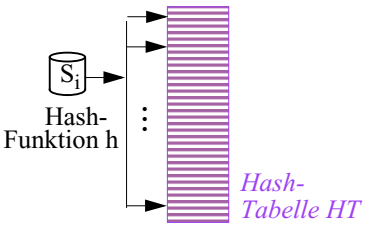

Probing-Phase

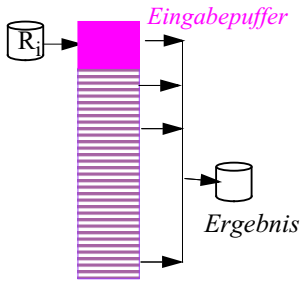

- rund 3-facher E/A-Aufwand gegenüber Basisverfahren ohne Überlauf

Paralleler Hash-Join

Building-Phase:

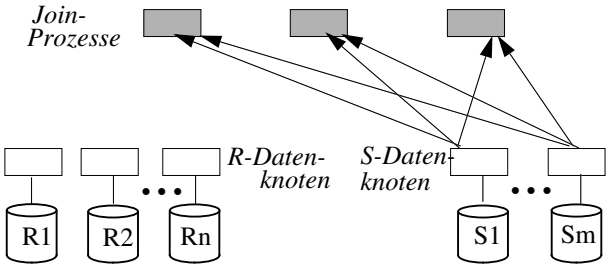

Probing-Phase:

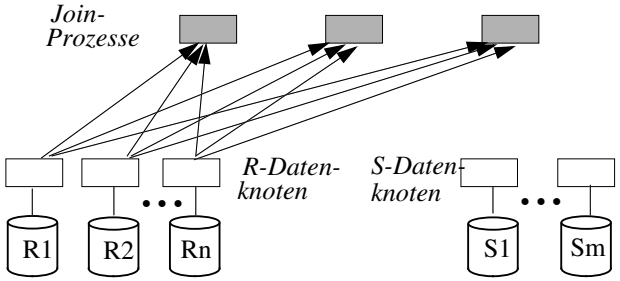

■ **Prinzip:**

- Partitionierung und Umverteilung der kleineren Relation S über Hash-Funktion h_P auf dem Join-Attribut
- In Join-Prozessoren kommen eingehende Tupel in HT (Hash-Fkt. h_{HT})
- Umverteilung der zweiten Relation R auf die Join-Prozessoren unter Anwendung von h_P
- Probing: für eingehende Tupel werden Verbundpartner in HT ermittelt

■ **Merkmale:**

- Sequentialisierung der Scan-Phasen !
- Vorteil: Reduzierung des Umverteilungsaufwandes für R durch Anwendung von Bitvektor-Filterung möglich
- Pipeline-Parallelität in Building- und Probing-Phase möglich
- Überlaufbehandlung erforderlich, falls S-Partitionen nicht vollständig in HT (Hauptspeicher) Platz finden (➥ 3-stufige Partitionierung)

Dynamische Bestimmung der Join-Parallelität*

■ Dynamische Umverteilung ermöglicht hohe Flexibilität zur Lastbalancierung:
Wahl des Parallelitätsgrades p sowie der Join-Prozessoren

- Kostenmodell zur Bestimmung eines optimalen Parallelitätsgrades $p_{su\text{-}opt}$ im Einbenutzerbetrieb
- Zuweisung zu den $p_{su\text{-}opt}$ Prozessoren mit der geringsten CPU-Auslastung

■ **Paralleler Hash-Join: Berücksichtigung der Hauptspeicherverfügbarkeit**

- dynamische Bestimmung der minimalen Rechneranzahl, welche temporäre E/A vermeidet (falls nicht möglich, Bestimmung der Konfiguration, die E/A minimiert)
- erfordert Information zur aktuellen Hauptspeicherbelegung
  AVAIL-MEMORY [1..#PE] of (node-ID, free);
  sortiert gemäß verfügbarem Hauptspeicher (free)
- p_{mu} = MIN (k | AVAIL-MEMORY [k].free *k > b); b = Größe der kleineren Relation
- Zuweisung zu den p Rechnern mit der maximalen Hauptspeicherverfügbarkeit
- falls mehrere Konfigurationen temporäre E/A ausschließen sind oft höhere Parallelitätsgrade sinnvoll (z.B. Anlehnung an Einbenutzer-Optimum)

1) keine Überlauf-E/A

k	1	2	3	4
nodeID	P3	P2	P4	P1
free (MB)	45	40	35	30

2) Überlauf-E/A erforderlich

k	1	2	3	4
nodeID	P2	P1	P4	P3
free (MB)	80	10	0	0

b = 100 MB

* Rahm, E.; Marek, R.: Dynamic Multi-resource Load Balancing in Parallel Database Systems. Proc. 21st VLDB Conf., 1995

Mehr-Wege-Joins

- **Mehr-Wege-Joins realisierbar als Folge von Zwei-Wege-Joins**
- **Bestimmung der Join-Reihenfolge ist ein zentrales Problem**
- **Minimierung der Zwischenergebnisse liefert auch bei "Ship-Whole" nicht unbedingt die geringsten Kommunikationskosten**
- **Beispiel**

Zu berechnen: R ⋈ S ⋈ T

Card (R) = 10000, *Card (S)* = 1000, *Card (T)* = 10000,

Joinselektivitäten JSF (R ⋈ S) = 0.01, *JSF* (S ⋈ T) = 0.1

jede der drei Relationen habe 10 Attribute

1. R -> K_S; Z := R ⋈ S; Z -> K_T. Berechnung des Ergebnisses Z ⋈ T
2. S -> K_R; Z := R ⋈ S; Z -> K_T. Berechnung des Ergebnisses Z ⋈ T
3. S -> K_T; Z := S ⋈ T; Z -> K_R. Berechnung des Ergebnisses Z ⋈ R
4. T -> K_S; Z := S ⋈ T; Z -> K_R. Berechnung des Ergebnisses Z ⋈ R
5. R -> K_S; T -> K_S. Berechnung des Ergebnisses R ⋈ S ⋈ T
6. S -> K_R; T -> K_R. Berechnung des Ergebnisses R ⋈ S ⋈ T

Mehr-Wege-Joins (2)

- **Reduzierung des Kommunikationsaufwandes durch Semi-Joins:**
  - Tupel qualifiziert sich nur, wenn es Verbundpartner in allen beteiligten Relationen findet
  - Reduzierungspotential steigt mit N (= Anzahl der Relationen)
- ***Vollständige Reduzierung (full reducer):***
  Folge von Semi-Joins, welche jede der beteiligten Relationen auf diejenigen Tupel reduzieren kann, die im Endergebnis enthalten sind

R

A	B
3	7
1	1
4	6
7	7
4	5
6	2
5	7

⋈

S

B	C
9	8
1	5
9	4
4	3
4	2
5	7

⋈

T

C	D
1	8
6	1
4	2
7	3
2	6
3	8

R ⋈ S ⋈ T

A	B	C	D
4	5	7	3

Mögliche Folge von Semi-Joins:

R' := R ⋉ S

S' := S ⋉ T

T' := T ⋉ S

Ergebnis: R' ⋈ S' ⋈ T'

➥ *keine vollständige Reduzierung*

Mehr-Wege-Joins (3)

■ **Vollständige Reduzierungen** bestehen i. allg. nur für azyklische Join-Anfragen, insbesondere für *gekettete Joins* (chained queries)

$$R_1 (A, A_1) \bowtie R_2 (A_1, A_2) \bowtie \ldots \bowtie R_N (A_{N-1}, B)$$

vollständige Ordnung über Join-Attributen A_i gegeben

■ **In diesem Fall besteht die vollständige Reduzierung aus 2N-2 Semi-Joins:**

- Vorwärtsreduzierung von R_1 bis R_N
  $R_2' := R_2 \ltimes R_1$
  $R_3' := R_3 \ltimes R_2'$
  • • •
  $R_N' := R_N \ltimes R_{N-1}'$
- Rückwärtsreduzierung von R_N' bis R_1
  $R_{N-1}'' := R_{N-1} \ltimes R_N'$
  $R_{N-2}'' := R_{N-2} \ltimes R_2''$
  • • •
  $R_1' := R_1 \ltimes R_2''$

■ **Beispiel**

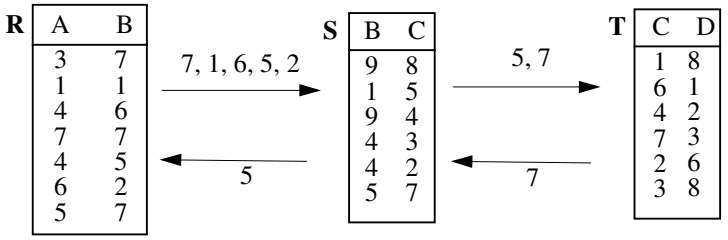

Vollständige Reduzierung:

S' := S ⋉ R

T' := T ⋉ S'

S'' := S' ⋉ T'

R' := R ⋉ S''

R ⋈ S ⋈ T

A	B	C	D
4	5	7	3

Inter-Operator-Parallelität

■ **Analyse des Operatorbaumes zur parallelen Berechnung unabhängiger Knoten (Operatoren)**

■ **Beispiele:**

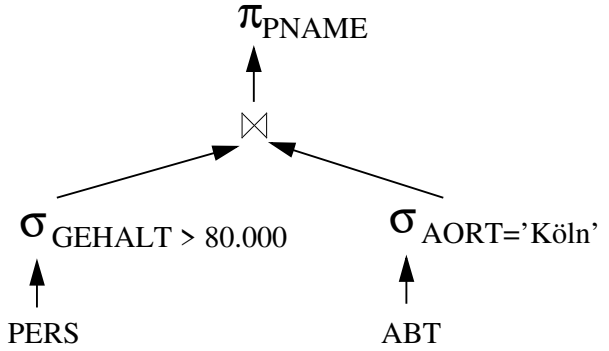

Parallele Berechnung verschiedener Selektionen

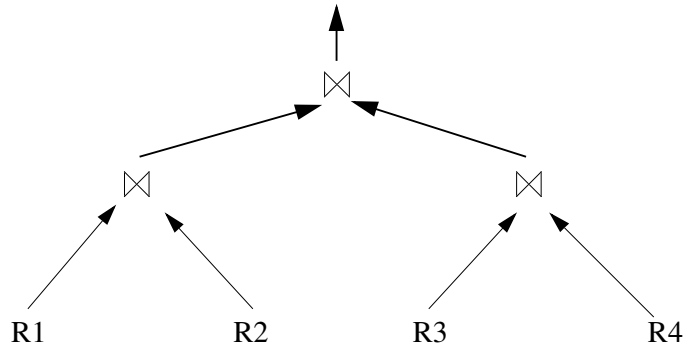

Mehr-Wege-Join
(R1⋈ R2⋈ R3⋈ R4)

Mehr-Wege-Joins: Nutzung von Pipeline-Parallelität

■ **Beispiel:**
Pipeline-Join in Rechner P3

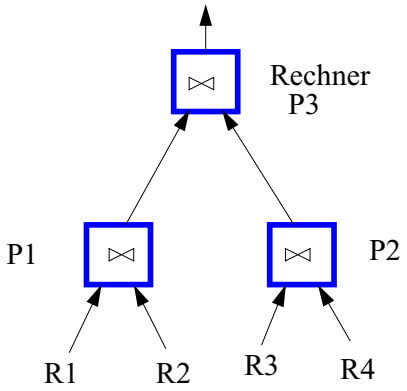

■ **Annahmen:**

- P3 hat Eingangswarteschlange Q für Tupel aus P1 und P2
- spezielle Nachrichten ENDP1, ENDP2 zeigen an, daß keine weiteren Tupel mehr folgen

■ **Algorithmus:**

```
Fertig1, Fertig2 := FALSE;
Von1, Von2, Ergebnis := { }
WHILE NOT (Fertig1 AND Fertig2) DO
BEGIN
    IF Q leer THEN warte bis neue Tupel eintreffen;
    t := erstes Tupel in Q;
    IF t = ENDP1 THEN Fertig1 := TRUE
    ELSE IF t=ENDP2 THEN Fertig2 := TRUE
        ELSE IF t von P1 THEN BEGIN
            Von1 := Von1 ∪ {t};
            Ergebnis := Ergebnis ∪ ( {t} ⋈ Von2 ) END
        ELSE BEGIN (* t von P2 *)
            Von2 := Von2 ∪ {t};
            Ergebnis := Ergebnis ∪ ( {t} ⋈ Von1 ) END
END; (* WHILE *)
```


Mehr-Wege-Joins (2)

■ **Beschränkte Berechnungsreihenfolgen** für Mehrwege-Joins erleichtern Optimierungsproblem

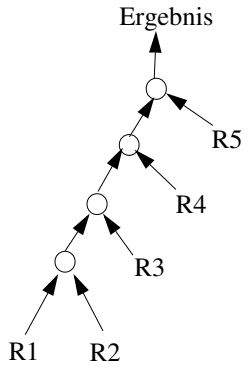

links-tiefer Operatorbaum

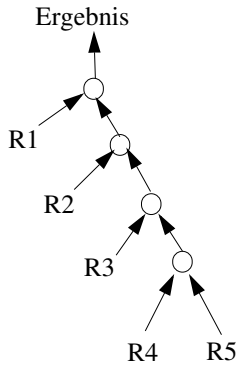

rechts-tiefer Operatorbaum

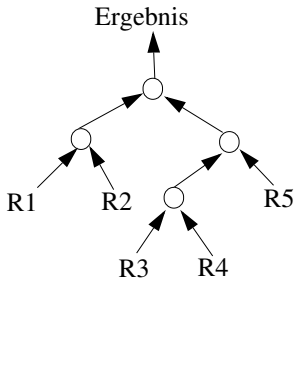

unbeschränkt (bushy tree)

■ **Rechts-tiefe Bäume** erlauben bei Verwendung von Hash-Joins einen hohen Grad an Parallelität,
jedoch mit hohem Ressourcenbedarf

- Join-Berechnung in 2 Schritten
- Building Phase: paralleles Einlesen von N-1 Relationen in eine Hauptspeicher-Hashtabelle
- Probing-Phase beginnt mit der N-ten Relation an einem der Rechner, danach wird sie mit den jeweiligen Join-Resultaten sukzessive an den anderen Knoten fortgeführt

■ **Links-tiefe Bäume**

- Join-Berechnung in N Schritten
- pro Schritt werden nur zwei Relationen im Hauptspeicher gehalten

Parallele Sortierung

■ **DBS: Externes Sortieren**

- Zerlegung der Eingabe in mehrere Läufe (runs)
- Sortieren und Zwischenspeichern der sortierten Läufe
- Sukzessives Mischen bis ein sortierter Lauf entsteht

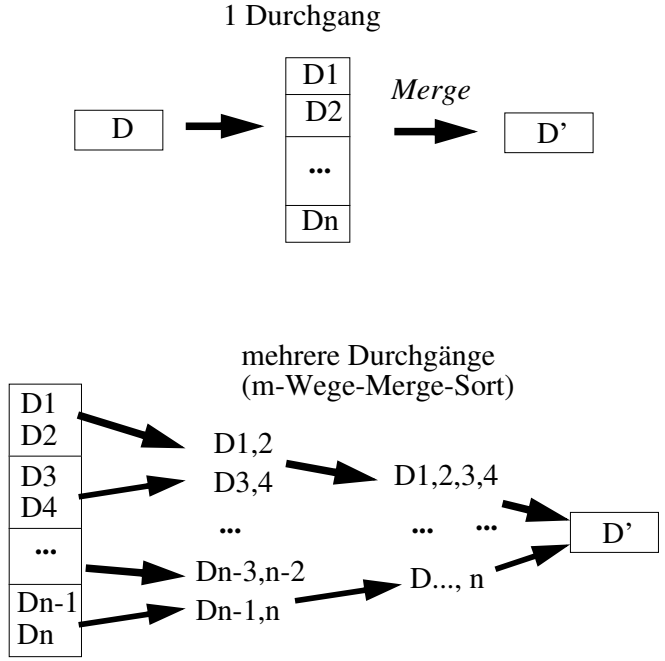

■ **Anforderungen an parallele Sortierung**

- parallele Eingabe (multiple input)
- parallele Sortierphasen
- paralleles Mischen
- Partitionierung der sortierten Ausgabe (multiple output)

Parallele Sortierung (2)

■ **Ansatz**

- lokale Sortierung der Partitionen an den Datenknoten
- dynamische Umverteilung der sortierten Läufe unter p Mischknoten
- Umverteilung wird über eine dynamische Bereichsfragmentierung auf dem Sortierattribut gesteuert
- paralleles Mischen in den p Mischknoten
- partitionierte Ausgabe

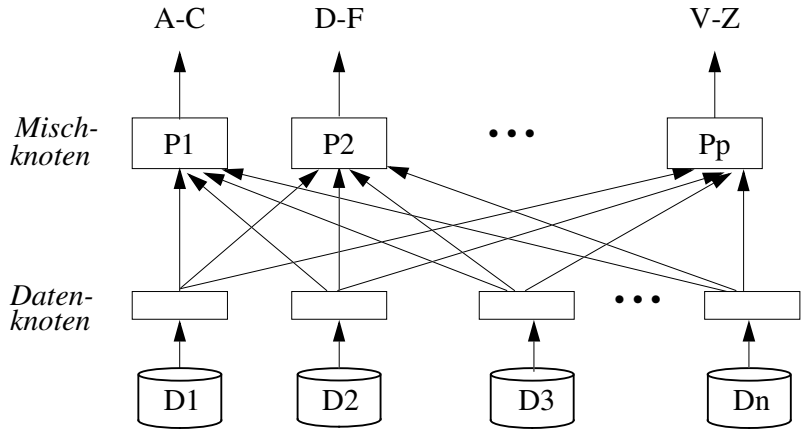

Zusammenfassung

■ **Prinzipielle Vorgehensweise**

- wie in zentralisierten DBS
- jedoch zusätzliche Optimierungsschritte zur Übersetzungs- und Laufzeit

■ **Weit höhere Komplexität der verteilten Anfrageverarbeitung** als im zentralisierten Fall

- Berücksichtigung der Fragmentierung
- Nutzung von Replikaten
- Optimierung der Objektverteilung und der Verarbeitungsorte (Minimierung des Kommunikationsaufwandes)

➥ Zusätzliche Kosten: #Nachrichten + zu übertragende Daten

■ **Arten der Optimierung**

- Behandlung von Fragmentanfragen
- Join-Berechnung
  "Ship Whole" oft dem "Fetch as Needed" vorzuziehen
- Bestimmung der Join-Reihenfolge ist ein zentrales Problem

■ **Anfrageoptimierung und -bearbeitung**

- global am Koordinatorknoten und
- lokal an den Speicherknoten

➥Optimierungsannahmen noch problematischer als im zentralisierten Fall

Zusammenfassung (2)

■ **Verteilte und parallele Anfragebearbeitung**

- Anfragetransformation, algebraische Optimierung
- Daten-Lokalisierung: Abbildung von Operatoren auf Fragmente
- Globale Optimierung: Kostenbewertung unter Berücksichtigung von Kommunikationsaufwand und Parallelsierungsalternativen

■ **Selektion, Projektion, Aggregationen**

- Datenallokation bestimmt Ausführungsort (Shared Nothing)
- Parallelisierbarkeit durch horizontale Fragmentierung

■ **Verteilte Join-Verarbeitung**

- Alternativen bezüglich Wahl des Join-Knotens und Übertragung der Daten
- Semi-Join und Bitvektor-Join effektiv nutzbar

■ **Parallele Join-Verarbeitung**

- hohes Lastbalancierungsaufwand bei dynamischer Umverteilung der Relationen
- Kommunikationseinsparungen falls Join-Attribut = Verteilattribut (insbesondere bei abhängiger horizontaler Fragmentierung)
- paralleler Hash-Join: Optimierung der Hauptspeichernutzung

■ **Mehr-Wege-Joins**

- Kommunikationsreduzierung durch mehrfache Semi-Joins
- Nutzung von Inter-Operator-Parallelität, insbesondere Pipeline-Parallelität