# Verteilte Datenbanken

- **Motivation:**

**geographisch verteilte Organisationsform einer Bank mit ihren Filialen**

- **Filialen sollen Daten lokaler Kunden bearbeiten können**
- **Zentrale soll Zugriff auf alle Daten haben (z.B. für Kontogutschreibungen)**

## Terminologie

Sammlung von Informationseinheiten, verteilt auf mehreren Rechnern, verbunden mittels Kommunikationsnetz → nach *Ceri & Pelagatti* (1984)

Kooperation zwischen autonom arbeitenden Stationen, zur Durchführung einer globalen Aufgabe



## Kommunikationsmedien

LAN: local area network, z.B. Ethernet, Token-Ring oder FDDI-Netz

WAN: wide area network, z.B. das Internet

Telefonverbindungen, z.B. ISDN oder einfache Modem-Verbindungen



## Verteiltes Datenbanksystem

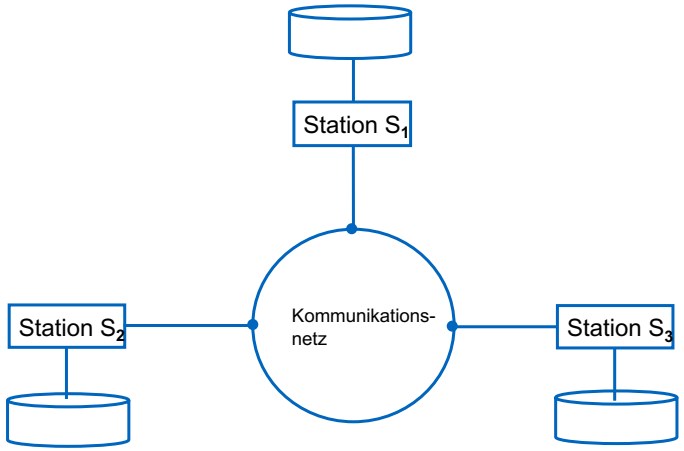

## Client-Server-Architektur

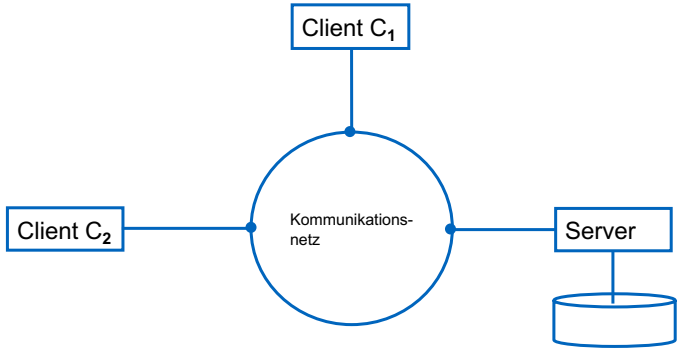


5

## Aufbau und Entwurf eines verteilten Datenbanksystems

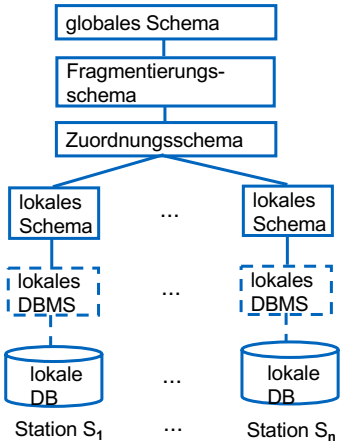


6

## Fragmentierung und Allokation einer Relation

Fragmentierung: Fragmente enthalten Daten mit gleichem Zugriffsverhalten

Allokation: Fragmente werden den Stationen zugeordnet
- mit Replikation (redundanzfrei)
- ohne Replikation

7

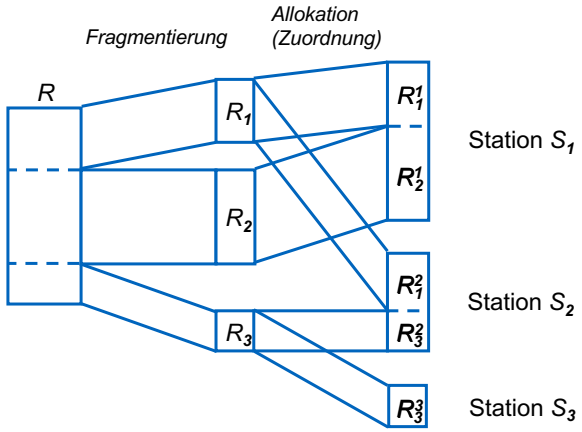


8

## Fragmentierung

**horizontale Fragmentierung**: Zerlegung der Relation in disjunkte Tupelmengen

**vertikale Fragmentierung**: Zusammenfassung von Attributen mit gleichem Zugriffsmuster

**kombinierte Fragmentierung**: Anwendung horizontaler und vertikaler Fragmentierung auf dieselbe Relation

9

## Korrektheits-Anforderungen

Rekonstruierbarkeit

Vollständigkeit

Disjunktheit

10

## Beispielrelation Professoren

| Professoren | | | | | | |
|---|---|---|---|---|---|---|
| **PersNr** | **Name** | **Rang** | **Raum** | **Fakultät** | **Gehalt** | **Steuerklasse** |
| 2125 | Sokrates | C4 | 226 | Philosophie | 85000 | 1 |
| 2126 | Russel | C4 | 232 | Philosophie | 80000 | 3 |
| 2127 | Kopernikus | C3 | 310 | Physik | 65000 | 5 |
| 2133 | Popper | C3 | 52 | Philosophie | 68000 | 1 |
| 2134 | Augustinus | C3 | 309 | Theologie | 55000 | 5 |
| 2136 | Curie | C4 | 36 | Physik | 95000 | 3 |
| 2137 | Kant | C4 | 7 | Philosophie | 98000 | 1 |

11

abstrakte Darstellung: $R$

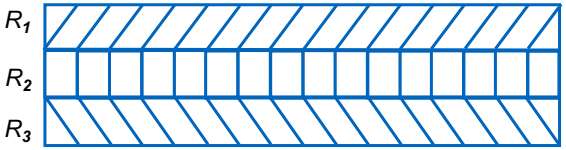


Für 2 Prädikate $p_1$ und $p_2$ ergeben sich 4 Zerlegungen:

$R1 := \sigma_{p_1 \wedge p_2}(R)$

$R2 := \sigma_{p_1 \wedge \neg p_2}(R)$

$R3 := \sigma_{\neg p_1 \wedge p_2}(R)$

$R4 := \sigma_{\neg p_1 \wedge \neg p_2}(R)$

⇒ n Zerlegungsprädikate $p_1,\ldots,p_n$ ergeben $2^n$ Fragmente

12

sinnvolle Gruppierung der Professoren nach Fakultätszugehörigkeit:

⇒ 3 Zerlegungsprädikate:

$p_1 \equiv$ Fakultät = ‚Theologie'
$p_2 \equiv$ Fakultät = ‚Physik'
$p_3 \equiv$ Fakultät = ‚Philosophie'

TheolProfs´ := $\sigma_{p1 \wedge \neg p2 \wedge \neg p3}(\text{Professoren}) = \sigma_{p1}(\text{Professoren})$
PhysikProfs´ := $\sigma_{\neg p1 \wedge p2 \wedge \neg p3}(\text{Professoren}) = \sigma_{p2}(\text{Professoren})$
PhiloProfs´ := $\sigma_{\neg p1 \wedge \neg p2 \wedge p3}(\text{Professoren}) = \sigma_{p3}(\text{Professoren})$
AndereProfs´ := $\sigma_{\neg p1 \wedge \neg p2 \wedge \neg p3}(\text{Professoren})$

13

## Abgeleitete horizontale Fragmentierung

Beispiel *Vorlesungen* aus dem Universitätsschema:
Zerlegung in Gruppen mit gleicher SWS-Zahl

2SWSVorls := $\sigma_{SWS=2}$ (Vorlesungen)
3SWSVorls := $\sigma_{SWS=3}$ (Vorlesungen)
4SWSVorls := $\sigma_{SWS=4}$ (Vorlesungen)

⇒ für Anfragebearbeitung schlechte Zerlegung

14

**select** Titel, Name
**from** Vorlesungen, Professoren
**where** gelesenVon = PersNr;

resultiert in:

$\Pi_{\text{Titel, Name}}$((TheolProfs´ ⋈ 2SWSVorls) ∪
(TheolProfs´ ⋈ 3SWSVorls) ∪
... ∪ (PhiloProfs´ ⋈ 4SWSVorls) )

Join-Graph zu diesem Problem:

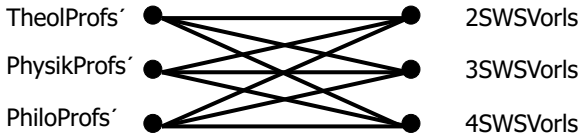


15

## Andere Join-Arten

• natürlicher Join

| L | | |
|---|---|---|
| A | B | C |
| $a_1$ | $b_1$ | $c_1$ |
| $a_2$ | $b_2$ | $c_2$ |

⋈

| R | | |
|---|---|---|
| C | D | E |
| $c_1$ | $d_1$ | $e_1$ |
| $c_3$ | $d_2$ | $e_2$ |

=

| Resultat | | | | |
|---|---|---|---|---|
| A | B | C | D | E |
| $a_1$ | $b_1$ | $c_1$ | $d_1$ | $e_1$ |

16

## Semi-Joins

• Semi-Join von R mit L

| L | | |
|---|---|---|
| A | B | C |
| $a_1$ | $b_1$ | $c_1$ |
| $a_2$ | $b_2$ | $c_2$ |

⋉

| R | | |
|---|---|---|
| C | D | E |
| $c_1$ | $d_1$ | $e_1$ |
| $c_3$ | $d_2$ | $e_2$ |

=

| Resultat | | |
|---|---|---|
| C | D | E |
| $c_1$ | $d_1$ | $e_1$ |

• Semi-Join von L mit R

| L | | |
|---|---|---|
| A | B | C |
| $a_1$ | $b_1$ | $c_1$ |
| $a_2$ | $b_2$ | $c_2$ |

⋉

| R | | |
|---|---|---|
| C | D | E |
| $c_1$ | $d_1$ | $e_1$ |
| $c_3$ | $d_2$ | $e_2$ |

=

| Resultat | | |
|---|---|---|
| A | B | C |
| $a_1$ | $b_1$ | $c_1$ |

17

## Lösung: abgeleitete Fragmentierung

TheolProfs´ — TheolVorls

PhysikProfs´ — PhysikVorls

PhiloProfs´ — PhiloVorls

TheolVorls := Vorlesungen $\ltimes_{\text{gelesenVon=PersNr}}$ TheolProfs´

PhysikVorls := Vorlesungen $\ltimes_{\text{gelesenVon=PersNr}}$ PhysikProfs´

PhiloVorls := Vorlesungen $\ltimes_{\text{gelesenVon=PersNr}}$ PhiloProfs´

$\Pi_{\text{Titel, Name}}$((TheolProfs´ $\bowtie_p$ TheolVorls) ∪
(PhysikProfs´ $\bowtie_p$ PhysikVorls) ∪
(PhiloProfs´ $\bowtie_p$ PhiloVorls) )

mit $p \equiv$ (PersNr = gelesenVon)

18

## Vertikale Fragmentierung

abstrakte Darstellung:

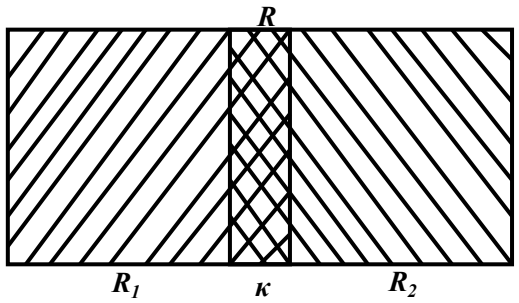


19

## Vertikale Fragmentierung

Beliebige vertikale Fragmentierung gewährleistet ***keine Rekonstruierbarkeit***

2 mögliche Ansätze, um Rekonstruierbarkeit zu garantieren:

- jedes Fragment enthält den Primärschlüssel der Originalrelation. Aber: Verletzung der *Disjunktheit*
- jedem Tupel der Originalrelation wird ein eindeutiges ***Surrogat*** (= künstlich erzeugter Objektindikator) zugeordnet, welches in jedes vertikale Fragment des Tupels mit aufgenommen wird

20

## Vertikale Fragmentierung (Beispiel)

für die Universitätsverwaltung sind PersNr, Name, Gehalt und Steuerklasse interessant:

ProfVerw := $\Pi_{\text{PersNr, Name, Gehalt, Steuerklasse}}$ (Professoren)

für Lehre und Forschung sind dagegen PersNr, Name, Rang, Raum und Fakultät von Bedeutung:

Profs := $\Pi_{\text{PersNr, Name, Rang, Raum, Fakultät}}$ (Professoren)

Rekonstruktion der Originalrelation *Professoren*:

Professoren = ProfVerw $\bowtie_{\text{ProfVerw.PersNr = Profs.PersNr}}$ Profs



## Kombinierte Fragmentierung

a) horizontale Fragmentierung nach vertikaler Fragmentierung

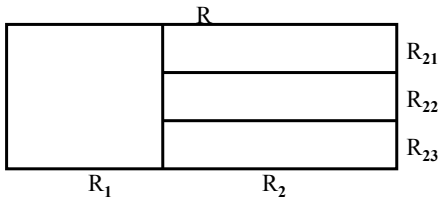


b) vertikale Fragmentierung nach horizontaler Fragmentierung

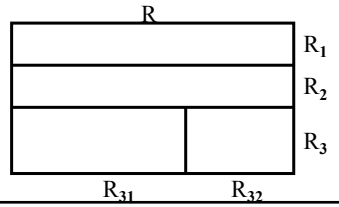




## Rekonstruktion nach kombinierter Fragmentierung

Fall a)

$$R = R_1 \bowtie_p (R_{21} \cup R_{22} \cup R_{23})$$

Fall b)

$$R = R_1 \cup R_2 \cup (R_{31} \bowtie_{R_{31}.K = R_{32}.K} R_{32})$$



## Baumdarstellung der Fragmentierungen (Beispiel)

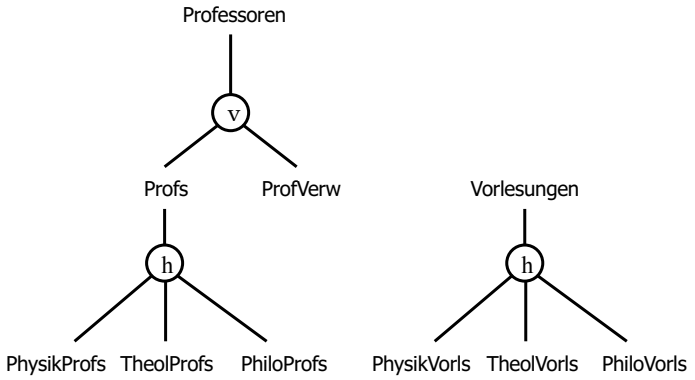

## Allokation

Dasselbe Fragment kann mehreren Stationen zugeordnet werden

Allokation für unser Beispiel ohne Replikationen ⇒ **redundanzfreie** Zuordnung

| Station | Bemerkung | zugeordnete Fragemente |
|---|---|---|
| $S_{Verw}$ | Verwaltungsrechner | *{ProfVerw}* |
| $S_{Physik}$ | Dekanat Physik | *{PhysikVorls, PhysikProfs}* |
| $S_{Philo}$ | Dekanat Philosophie | *{PhiloVorls, PhiloProfs}* |
| $S_{Theol}$ | Dekanat Theologie | *{TheolVorls, TheolProfs}* |



## Transparenz in verteilten Datenbanken

Grad der Unabhängigkeit den ein VDBMS dem Benutzer beim Zugriff auf verteilte Daten vermittelt

verschiedene Stufen der Transparenz:

- Fragmentierungstransparenz
- Allokationstransparenz
- Lokale Schema-Transparenz



## Fragmentierungstranparenz

Beispielanfrage, die Fragmentierungstransparenz voraussetzt:

**select** Titel, Name
**from** Vorlesungen, Professoren
**where** gelesenVon = PersNr;

Beispiel für eine Änderungsoperation, die Fragmentierungs-transparenz voraussetzt:

**update** Professoren
**set** Fakultät = ‚Theologie'
**where** Name = ‚Sokrates';



## Fortsetzung Beispiel

Ändern des Attributwertes von *Fakultät*

- Transferieren des Sokrates-Tupels aus Fragment *PhiloProfs* in das Fragment *TheolProfs* (= Löschen aus *PhiloProfs*, Einfügen in *TheolProfs*)
- Ändern der abgeleiteten Fragmentierung von *Vorlesungen* (= Einfügen der von Sokrates gehaltenen Vorlesungen in *TheolVorls*, Löschen der von ihm gehaltenen Vorlesungen aus *PhiloVorls*)

## Allokationstransparenz

Benutzer müssen Fragmentierung kennen, aber nicht den „Aufenthaltsort" eines Fragments

Beispielanfrage:

**select** Gehalt
**from** ProfVerw
**where** Name = ‚Sokrates';

29

## Allokationstransparenz (Forts.)

unter Umständen muss Originalrelation rekonstruiert werden

Beispiel:
Verwaltung möchte wissen, wieviel die C4-Professoren der Theologie insgesamt verdienen

da Fragmentierungstransparenz fehlt muss die Anfrage folgendermaßen formuliert werden:

**select sum** (Gehalt)
**from** ProfVerw, TheolProfs
**where** ProfVerw.PersNr = TheolProfs.PersNr **and**
Rang = ‚C4';

30

## Lokale Schema-Transparenz

Der Benutzer muss auch noch den Rechner kennen, auf dem ein Fragment liegt.

Beispielanfrage:

**select** Name
**from** TheolProfs **at** $S_{Theol}$
**where** Rang = ‚C3';

31

## Lokale Schema-Transparenz (Forts.)

Ist überhaupt Transparenz gegeben?

Lokale Schema-Transparenz setzt voraus, dass alle Rechner dasselbe Datenmodell und dieselbe Anfragesprache verwenden.
⇒ vorherige Anfrage kann somit analog auch an Station $S_{Philo}$ ausgeführt werden
Dies ist nicht möglich bei Kopplung unterschiedlicher DBMS.

Verwendung grundsätzlich verschiedener Datenmodelle auf lokalen DBMS nennt man „Multi-Database-Systems" (oft unumgänglich in „realer" Welt).

32

## Anfrageübersetzung und Anfrageoptimierung

Voraussetzung: Fragmentierungstransparenz

Aufgabe des Anfrageübersetzers: Generierung eines Anfrageauswertungsplans auf den Fragmenten

Aufgabe des Anfrageoptimierers: Generierung eines möglichst effizienten Auswertungsplanes

→ abhängig von der Allokation der Fragmente auf den verschiedenen Stationen des Rechnernetzes



## Anfragebearbeitung bei horizontaler Fragmentierung

Übersetzung einer SQL-Anfrage auf dem globalen Schema in eine äquivalente Anfrage auf den Fragmenten benötigt 2 Schritte:

1. Rekonstruktion aller in der Anfrage vorkommenden globalen Relationen aus den Fragmenten, in die sie während der Fragmentierungsphase zerlegt wurden. Hierfür erhält man einen algebraischen Ausdruck.
2. Kombination des Rekonstruktionsausdrucks mit dem algebraischen Anfrageausdruck, der sich aus der Übersetzung der SQL-Anfrage ergibt.



## Beispiel

**select** Titel
**from** Vorlesungen, Profs
**where** gelesenVon = PersNr **and**
Rang = ‚C4‘;

Der entstandene algebraische Ausdruck heißt kanonische Form der Anfrage:

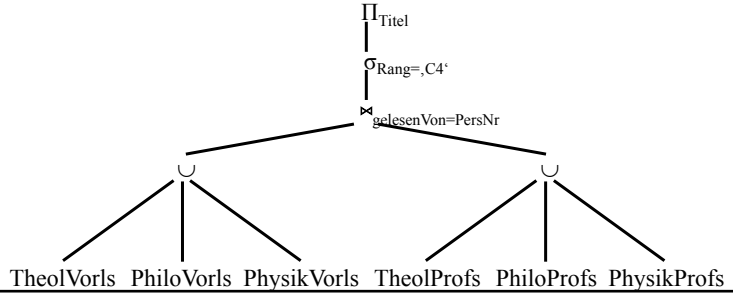




## Algebraische Äquivalenzen

Für eine effizientere Abarbeitung der Anfrage benutzt der Anfrageoptimierer die folgende Eigenschaft:

$(R_1 \cup R_2) \bowtie_p (S_1 \cup S_2) =$
$(R_1 \bowtie_p S_1) \cup (R_1 \bowtie_p S_2) \cup (R_2 \bowtie_p S_1) \cup (R_2 \bowtie_p S_2)$

Die Verallgemeinerung auf $n$ horizontale Fragmente $R_1,\ldots,R_n$ von $R$ und $m$ Fragmente $S_1,\ldots,S_m$ von $S$ ergibt:

$$(R_1 \cup \ldots \cup R_n) \bowtie_p (S_1 \cup \ldots \cup S_m) = \bigcup_{1\le i\le n} \bigcup_{1\le j\le m} (R_i \bowtie_p S_j)$$

Falls gilt: $S_i = S \ltimes_p R_i$ mit $S = S_1 \cup \ldots \cup S_n$
Dann gilt immer:

$R \bowtie_p S = \bigcup_{1\le i\le m} (R_i \bowtie_p S_i)$

## Algebraische Äquivalenzen (Forts.)

Für eine derartig abgeleitete horizontale Fragmentierung von S gilt somit:

$(R_1 \cup ... \cup R_n) \bowtie_p (S_1 \cup ... \cup S_m) =$

$(R_1 \bowtie_p S_1) \cup (R_2 \bowtie_p S_2) \cup ... \cup (R_n \bowtie_p S_n)$



## Algebraische Äquivalenzen (Forts.)

Für eine derartig abgeleitete horizontale Fragmentierung von S gilt somit:

$(R_1 \cup ... \cup R_n) \bowtie_p (S_1 \cup ... \cup S_m) =$

$(R_1 \bowtie_p S_1) \cup (R_2 \bowtie_p S_2) \cup ... \cup (R_n \bowtie_p S_n)$

Für unser Beispiel gilt nun folgendes:

(TheolVorls ∪ PhysikVorls ∪ PhiloVorls) ⋈...
(TheolProfs ∪ PhysikProfs ∪ PhiloProfs)

Um Selektionen und Projektionen über den Vereinigungs-operator hinweg „nach unten zu drücken" benötigt man folgende Regeln:

- $\sigma_p(R_1 \cup R_2) = \sigma_p(R_1) \cup \sigma_p(R_2)$
- $\Pi_L(R_1 \cup R_2) = \Pi_L(R_1) \cup \Pi_L(R_2)$



## Optimale Form der Anfrage

Die Anwendung dieser algebraischen Regeln generiert den folgenden Auswertungsplan:

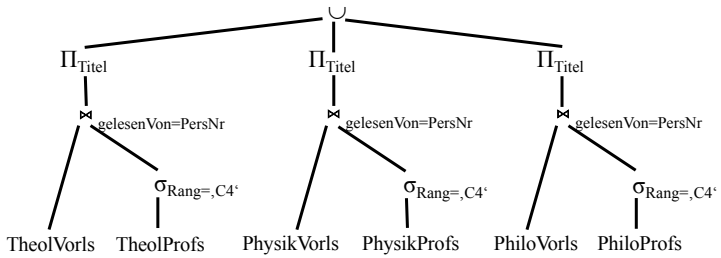


Auswertungen können lokal auf den Stationen $S_{Theol}$, $S_{Physik}$ und $S_{Philo}$ ausgeführt werden ⇒ Stationen können parallel abarbeiten und lokales Ergebnis voneinander unabhängig an die Station, die die abschliessende Vereinigung durchführt, übermitteln.



## Anfragebearbeitung bei vertikaler Fragmentierung

Beispiel:

**select** Name, Gehalt
**from** Professoren
**where** Gehalt > 80000;

kanonischer Auswertungsplan:

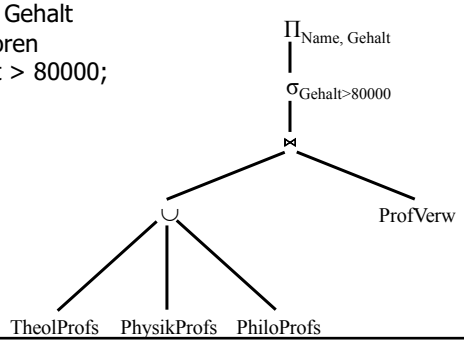

## Optimierung bei vertikaler Fragmentierung

Für unser Beispiel gilt:

Alle notwendigen Informationen sind in *ProfVerw* enthalten ⇒
der Teil mit Vereinigung und Join kann „abgeschnitten" werden.
Das ergibt den folgenden
optimierten Auswertungsplan:

$\Pi_{\text{Name, Gehalt}}$
|
$\sigma_{\text{Gehalt>80000}}$
|
ProfVerw

Beispiel für eine schlecht zu optimierende Anfrage:
(Attribut *Rang* fehlt in *ProfVerw*)

**select** Name, Gehalt, Rang
**from** Professoren
**where** Gehalt > 80000;

41

## Der natürliche Verbund zweier Relationen R und S

| R | | |
|---|---|---|
| A | B | C |
| $a_1$ | $b_1$ | $c_1$ |
| $a_2$ | $b_2$ | $c_2$ |
| $a_3$ | $b_3$ | $c_1$ |
| $a_4$ | $b_4$ | $c_2$ |
| $a_5$ | $b_5$ | $c_3$ |
| $a_6$ | $b_6$ | $c_2$ |
| $a_7$ | $b_7$ | $c_6$ |

⋈

| S | | |
|---|---|---|
| C | D | E |
| $c_1$ | $d_1$ | $e_1$ |
| $c_3$ | $d_2$ | $e_2$ |
| $c_4$ | $d_3$ | $e_3$ |
| $c_5$ | $d_4$ | $e_4$ |
| $c_7$ | $d_5$ | $e_5$ |
| $c_8$ | $d_6$ | $e_6$ |
| $c_5$ | $d_7$ | $e_7$ |

=

| R A S | | | | |
|---|---|---|---|---|
| A | B | C | D | E |
| $a_1$ | $b_1$ | $c_1$ | $d_1$ | $e_1$ |
| $a_3$ | $b_3$ | $c_1$ | $d_1$ | $e_1$ |
| $a_5$ | $b_5$ | $c_3$ | $d_2$ | $e_2$ |

42

## Join-Auswertung in VDBMS

spielt kritischere Rolle als in zentralisierten Datenbanken

Problem: Argumente eines Joins zweier Relationen können auf unterschiedlichen Stationen des VDBMS liegen

2 Möglichkeiten: Join-Auswertung mit und ohne Filterung

43

## Join-Auswertung

Betrachtung des allgemeinsten Falles:

äußere Argumentrelation *R* ist auf Station $St_R$ gespeichert

innere Argumentrelation *S* ist dem Knoten $St_S$ zugeordnet

Ergebnis der Joinberechnung wird auf einem dritten Knoten $St_{Result}$ benötigt

44

## Join-Auswertung ohne Filterung

Nested-Loops

Transfer einer Argumentrelation

Transfer beider Argumentrelationen



## Nested-Loops

Iteration durch die äußere Relation *R* mittels Laufvariable *r* und Anforderung des/der zu jedem Tupel *r* passenden Tupel *s* ∈ *S* mit *r.C* = *s.C* (über Kommunikationsnetz bei $St_S$)

Diese Vorgehensweise benötigt pro Tupel aus *R* eine Anforderung und eine passende Tupelmenge aus *S* (welche bei vielen Anforderungen leer sein könnte)
⇒ es werden $2 * |R|$ Nachrichten benötigt



## Der natürliche Verbund zweier Relationen R und S

| R | | |
|---|---|---|
| A | B | C |
| $a_1$ | $b_1$ | $c_1$ |
| $a_2$ | $b_2$ | $c_2$ |
| $a_3$ | $b_3$ | $c_1$ |
| $a_4$ | $b_4$ | $c_2$ |
| $a_5$ | $b_5$ | $c_3$ |
| $a_6$ | $b_6$ | $c_2$ |
| $a_7$ | $b_7$ | $c_6$ |

| S | | |
|---|---|---|
| C | D | E |
| $c_1$ | $d_1$ | $e_1$ |
| $c_3$ | $d_2$ | $e_2$ |
| $c_4$ | $d_3$ | $e_3$ |
| $c_5$ | $d_4$ | $e_4$ |
| $c_7$ | $d_5$ | $e_5$ |
| $c_8$ | $d_6$ | $e_6$ |
| $c_5$ | $d_7$ | $e_7$ |



## Transfer einer Argumentrelation

1. vollständiger Transfer einer Argumentrelation (z.B. R) zum Knoten der anderen Argumentrelation
2. Ausnutzung eines möglicherweise auf *S.C* existierenden Indexes

## Der natürliche Verbund zweier Relationen R und S

| R | | |
|---|---|---|
| A | B | C |
| $a_1$ | $b_1$ | $c_1$ |
| $a_2$ | $b_2$ | $c_2$ |
| $a_3$ | $b_3$ | $c_1$ |
| $a_4$ | $b_4$ | $c_2$ |
| $a_5$ | $b_5$ | $c_3$ |
| $a_6$ | $b_6$ | $c_2$ |
| $a_7$ | $b_7$ | $c_6$ |

| S | | |
|---|---|---|
| C | D | E |
| $c_1$ | $d_1$ | $e_1$ |
| $c_3$ | $d_2$ | $e_2$ |
| $c_4$ | $d_3$ | $e_3$ |
| $c_5$ | $d_4$ | $e_4$ |
| $c_7$ | $d_5$ | $e_5$ |
| $c_8$ | $d_6$ | $e_6$ |
| $c_5$ | $d_7$ | $e_7$ |

49

## Transfer beider Argumentrelationen

1. Transfer beider Argumentrelationen zum Rechner $St_{Result}$
2. Berechnung des Ergebnisses auf dem Knoten $St_{Result}$ mittels
   - a) Merge-Join (bei vorliegender Sortierung)

   oder
   - b) Hash-Join (bei fehlender Sortierung)

   → evtl. Verlust der vorliegenden Indexe für die Join-Berechnung

   → kein Verlust der Sortierung der Argumentrelation(en)

50

## Join-Auswertung mit Filterung

Verwendung des Semi-Join-Operators zur Filterung

Schlüsselidee: nur Transfer von Tupeln, die passenden Join-Partner haben

Benutzung der folgenden algebraischen Eigenschaften:

- $R \ltimes S = R \ltimes (R \bowtie S)$
- $R \bowtie S = \Pi_C(R) \bowtie S$

51

## Join-Auswertung mit Filterung (Beispiel, Filterung der Relation *S*)

1. Transfer der unterschiedlichen *C*-Werte von $R$ ($= \Pi_C(R)$) nach $St_S$
2. Auswertung des Semi-Joins $R \ltimes S = \Pi_C(R) \ltimes S$ auf $St_S$ und Transfer nach $St_R$
3. Auswertung des Joins auf $St_R$, der nur diese transferierten Ergebnistupel des Semi-Joins braucht

Transferkosten werden nur reduziert, wenn gilt:
$\| \Pi_C(R) \| + \| R \ltimes S \| < \| S \|$
mit $\| R \|$ = Größe (in Byte) einer Relation

52

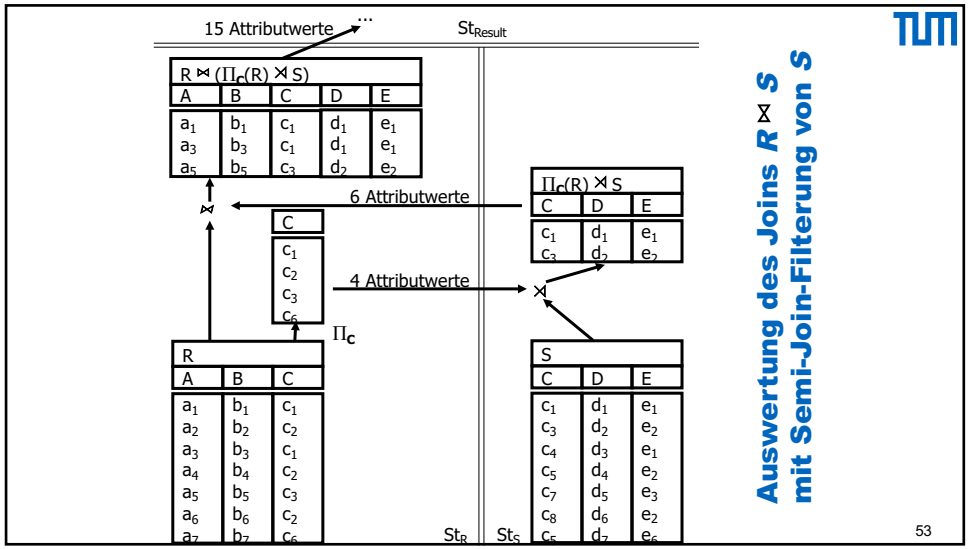
15 Attributwerte
$St_{Result}$
$R \bowtie (\Pi_C(R) \bowtie S)$
A B C D E
6 Attributwerte
$\Pi_C(R) \bowtie S$
C D E
4 Attributwerte
$\Pi_C$
R
A B C
S
C D E
$St_R$
$St_S$
Auswertung des Joins $R \bowtie S$ mit Semi-Join-Filterung von $S$
53

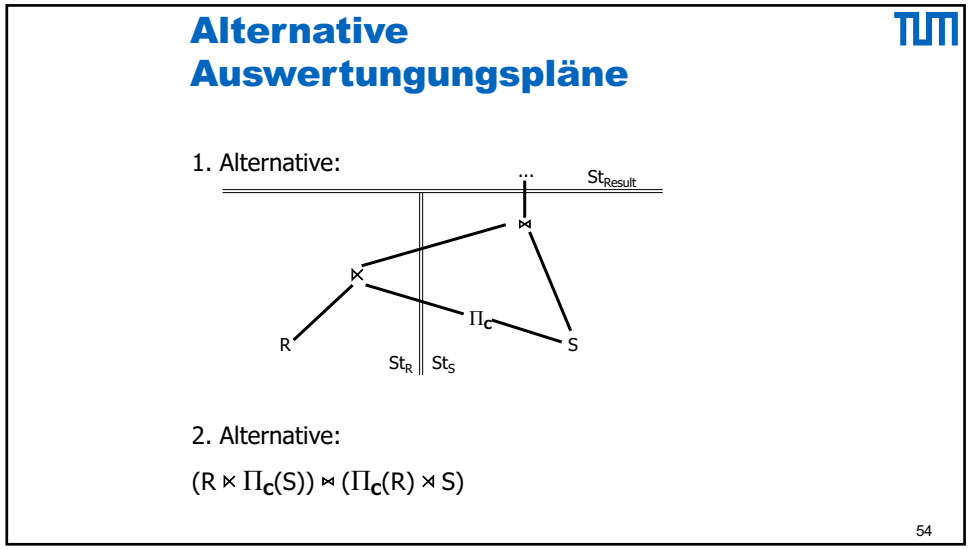
Alternative Auswertungungspläne
1. Alternative:
$St_{Result}$
$\Pi_C$
R
S
$St_R$
$St_S$
2. Alternative:
$(R \ltimes \Pi_C(S)) \bowtie (\Pi_C(R) \bowtie S)$
54

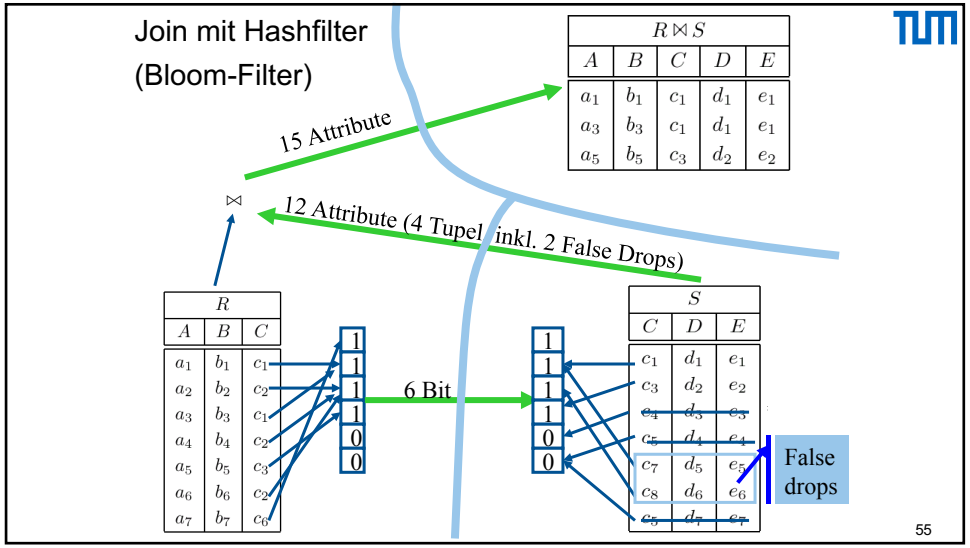
Join mit Hashfilter
(Bloom-Filter)
15 Attribute
12 Attribute (4 Tupel inkl. 2 False Drops)
6 Bit
False drops
55

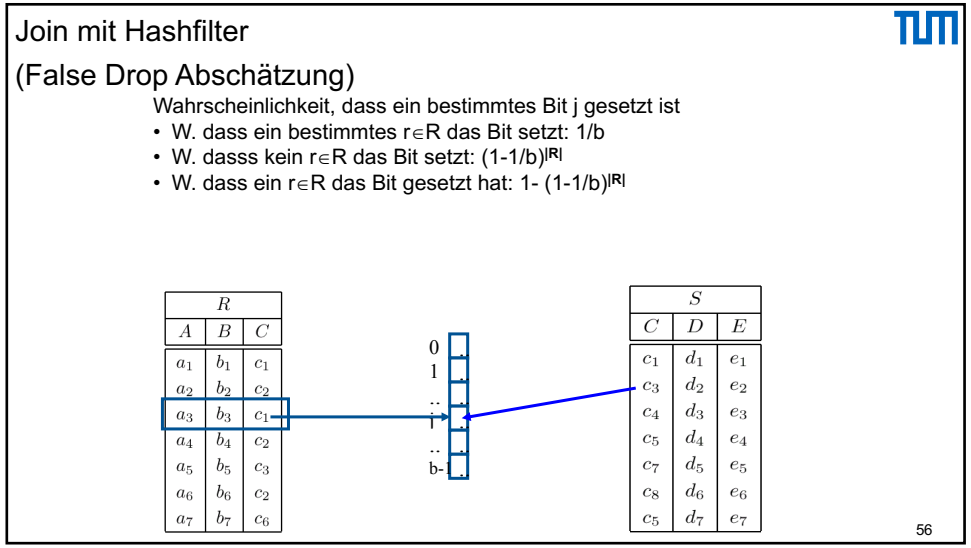
Join mit Hashfilter
(False Drop Abschätzung)
Wahrscheinlichkeit, dass ein bestimmtes Bit j gesetzt ist
• W. dass ein bestimmtes r∈R das Bit setzt: 1/b
• W. dasss kein r∈R das Bit setzt: (1-1/b)^|R|
• W. dass ein r∈R das Bit gesetzt hat: 1- (1-1/b)^|R|
56

## Join mit Hashfilter

## (False Drop Abschätzung)

W. dass irgendein r∈R ein bestimmtes Bit gesetzt hat: 1- (1-1/b)$^{|R|}$

Wieviele Bits sind gesetzt?
- b * [1- (1-1/b)$^{|R|}$]

Mehrere r∈R können dasselbe Bit setzen

Approximation: alle r∈R setzen unterschiedliche Bits
- W. dass ein bestimmtes Bit j gesetzt ist: |R| / b
- b >> |R|

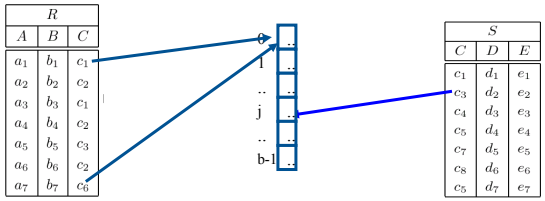




## Join mit Hashfilter

## (False Drop Abschätzung)

W. dass irgendein r∈R ein bestimmtes Bit gesetzt hat:
- 1- (1-1/b)$^{|R|}$

W. dass ein bestimmtes s∈S ausgewählt wird:
- 1- (1-1/b)$^{|R|}$

Wieviele s∈S werden ausgewählt?
- |S| * [1- (1-1/b)$^{|R|}$]

Approximation: alle r setzen unterschiedliche Bits
- W. dass ein bestimmtes Bit j gesetzt ist: |R| / b
- |S|*(|R|/b) Elemente aus S werden ausgewählt

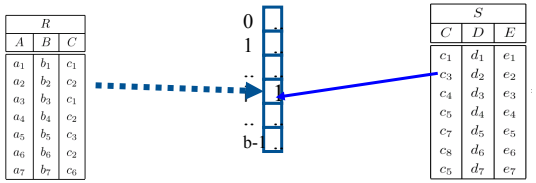




## Parameter für die Kosten eines Auswertungsplan

Kardinalitäten von Argumentrelationen

Selektivitäten von Joins und Selektionen

Transferkosten für Datenkommunikation (Verbindungsaufbau + von Datenvolumen abhängiger Anteil für Transfer)

Auslastung der einzelnen VDBMS-Stationen

Effektive Anfrageoptimierung muss auf Basis eines Kostenmodells durchgeführt werden und soll mehrere Alternativen für unterschiedliche Auslastungen des VDBMS erzeugen.



## Transaktionskontrolle in VDBMS

Transaktionen können sich bei VDBMS über mehrere Rechnerknoten erstrecken

⇒ Recovery:

- Redo: Wenn eine Station nach einem Fehler wieder anläuft, müssen alle Änderungen einmal abgeschlossener Transaktionen - seien sie lokal auf dieser Station oder global über mehrere Stationen ausgeführt worden - auf den an dieser Station abgelegten Daten wiederhergestellt werden.
- Undo: Die Änderungen noch nicht abgeschlossener lokaler und globaler Transaktionen müssen auf den an der abgestürzten Station vorliegenden Daten rückgängig gemacht werden.

## EOT-Behandlung

Die EOT (End-of-Transaction)-Behandlung von globalen Transaktionen stellt in VDBMS ein Problem dar.

Eine globale Transaktion muss atomar beendet werden, d.h. entweder

- **commit**: globale Transaktion wird an allen (relevanten) lokalen Stationen festgeschrieben

**oder**

- **abort**: globale Transaktion wird gar nicht festgeschrieben

⇒ Problem in verteilter Umgebung, da die Stationen eines VDBMS unabhängig voneinander „abstürzen" können



## Problemlösung:

## *Zweiphasen-Commit-Protokoll*

→ gewährleistet die Atomarität der EOT-Behandlung

das 2PC-Verfahren wird von sog. Koordinator *K* überwacht und gewährleistet, dass die *n* Agenten (=Stationen im VDBMS) $A_1,...A_n$, die an einer Transaktion beteiligt waren, entweder alle von Transaktion *T* geänderten Daten festschreiben oder alle Änderungen von *T* rückgängig machen



## Nachrichtenaustausch beim 2PC-Protokoll (für 4 Agenten)

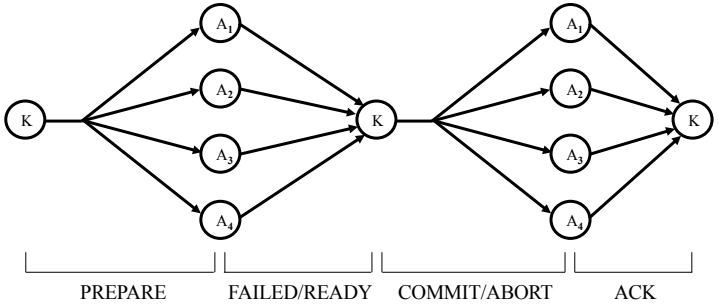




## Ablauf der EOT-Behandlung beim 2PC-Protokoll

*K* schickt allen Agenten eine PREPARE-Nachricht, um herauszufinden, ob sie Transaktionen festschreiben können
jeder Agent $A_i$ empfängt PREPARE-Nachricht und schickt eine von zwei möglichen Nachrichten an *K*:

- READY, falls $A_i$ in der Lage ist, die Transaktion *T* lokal festzuschreiben
- FAILED, falls $A_i$ kein **commit** durchführen kann (wegen Fehler, Inkonsistenz etc.)

- hat *K* von **allen** *n* Agenten $A_1,...,A_n$ ein READY erhalten, kann *K* ein COMMIT an alle Agenten schicken mit der Aufforderung, die Änderungen von *T* lokal festzuschreiben; antwortet einer der Agenten mit FAILED od. gar nicht innerhalb einer bestimmten Zeit (*timeout*), schickt *K* ein ABORT an alle Agenten und diese machen die Änderungen der Transaktion rückgängig
- haben die Agenten ihre lokale EOT-Behandlung abgeschlossen, schicken sie eine ACK-Nachricht (=acknowledgement, dt. Bestätigung) an den Koordinator

## Lineare Organisationsform beim 2PC-Protokoll

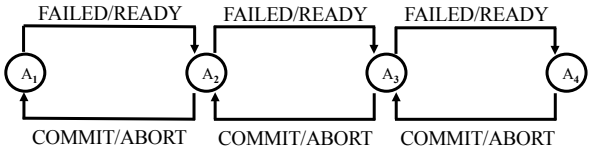


65

## Zustandsübergang beim 2PC-Protokoll: Koordinator

„Bullet" ● = wichtigste Aktion(en)

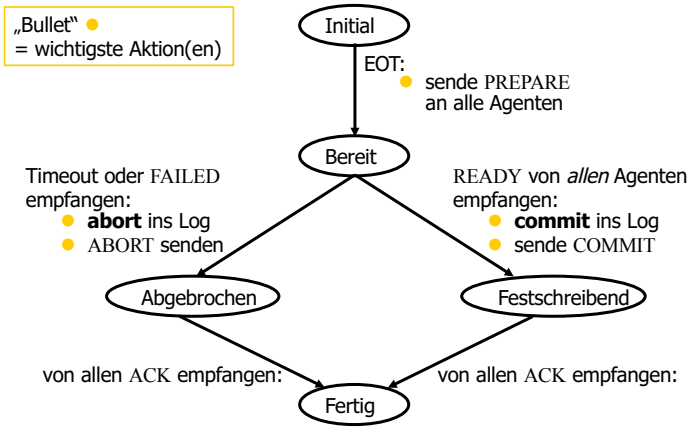


66

## Zustandsübergang beim 2PC-Protokoll: Agent

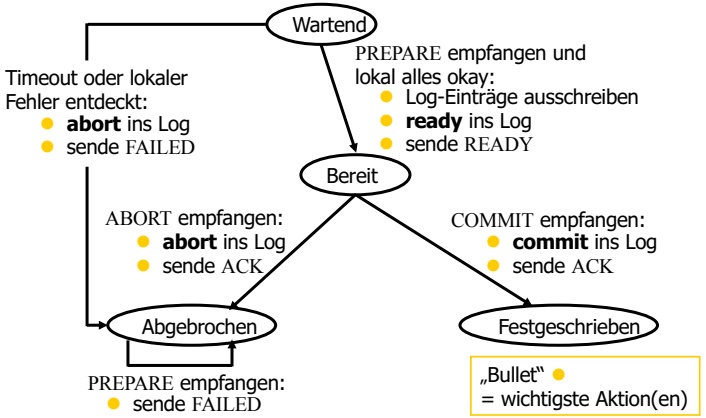


67

## Fehlersituationen des 2PC-Protokolls

Absturz eines Koordinators

Absturz eines Agenten

verlorengegangene Nachrichten

68

## Absturz eines Koordinators

- Absturz vor dem Senden einer COMMIT-Nachricht → Rückgängigmachen der Transaktion durch Versenden einer ABORT-Nachricht
- Absturz nachdem Agenten ein READY mitgeteilt haben → Blockierung der Agenten

⇒ Hauptproblem des 2PC-Protokolls beim Absturz des Koordinators, da dadurch die Verfügbarkeit des Agenten bezüglich andere globaler und lokaler Transaktionen drastisch eingeschränkt ist

Um Blockierung von Agenten zu verhindern, wurde ein **Dreiphasen-Commit-Protokoll** konzipiert, das aber in der Praxis zu aufwendig ist (VDBMS benutzen das 2PC-Protokoll).

69

## Absturz eines Agenten

- antwortet ein Agent innerhalb eines Timeout-Intervalls nicht auf die *PREPARE*-Nachricht, gilt der Agent als abgestürzt; der Koordinator bricht die Transaktion ab und schickt eine *ABORT*-Nachricht an alle Agenten
- „abgestürzter" Agent schaut beim Wiederanlauf in seine Log-Datei:
  - kein **ready**-Eintrag bzgl. Transaktion *T* → Agent führt ein abort durch und teilt dies dem Koordinator mit (*FAILED*-Nachricht)
  - **ready**-Eintrag aber kein **commit**-Eintrag → Agent fragt Koordinator, was aus Transaktion *T* geworden ist; Koordinator teilt *COMMIT* oder *ABORT* mit, was beim Agenten zu einem Redo oder Undo der Transaktion führt
  - **commit**-Eintrag vorhanden → Agent weiß ohne Nachfragen, dass ein (lokales) Redo der Transaktion nötig ist

70

## Verlorengegangene Nachrichten

- *PREPARE*-Nachricht des Koordinators an einen Agenten geht verloren oder
- *READY*-(oder *FAILED*-)Nachricht eines Agenten geht verloren

→ nach Timeout-Intervall geht Koordinator davon aus, dass betreffender Agent nicht funktionsfähig ist und sendet *ABORT*-Nachricht an alle Agenten (Transaktion gescheitert)

- Agent erhält im Zustand **Bereit** keine Nachricht vom Koordinator

→ Agent ist blockiert, bis *COMMIT*- oder *ABORT*-Nachricht vom Koordinator kommt, da Agent nicht selbst entscheiden kann (deshalb schickt Agent eine „Erinnerung" an den Koordinator)

71

## Mehrbenutzersynchronisation in VDBMS

Serialisierbarkeit

Zwei-Phasen-Sperrprotokoll in VDBMS

- lokale Sperrverwaltung an jeder Station
- globale Sperrverwaltung

72

## Serialisierbarkeit

Lokale Serialisierbarkeit an jeder der an den Transaktionen beteiligten Stationen reicht nicht aus. Deshalb muß man bei der Mehrbenutzersynchronisation auf globaler Serialisierbarkeit bestehen.

Beispiel (lokal serialisierbare Historien):

$S_1$

| Schritt | $T_1$ | $T_2$ |
|---|---|---|
| 1. | r(A) | |
| 2. | | w(A) |

$S_2$

| Schritt | $T_1$ | $T_2$ |
|---|---|---|
| 3. | | w(B) |
| 4. | r(B) | |

$T_1 \leftrightarrow T_2$



## Lokale Sperrverwaltung

globale Transaktion muss vor Zugriff/Modifikation eines Datums A, das auf Station S liegt, eine Sperre vom Sperrverwalter der Station S erwerben

Verträglichkeit der angeforderten Sperre mit bereits existierenden Sperren kann lokal entschieden werden → favorisiert lokale Transaktionen, da diese nur mit ihrem lokalen Sperrverwalter kommunizieren müssen



## Globale Sperrverwaltung

= alle Transaktionen fordern alle Sperren an einer einzigen, ausgezeichneten Station an.

Nachteile:

zentraler Sperrverwalter kann zum Engpass des VDBMS werden, besonders bei einem Absturz der Sperrverwalter-Station („rien ne vas plus“)

Verletzung der lokalen Autonomie der Stationen, da auch lokale Transaktionen ihre Sperren bei der zentralisierten Sperrverwaltung anfordern müssen

⇒ zentrale Sperrverwaltung i.a. nicht akzeptabel



## Deadlocks in VDBMS

Erkennung von Deadlocks (Verklemmungen)

- zentralisierte Deadlock-Erkennung
- dezentrale (verteilte) Deadlock-Erkennung

- Vermeidung von Deadlocks

## „Verteilter“ Deadlock

$S_1$

| Schritt | $T_1$ | $T_2$ |
|---|---|---|
| 0. | **BOT** | |
| 1. | **lockS**(A) | |
| 2. | r(A) | |
| | | |
| | | |
| 6. | | **lockX**(A) |
| | | ~~~~ |

$S_2$

| Schritt | $T_1$ | $T_2$ |
|---|---|---|
| | | |
| | | |
| 3. | | **BOT** |
| 4. | | **lockX**(B) |
| 5. | | w(B) |
| | | |
| 7. | **lockS**(B) | |
| | ~~~~ | |



## Timeout

betreffende Transaktion wird zurückgesetzt und erneut gestartet
→ einfach zu realisieren

Problem: richtige Wahl des Timeout-Intervalls:

- zu lang → schlechte Ausnutzung der Systemressourcen
- zu kurz → Deadlock-Erkennung, wo gar keine Verklemmung vorliegt



## Zentralisierte Deadlock-Erkennung

Stationen melden lokal vorliegende Wartebeziehungen an neutralen Knoten, der daraus globalen Wartegraphen aufbaut (Zyklus im Graphen → Deadlock)
→ sichere Lösung
Nachteile:

- hoher Aufwand (viele Nachrichten)
- Entstehung von Phantom-Deadlocks (=nicht-existierende Deadlocks) durch „Überholen“ von Nachrichten im Kommunikationssystem



## Dezentrale Deadlock-Erkennung

lokale Wartegraphen an den einzelnen Stationen →
Erkennen von lokalen Deadlocks

Erkennung globaler Deadlocks:

- jeder lokale Wartegraph hat einen Knoten *External*, der stationenübergreifenden Wartebeziehungen zu externen Subtransaktionen modelliert
- Zuordnung jeder Transition zu einem Heimatknoten, von wo aus *externe Subtransaktionen* auf anderen Stationen initiiert werden

Die Kante $External \rightarrow T_i$
wird für jede „von außen“ kommende Transaktion $T_i$ eingeführt.

Die Kante $T_j \rightarrow External$
wird für jede von außen kommende Transaktion $T_j$ dieser Station eingeführt, falls $T_j$ „nach außen“ geht.

## Beispiel:

$S_1$ Heimatknoten von $T_1$, $S_2$ Heimatknoten von $T_2$

Wartegraphen:

$S_1$: $External \rightarrow T_2 \rightarrow T_1 \rightarrow External$

$S_2$ : $External \rightarrow T_1 \rightarrow T_2 \rightarrow External$

$S_2$ : $External \leftrightarrow T_1 \leftrightarrow T_2 \leftrightarrow External$

$T_1 \rightarrow T_2 \rightarrow T_1$

$T_2 \rightarrow T_1 \rightarrow T_2$

Zur Reduzierung des Nachrichtenaufkommens wird der Pfad

$External \rightarrow T_1' \rightarrow T_2' \rightarrow \ldots \rightarrow T_n' \rightarrow External$

nur weitergereicht, wenn $T_1'$ einen kleineren Identifikator als $T_n'$ hat (= path pushing).

81

## Deadlock-Vermeidung

optimistische Mehrbenutzersynchronisation:
nach Abschluss der Transaktionsbearbeitung wird Validierung durchgeführt

Zeitstempel-basierende Synchronisation:
Zuordnung eines Lese-/Schreib-Stempels zu jedem Datum
entscheidet, ob beabsichtigte Operation durchgeführt werden kann ohne Serialisierbarkeit zu verletzen oder ob Transaktion abgebrochen wird (**abort**)

82

## Deadlockvermeidung bei Sperrbasierte Synchronisation

**wound/wait:**
- nur jüngere Transaktionen warten auf ältere;
- fordert ältere Transaktion Sperre an, die mit der von der jüngeren Transaktion gehaltenen nicht verträglich ist, wird jüngere Transaktion abgebrochen

**wait/die:**
- nur ältere Transaktionen warten auf jüngere;
- fordert jüngere Transaktion Sperre an, die mit der von der älteren Transaktion gehaltenen nicht kompatibel ist, wird jüngere Transaktion abgebrochen

83

## Voraussetzungen für Deadlockvermeidungsverfahren

Vergabe global eindeutiger Zeitstempel als Transaktionsidentifikatoren

| lokale Zeit | Stations-ID |
|---|---|

- lokale Uhren müssen hinreichend genau aufeinander abgestimmt sein

84

## Synchronisation bei replizierten Daten

### ROWA: Read One, Write All

**Problem:**

Zu einem Datum A gibt es mehrere Kopien A1, A2, ..., An, die auf unterschiedlichen Stationen liegen.

Eine Lesetransaktion erfordert nur eine Kopie, bei Änderungstransaktionen müssen aber alle bestehenden Kopien geändert werden.

⇒ hohe Laufzeit und Verfügbarkeitsprobleme



## Quorum-Consensus Verfahren

Ausgleich der Leistungsfähigkeit zwischen Lese- und Änderungstransaktionen
→ teilweise Verlagerung des Overheads von den Änderungs- zu den Lesetransaktionen indem den Kopien $A_i$ eines replizierten Datums $A$ individuelle Gewichte zugeordnet werden

- ***Lesequorum*** $Q_r(A)$
- ***Schreibquorum*** $Q_w(A)$

Folgende Bedingungen müssen gelten:

1. $Q_w(A) + Q_w(A) > W(A)$
2. $Q_r(A) + Q_w(A) > W(A)$



## Beispiel

| Station ($S_i$) | Kopie ($A_i$) | Gewicht ($w_i$) |
|---|---|---|
| $S_1$ | $A_1$ | 3 |
| $S_2$ | $A_2$ | 1 |
| $S_3$ | $A_3$ | 2 |
| $S_4$ | $A_4$ | 2 |

$$W(A) = \sum_{i=1}^{4} w_i(A) = 8$$

$$Q_r(A) = 4$$

$$Q_w(A) = 5$$



## Zustände

a) vor dem Schreiben eines Schreibquorums

| Station | Kopie | Gewicht | Wert | Versions# |
|---|---|---|---|---|
| $S_1$ | $A_1$ | 3 | 1000 | 1 |
| $S_2$ | $A_2$ | 1 | 1000 | 1 |
| $S_3$ | $A_3$ | 2 | 1000 | 1 |
| $S_4$ | $A_4$ | 2 | 1000 | 1 |

b) nach dem Schreiben eines Schreibquorums

| Station | Kopie | Gewicht | Wert | Versions# |
|---|---|---|---|---|
| $S_1$ | $A_1$ | 3 | 1100 | 2 |
| $S_2$ | $A_2$ | 1 | 1000 | 1 |
| $S_3$ | $A_3$ | 2 | 1100 | 2 |
| $S_4$ | $A_4$ | 2 | 1000 | 1 |

## Peer to Peer-Informationssysteme

Seti@Home
- P2P number crunching

Napster
- P2P file sharing / Informationsmanagement



## Napster-Architektur

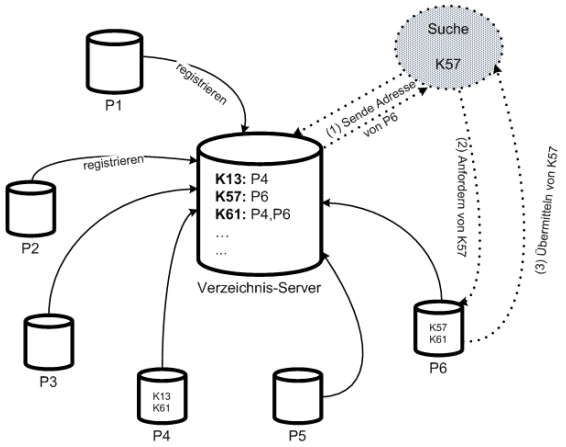




## Gnutella-Architektur

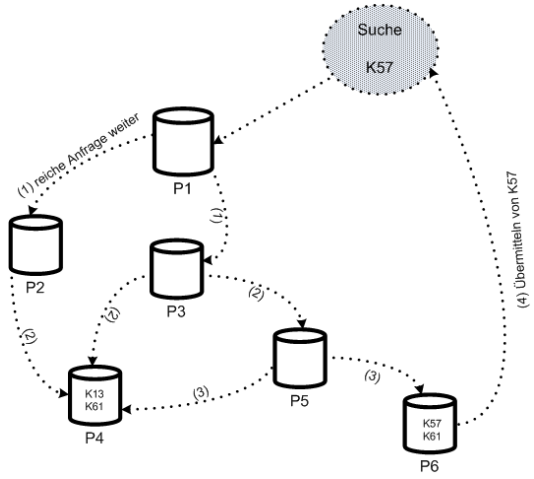




## DHT: Distributed Hash Table

Basieren auf „consistent hashing“

Vollständige Dezentralisierung der Kontrolle

Dennoch zielgerichtete Suche

## CHORD

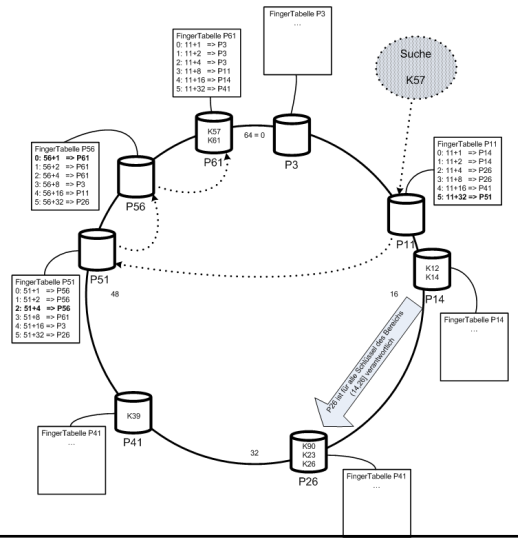




## CAN

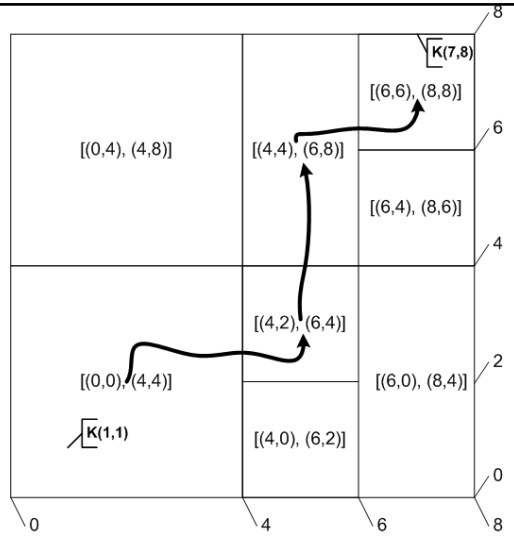




## No-SQL Datenbanken

Internet-scale Skalierbarkeit
CAP-Theorem: nur 2 von 3 Wünschen erfüllbar
- Konsistenz (Consistency)
- Zuverläassigkeit/Verfügbarkeit (Availability)
- Partitionierungs-Toleranz

No-SQL Datenbanksysteme verteilen die Last innerhalb eines Clusters/Netzwerks
- Dabei kommen oft DHT-Techniken zum Einsatz



## Schnittstelle der No-SQL Datenbanken

Insert(k,v)
Lookup(k)
Delete(k)

Extrem einfach ➔ effizient
Aber: wer macht denn die Joins/Selektionen/…
- ➔ das Anwendungsprogramm

## Konsistenzmodell: ~~C~~AP

Relaxiertes Konsistenzmodell
- Replizierte Daten haben nicht alle den neuesten Zustand
  - Vermeidung des (teuren) Zwei-Phasen-Commit-Protokolls
- Transaktionen könnten veraltete Daten zu lesen bekommen
- Eventual Consistency
  - Würde man das System anhalten, würden alle Kopien irgendwann (also eventually) in denselben Zustand übergehen
- Read your Writes-Garantie
  - Tx leist auf jeden Fall ihre eigenen Änderungen
- Monotonic Read-Garantie
  - Tx würde beim wiederholten Lesen keinen älteren Zustand als den vorher mal sichtbaren lesen

97

## Systeme

MongoDB
Cassandra
Dynamo
BigTable
Hstore
SimpleDB
S3
CockroachDB

98