Kapitel 15
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 Kontogutheissungen)

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

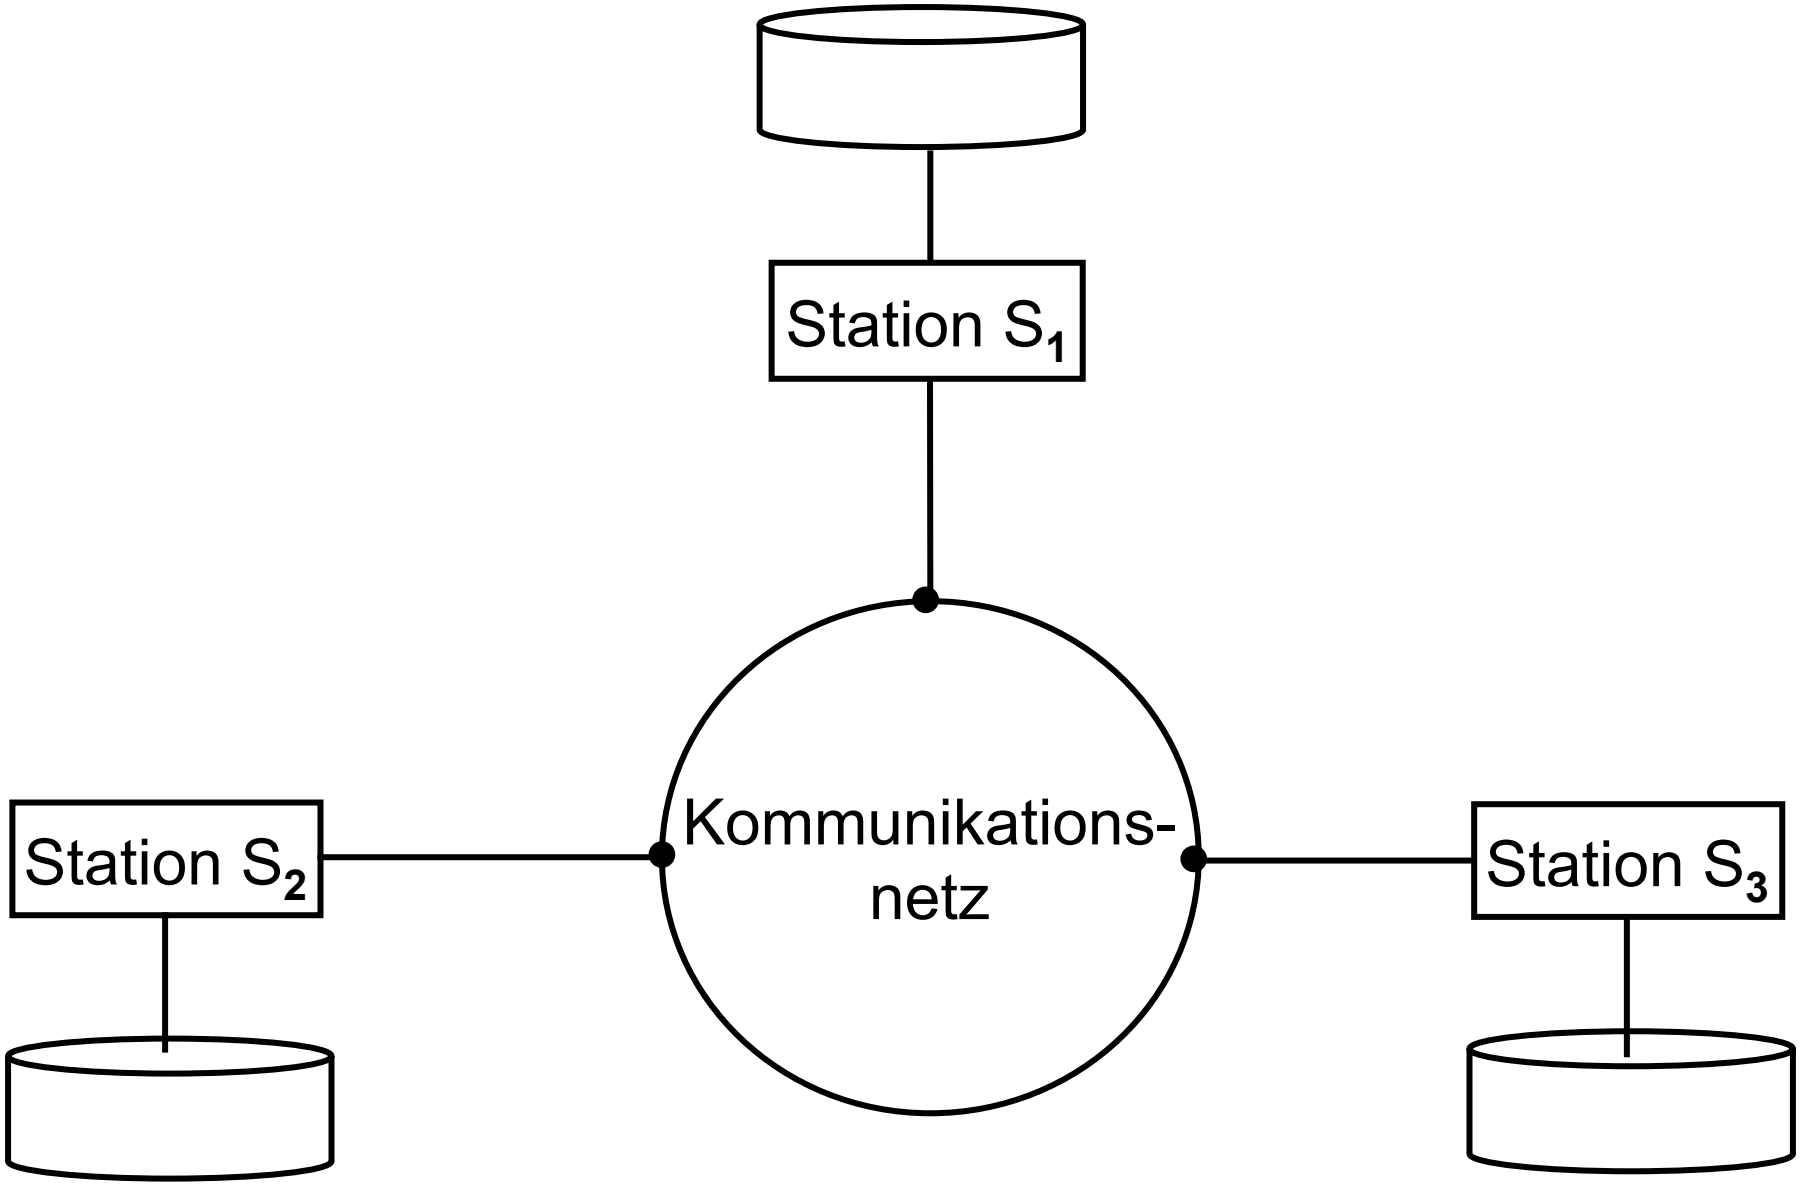

Client-Server-Architektur

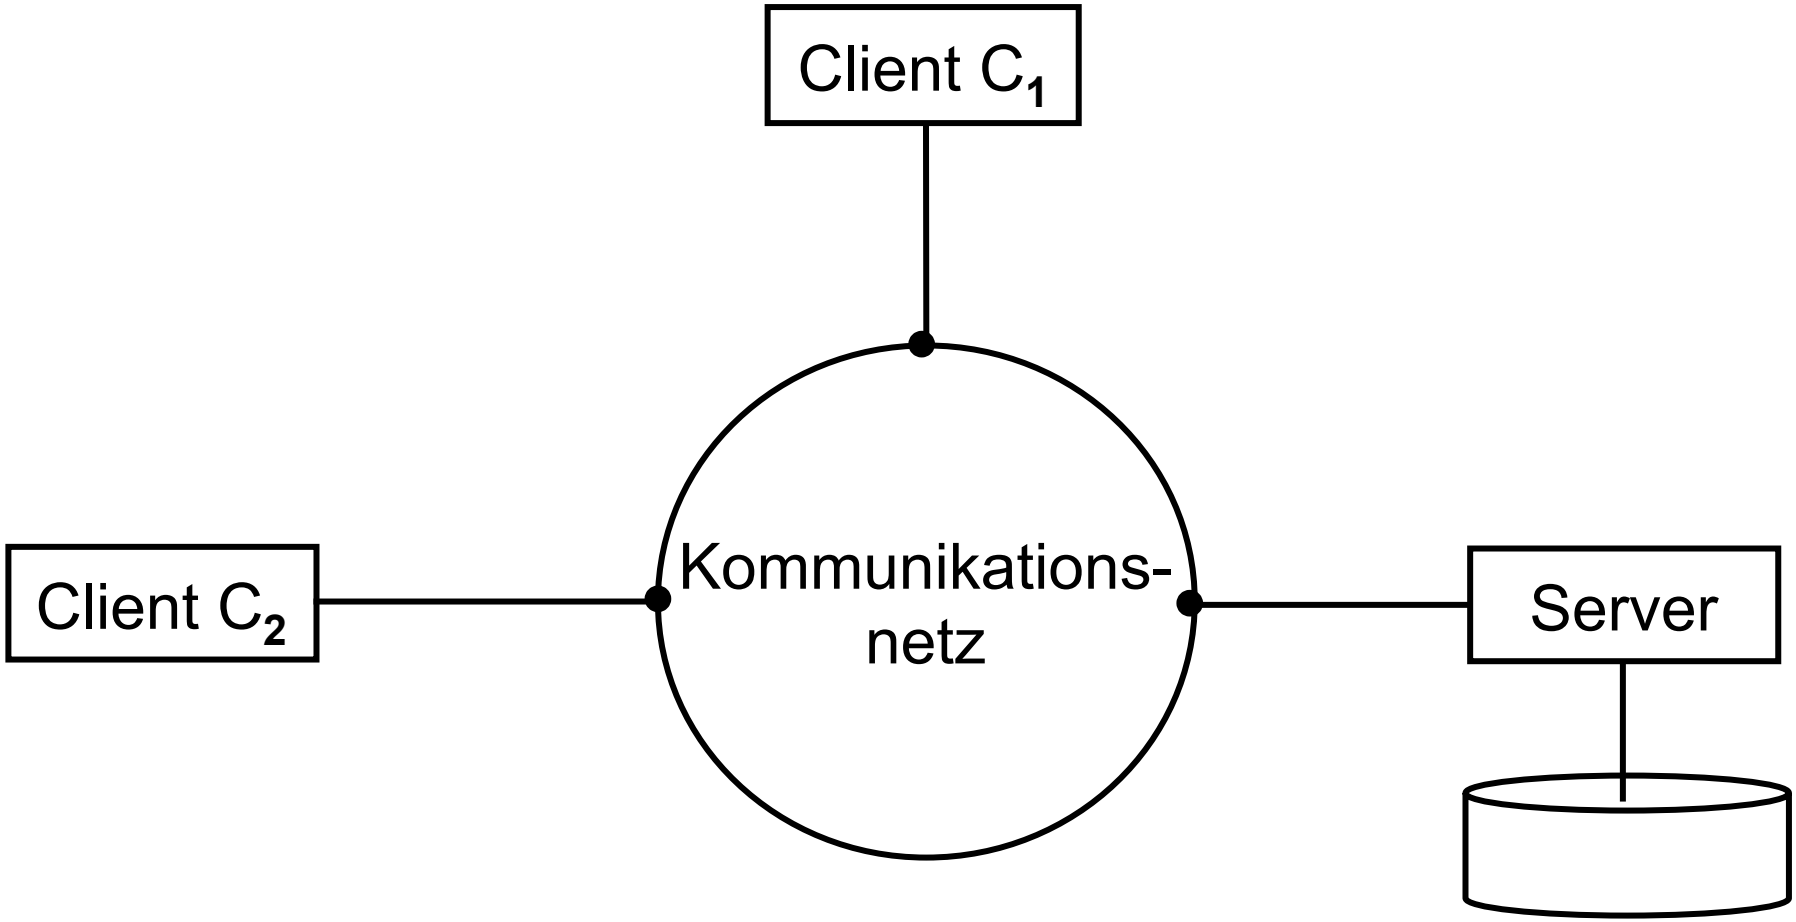

Aufbau und Entwurf eines verteilten Datenbanksystems

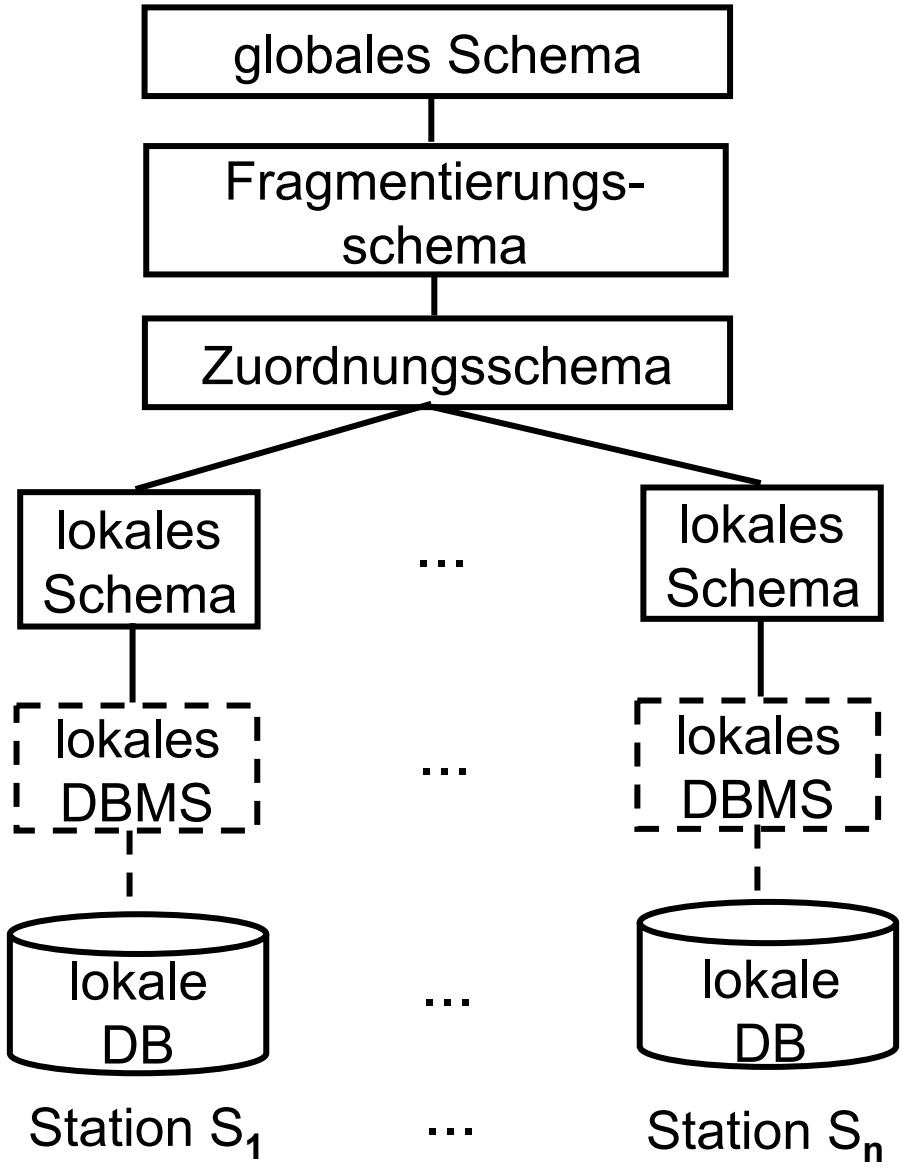

Fragmentierung und Allokation einer Relation

- Fragmentierung: Fragmente enthalten Daten mit gleichem Zugriffsverhalten
- Allokation: Fragmente werden den Stationen zugeordnet

  - mit Replikation (redundanzfrei)
  - ohne Replikation

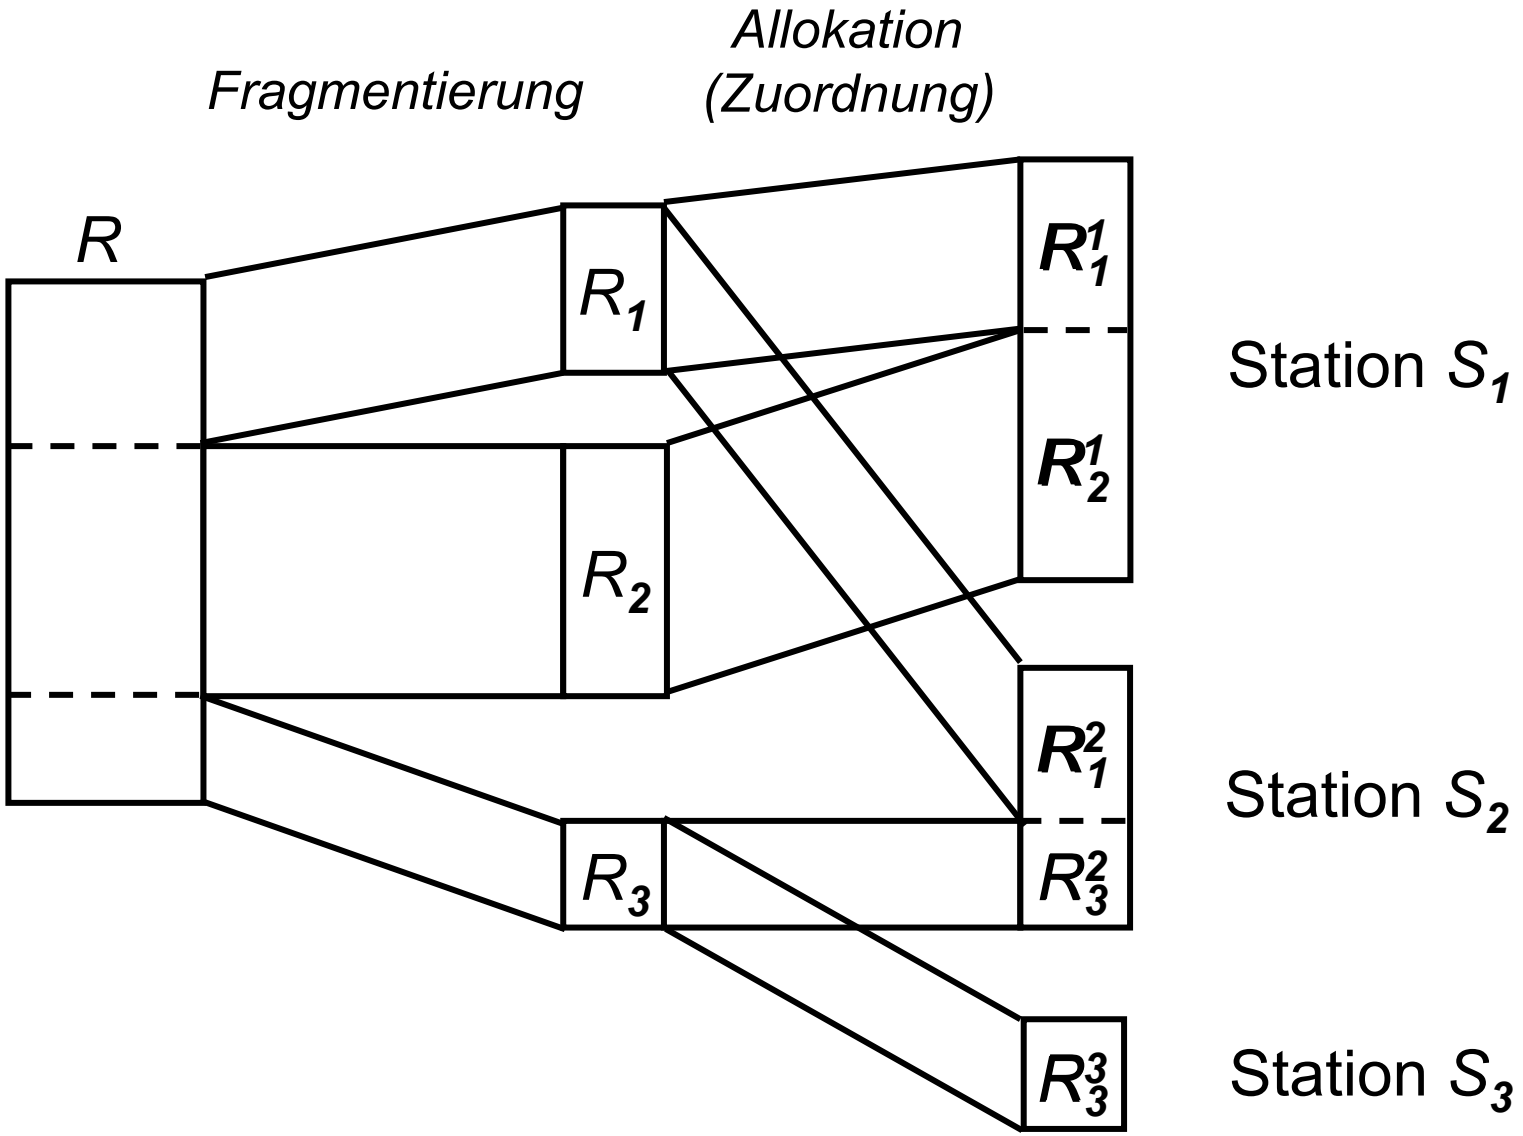
Fragmentierung
Allokation
(Zuordnung)
R
R1
R2
R3
R11
R21
R12
R32
R33
Station S1
Station S2
Station S3

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

Korrektheits-Anforderungen

- Rekonstruierbarkeit
- Vollständigkeit
- Disjunktheit

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

Horizontale Fragmentierung

abstrakte Darstellung: R

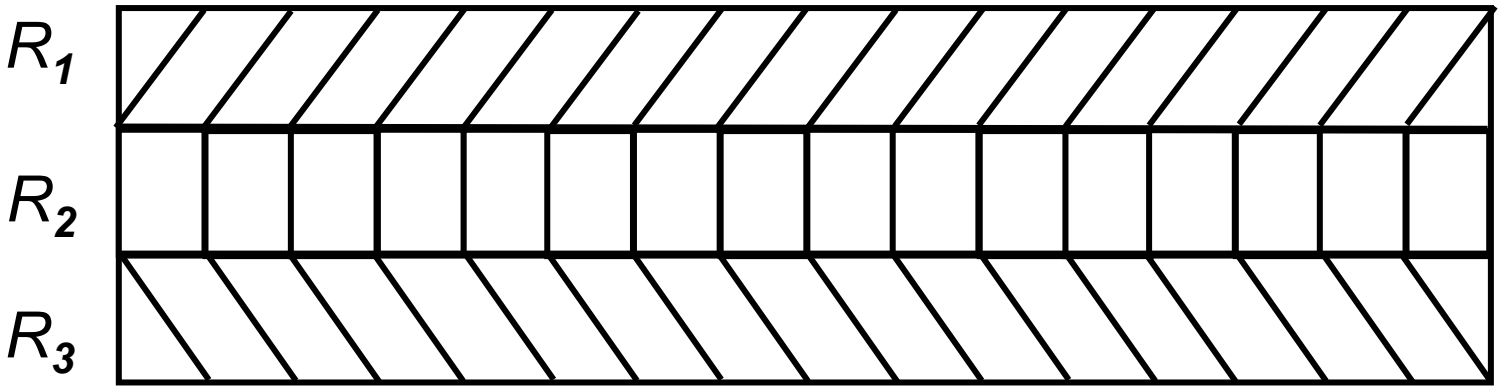

Für 2 Prädikate p_1 und p_2 ergeben sich 4 Zerlegungen:

$$R1 := \sigma_{p_1 \wedge p_2}(R)$$
$$R2 := \sigma_{p_1 \wedge \neg p_2}(R)$$
$$R3 := \sigma_{\neg p_1 \wedge p_2}(R)$$
$$R4 := \sigma_{\neg p_1 \wedge \neg p_2}(R)$$

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

sinnvolle Gruppierung der Professoren nach Fakultätszugehörigkeit:

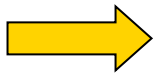 3 Zerlegungsprädikate:

$p_1 \equiv$ Fakultät = ‚Theologie'

$p_2 \equiv$ Fakultät = ‚Physik'

$p_3 \equiv$ Fakultät = ‚Philosophie'

$$\text{TheolProfs}' := \sigma_{p1 \wedge \neg p2 \wedge \neg p3}(\text{Professoren}) = \sigma_{p1}(\text{Professoren})$$

$$\text{PhysikProfs}' := \sigma_{\neg p1 \wedge p2 \wedge \neg p3}(\text{Professoren}) = \sigma_{p2}(\text{Professoren})$$

$$\text{PhiloProfs}' := \sigma_{\neg p1 \wedge \neg p2 \wedge p3}(\text{Professoren}) = \sigma_{p3}(\text{Professoren})$$

$$\text{AndereProfs}' := \sigma_{\neg p1 \wedge \neg p2 \wedge \neg p3}(\text{Professoren})$$

Abgeleitete horizontale Fragmentierung

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

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

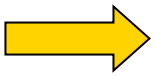

für Anfragebearbeitung schlechte Zerlegung

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

resultiert in:

$\Pi_{\textbf{Titel, Name}}((\text{TheolProfs}' \bowtie \text{2SWSVorls}) \cup$
$(\text{TheolProfs}' \bowtie \text{3SWSVorls}) \cup$
$\ldots \cup (\text{PhiloProfs}' \bowtie \text{4SWSVorls}))$

Join-Graph zu diesem Problem:

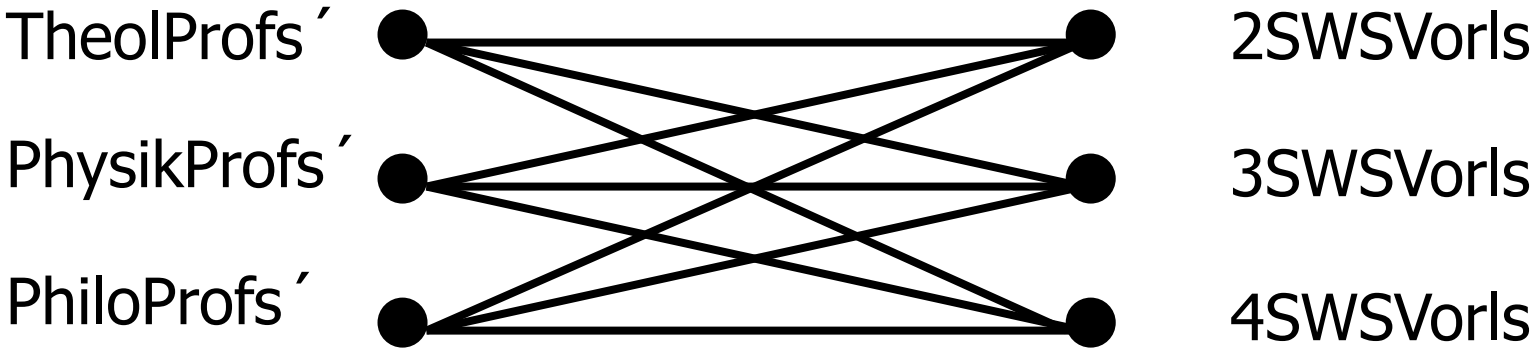

Andere Join-Arten

- natürlicher Join

L		
A	B	C
a_1	b_1	c_1
a_2	b_2	c_2

$\bowtie$

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

Semi-Joins

- Semi-Join von R mit L

L		
A	B	C
a_1	b_1	c_1
a_2	b_2	c_2

$\rtimes$

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

$\ltimes$

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

Lösung: abgeleitete Fragmentierung

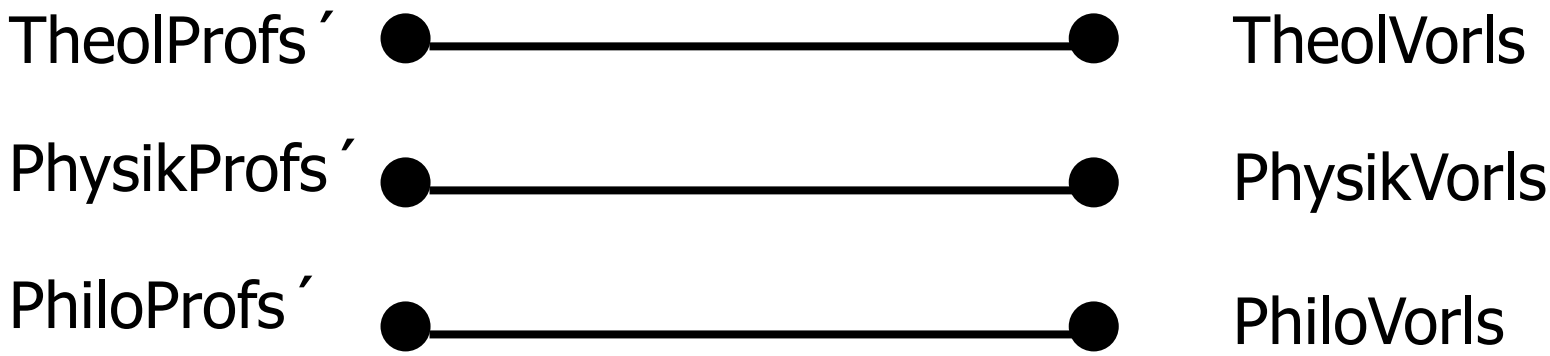

$$\text{TheolVorls} := \text{Vorlesungen} \ltimes_{\textbf{gelesenVon=PersNr}} \text{TheolProfs}'$$

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

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

$$\Pi_{\textbf{Titel, Name}}((\text{TheolProfs}' \bowtie_{p} \text{TheolVorls}) \cup (\text{PhysikProfs}' \bowtie_{p} \text{PhysikVorls}) \cup (\text{PhiloProfs}' \bowtie_{p} \text{PhiloVorls}))$$

mit $p \equiv (\text{PersNr} = \text{gelesenVon})$

Vertikale Fragmentierung

abstrakte Darstellung:

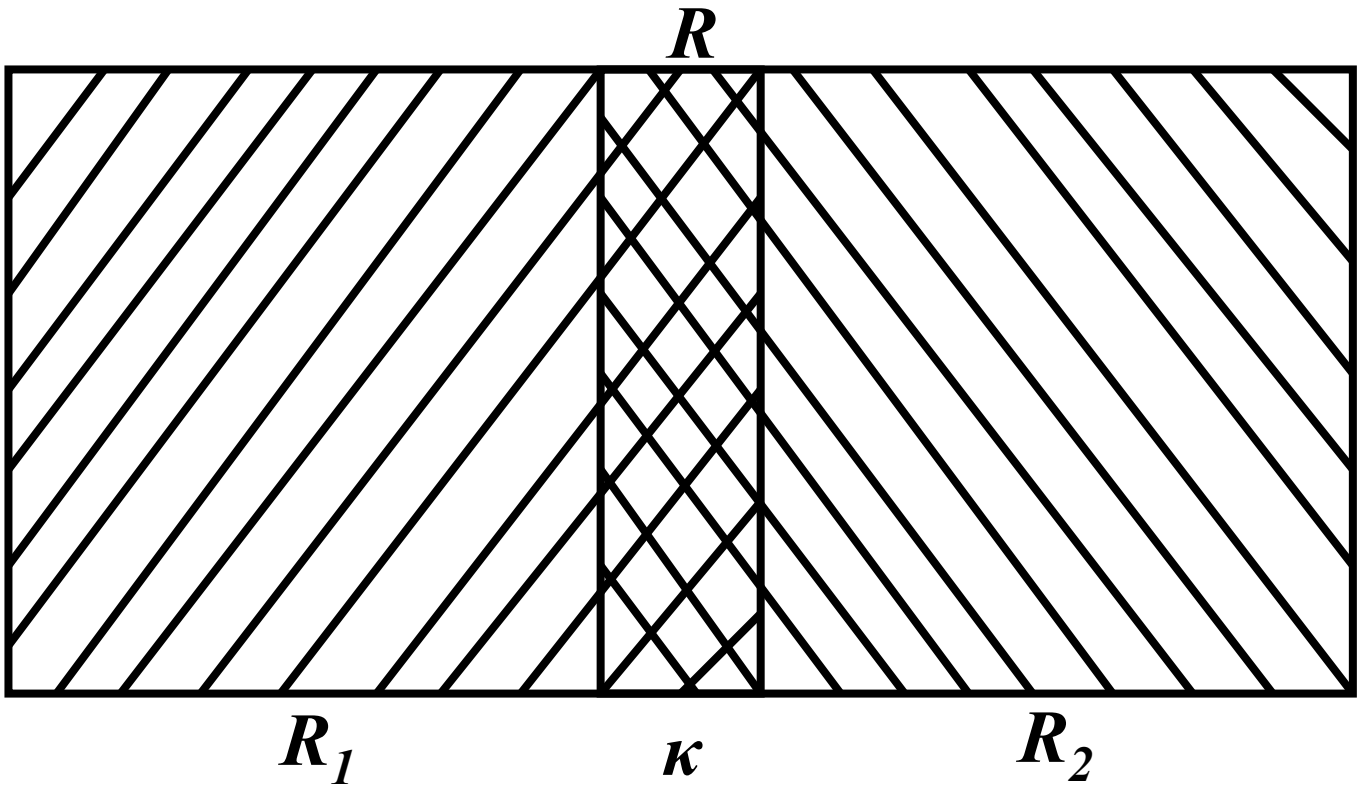

Vertikale Fragmentierung

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

Vertikale Fragmentierung (Beispiel)

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

ProfVerw := Π **PersNr, Name, Gehalt, Steuerklasse** (Professoren)

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

Profs := Π **PersNr, Name, Rang, Raum, Fakultät** (Professoren)

Rekonstruktion der Originalrelation *Professoren*:

Professoren = ProfVerw $\bowtie$**ProfVerw.PersNr = Profs.PersNr** Profs

Kombinierte Fragmentierung

a) horizontale Fragmentierung nach vertikaler Fragmentierung

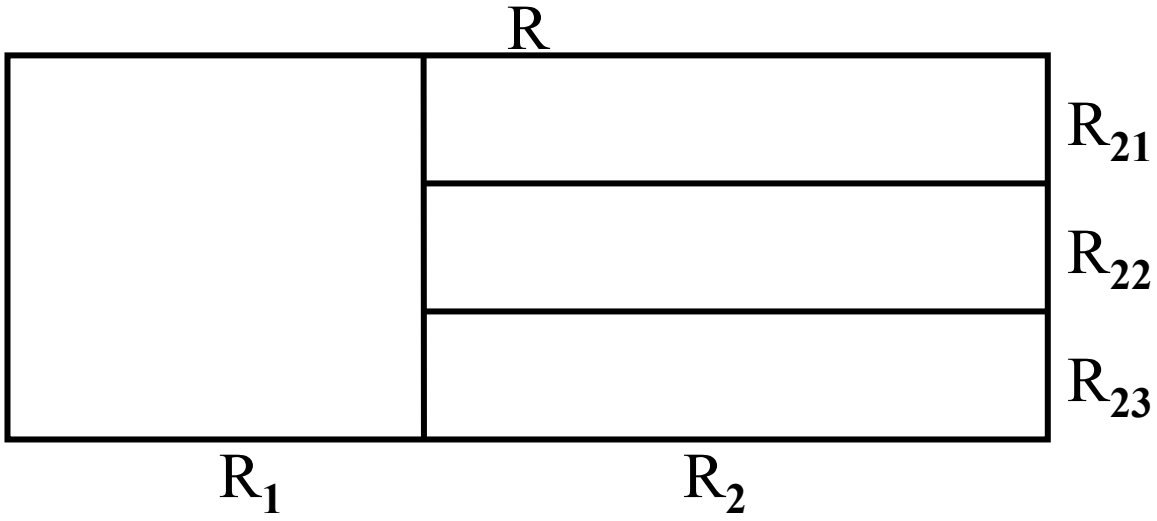

b) vertikale Fragmentierung nach horizontaler Fragmentierung

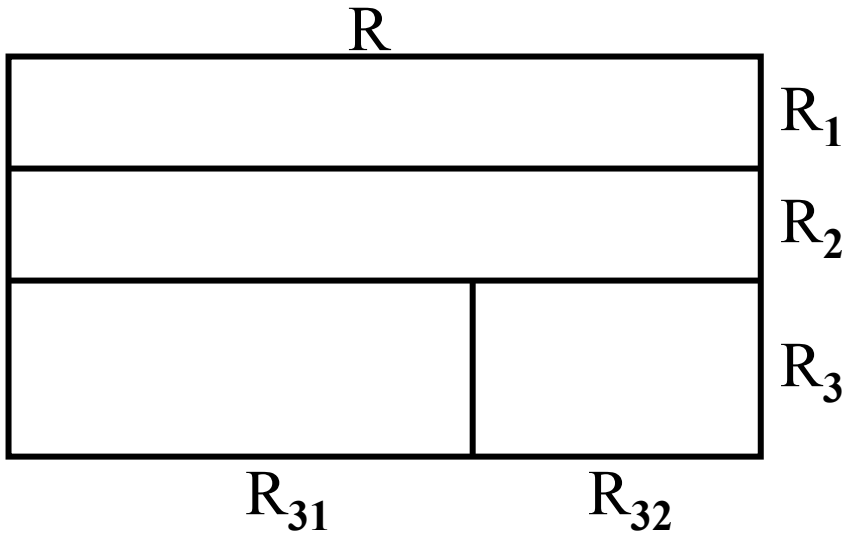

Rekonstruktion nach kombinierter Fragmentierung

Fall a)

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

Fall b)

$$R = R_1 \cup R_2 \cup (R_{31} \ltimes_{R_{31}.\kappa = R_{32}.\kappa} R_{32})$$

Baumdarstellung der Fragmentierungen (Beispiel)

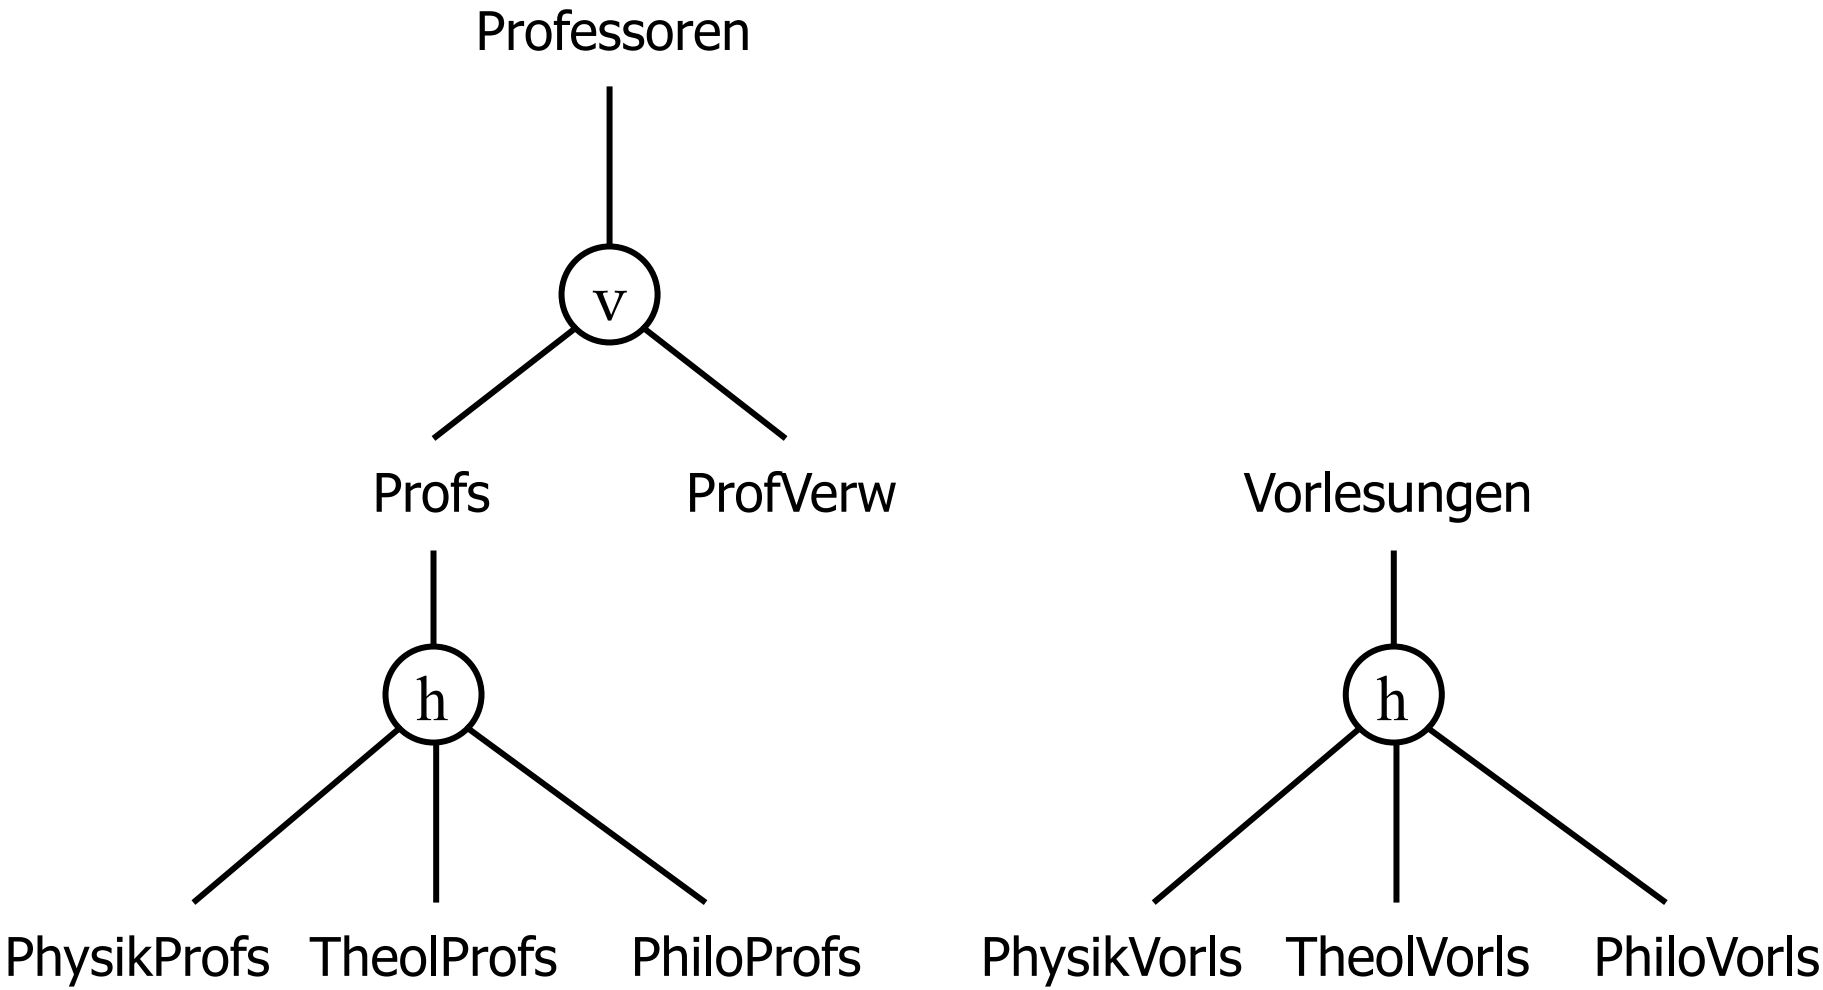

Allokation

- 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‘;

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‘;
```

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‘;

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).

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:

- 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.
- 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:

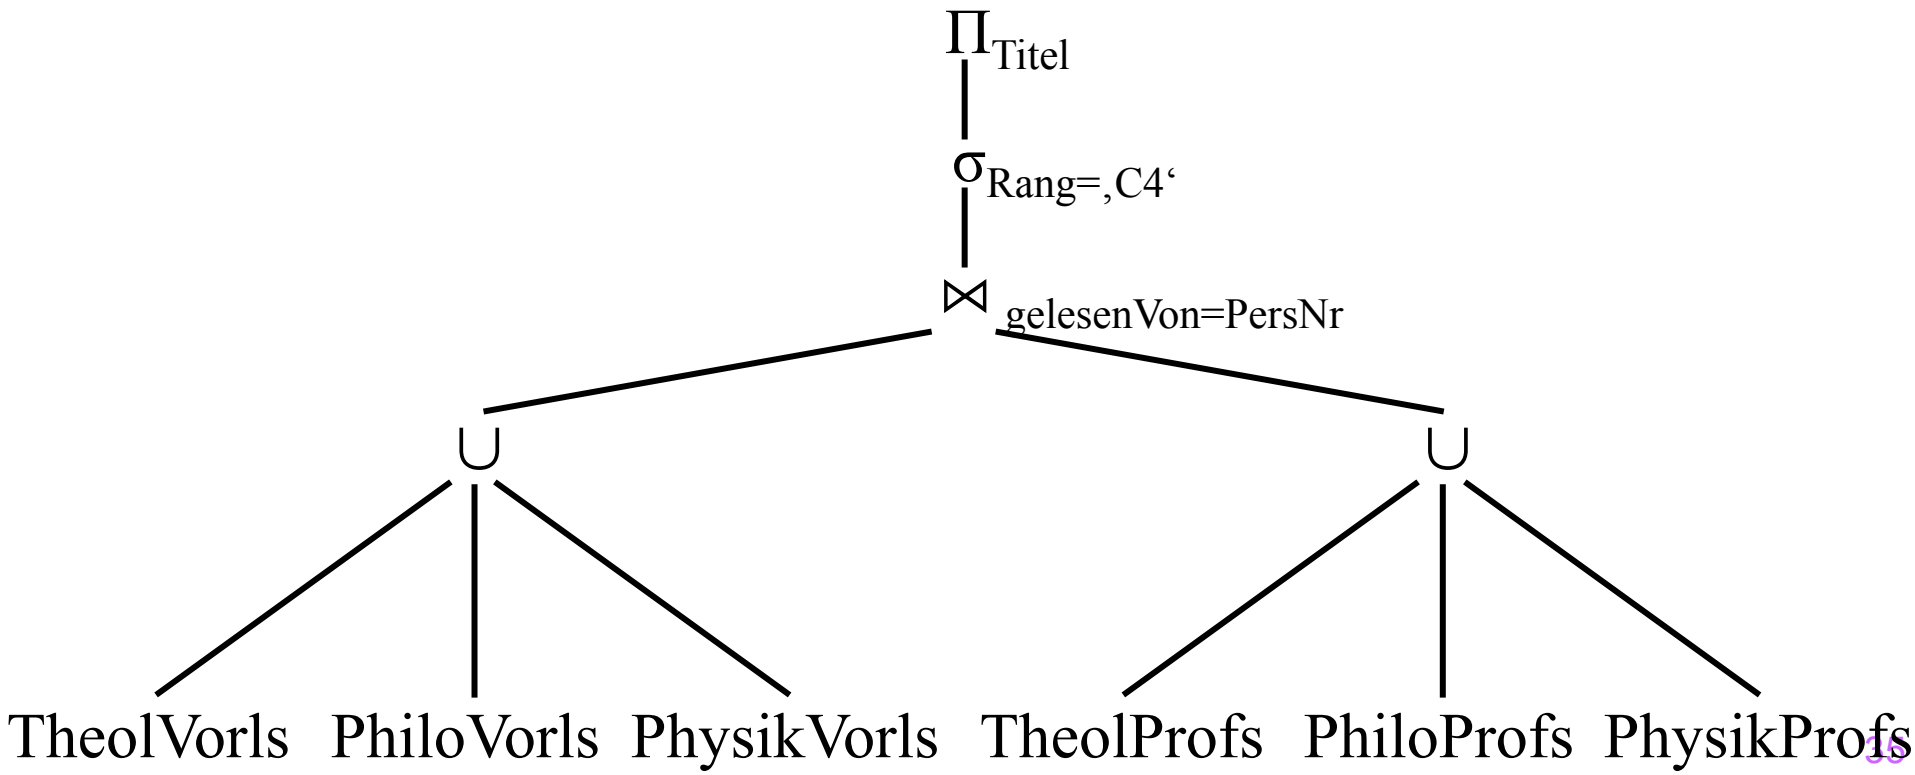

Algebraische Äquivalenzen

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 $S = S_i \cup \ldots \cup S_n$
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:

$$(R_1 \cup \ldots \cup R_n) \bowtie_p (S_1 \cup \ldots \cup S_m) =$$
$$(R_1 \bowtie_p S_1) \cup (R_2 \bowtie_p S_2) \cup \ldots \cup (R_n \bowtie_p S_n)$$

Algebraische Äquivalenzen (Forts.)

Für eine derartig abgeleitete horizontale Fragmentierung von S gilt somit:

$$(R_1 \cup \ldots \cup R_n) \bowtie_p (S_1 \cup \ldots \cup S_m) =$$
$$(R_1 \bowtie_p S_1) \cup (R_2 \bowtie_p S_2) \cup \ldots \cup (R_n \bowtie_p S_n)$$

Für unser Beispiel gilt nun folgendes:

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

⟹ Um Selektionen und Projektionen über den Vereinigungsoperator 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:

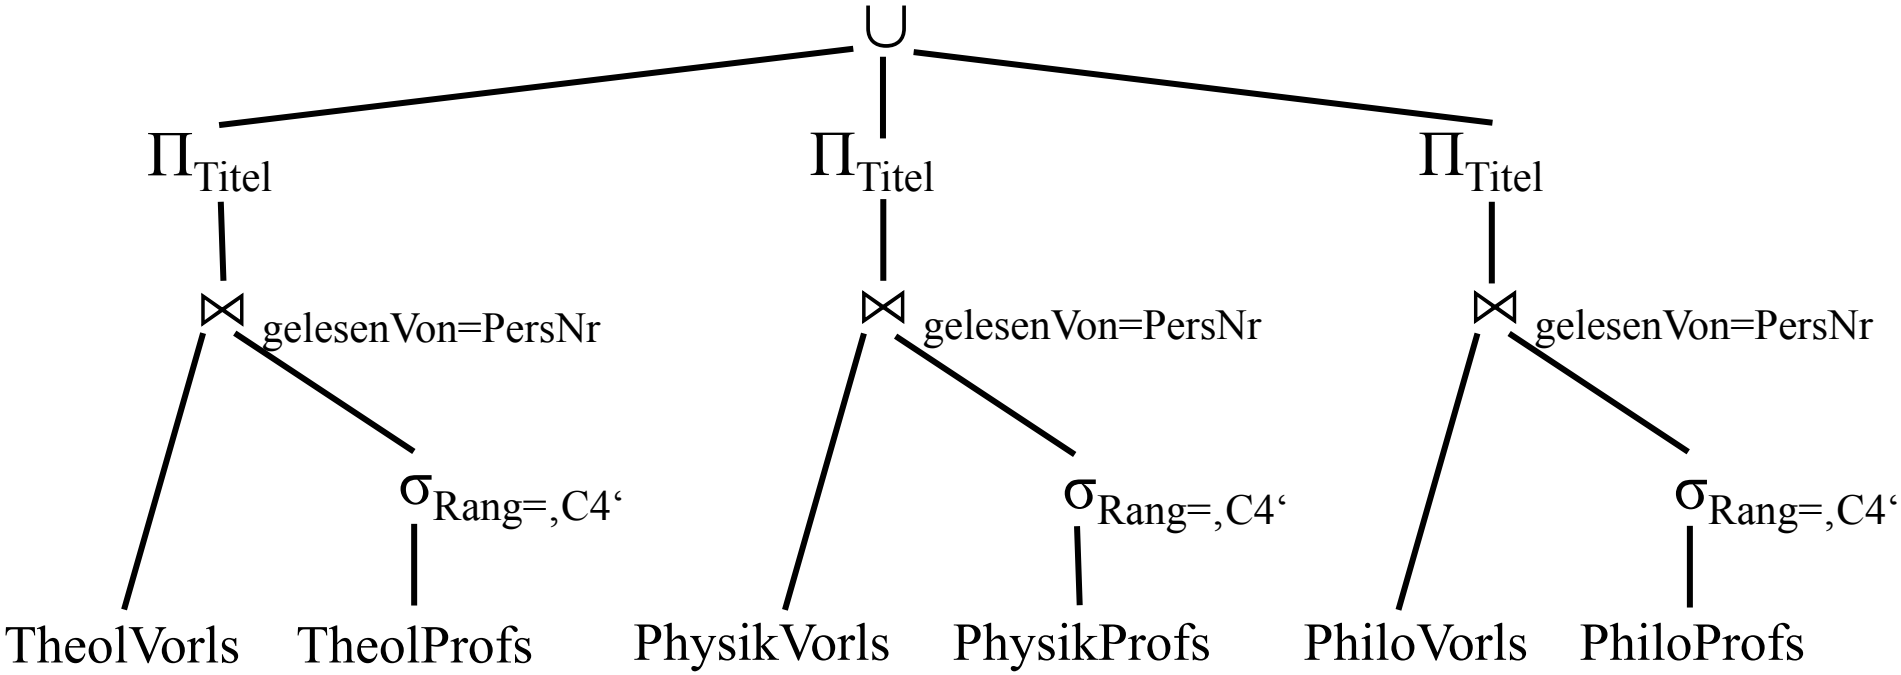

Auswertungen können lokal auf den Stationen S_{Theol}, S_{Physik} und S_{Philo} ausgeführt werden ⇒ Stationen können parallel abarbeiten und lokales Ergebnis voneinander unabhängig an die Station, die die abschliessende Vereinigung durchführt, übermitteln.

Anfragebearbeitung bei vertikaler Fragmentierung

Beispiel:

select Name, Gehalt
from Professoren
where Gehalt > 80000;

kanonischer Auswertungsplan:

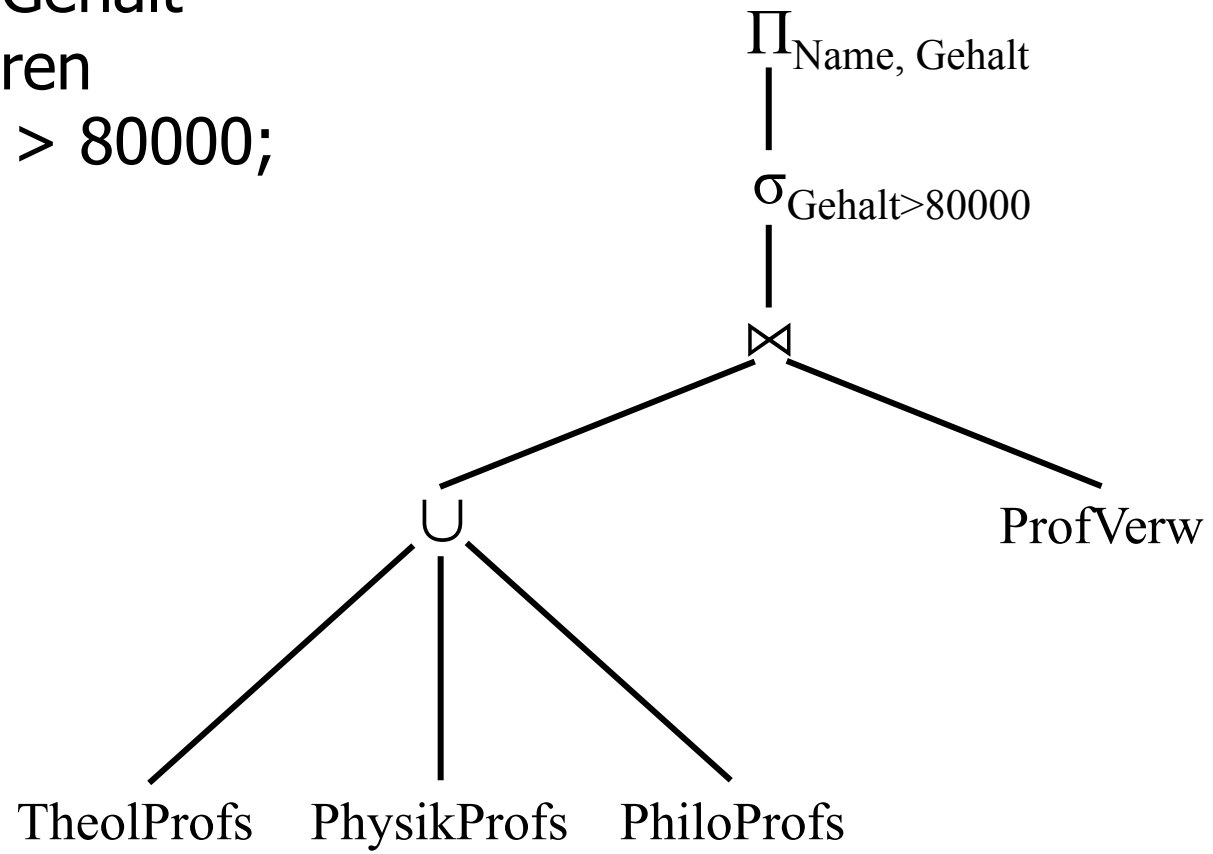

Optimierung bei vertikaler Fragmentierung

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:

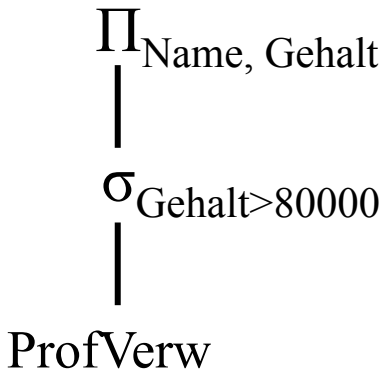

Beispiel für eine schlecht zu optimierende Anfrage:
(Attribut *Rang* fehlt in *ProfVerw*)

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

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

$\bowtie$

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 ⋈ 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

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

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

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 zu jedem Tupel r passenden Tupel $s \in S$ 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)

$\Rightarrow$ es werden $\mathbf{2 * |R|}$ 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

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)

Join-Auswertung mit Filterung

- Verwendung des Semi-Join-Operators zur Filterung
- Schlüsselidee: nur Transfer von Tupel, die passenden Join-Partner haben
- Benutzung der folgenden algebraischen Eigenschaften:

$$R \bowtie S = R \bowtie (R \rtimes S)$$

$$R \rtimes S = \Pi_{\mathbf{c}}(R) \rtimes S$$

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 $R \bowtie S = \Pi_C(R) \rtimes S$ 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:

$$\| \Pi_C(R) \| + \| R \rtimes S \| < \| S \|$$

mit $\| P \|$ = Größe (in Byte) einer Relation

Auswertung des Joins $R \rtimes S$ mit Semi-Join-Filterung von S

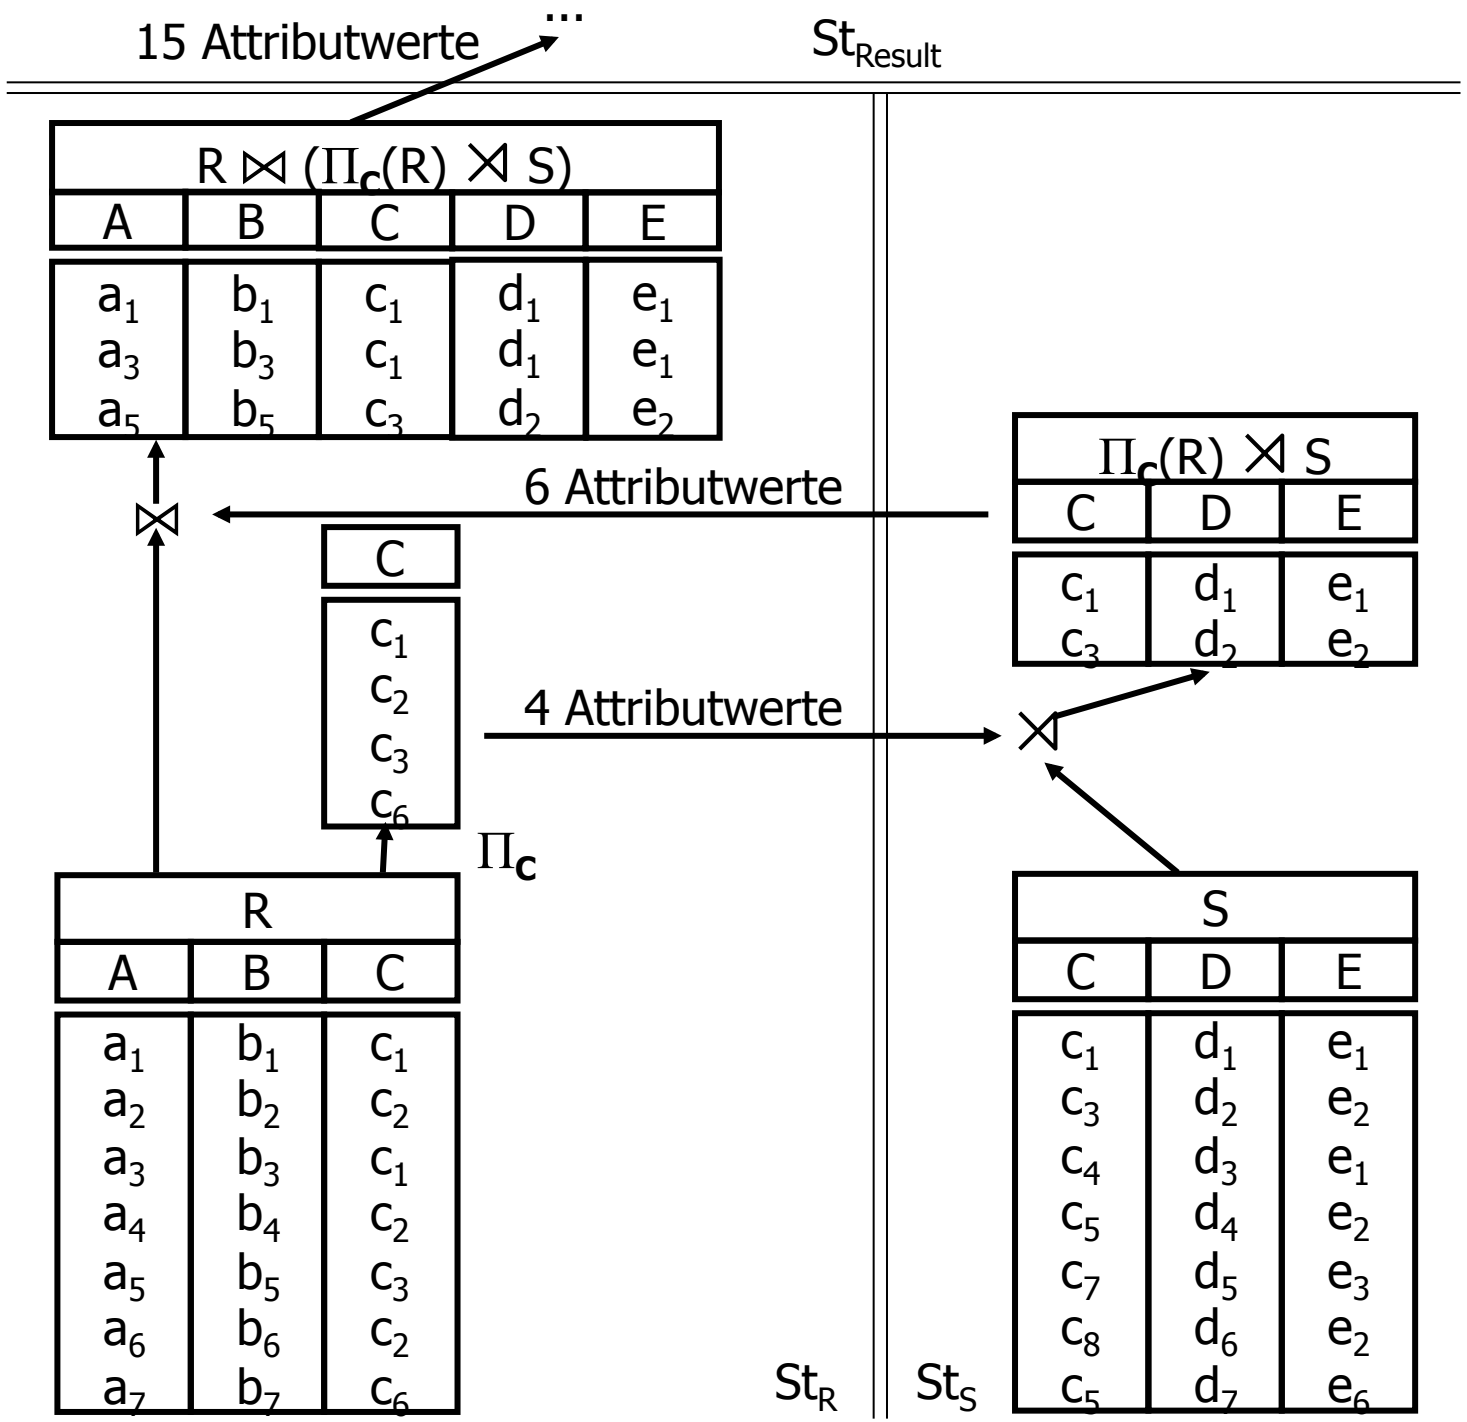

Alternative Auswertungungspläne

1. Alternative:

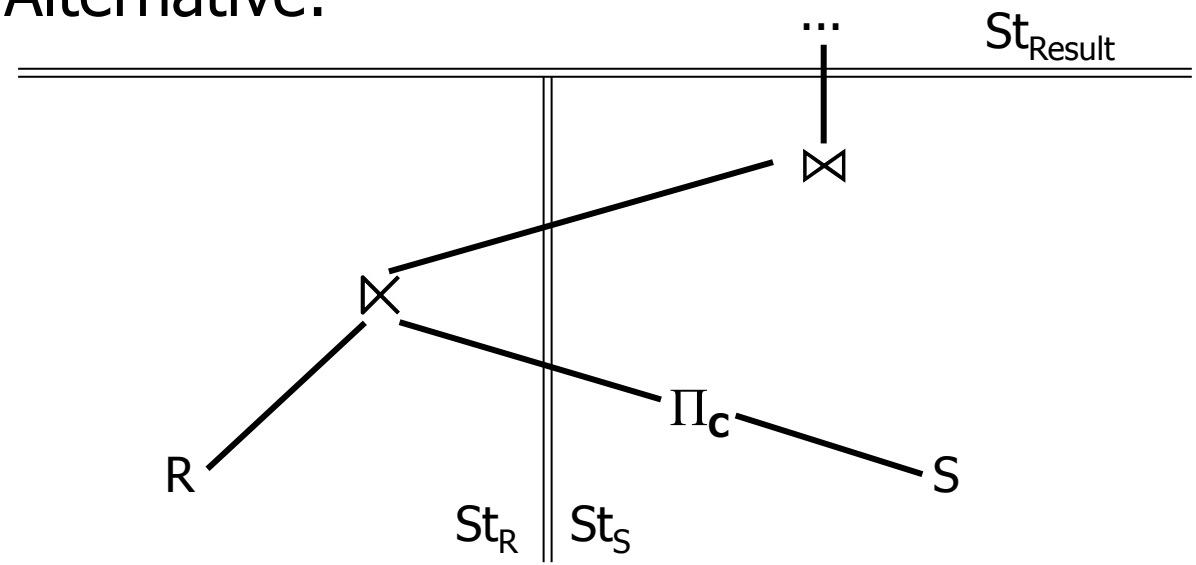

2. Alternative:

$(R \ltimes \Pi_c(S)) \bowtie (\Pi_c(R) \rtimes S)$

Join mit Hashfilter (Bloom-Filter)

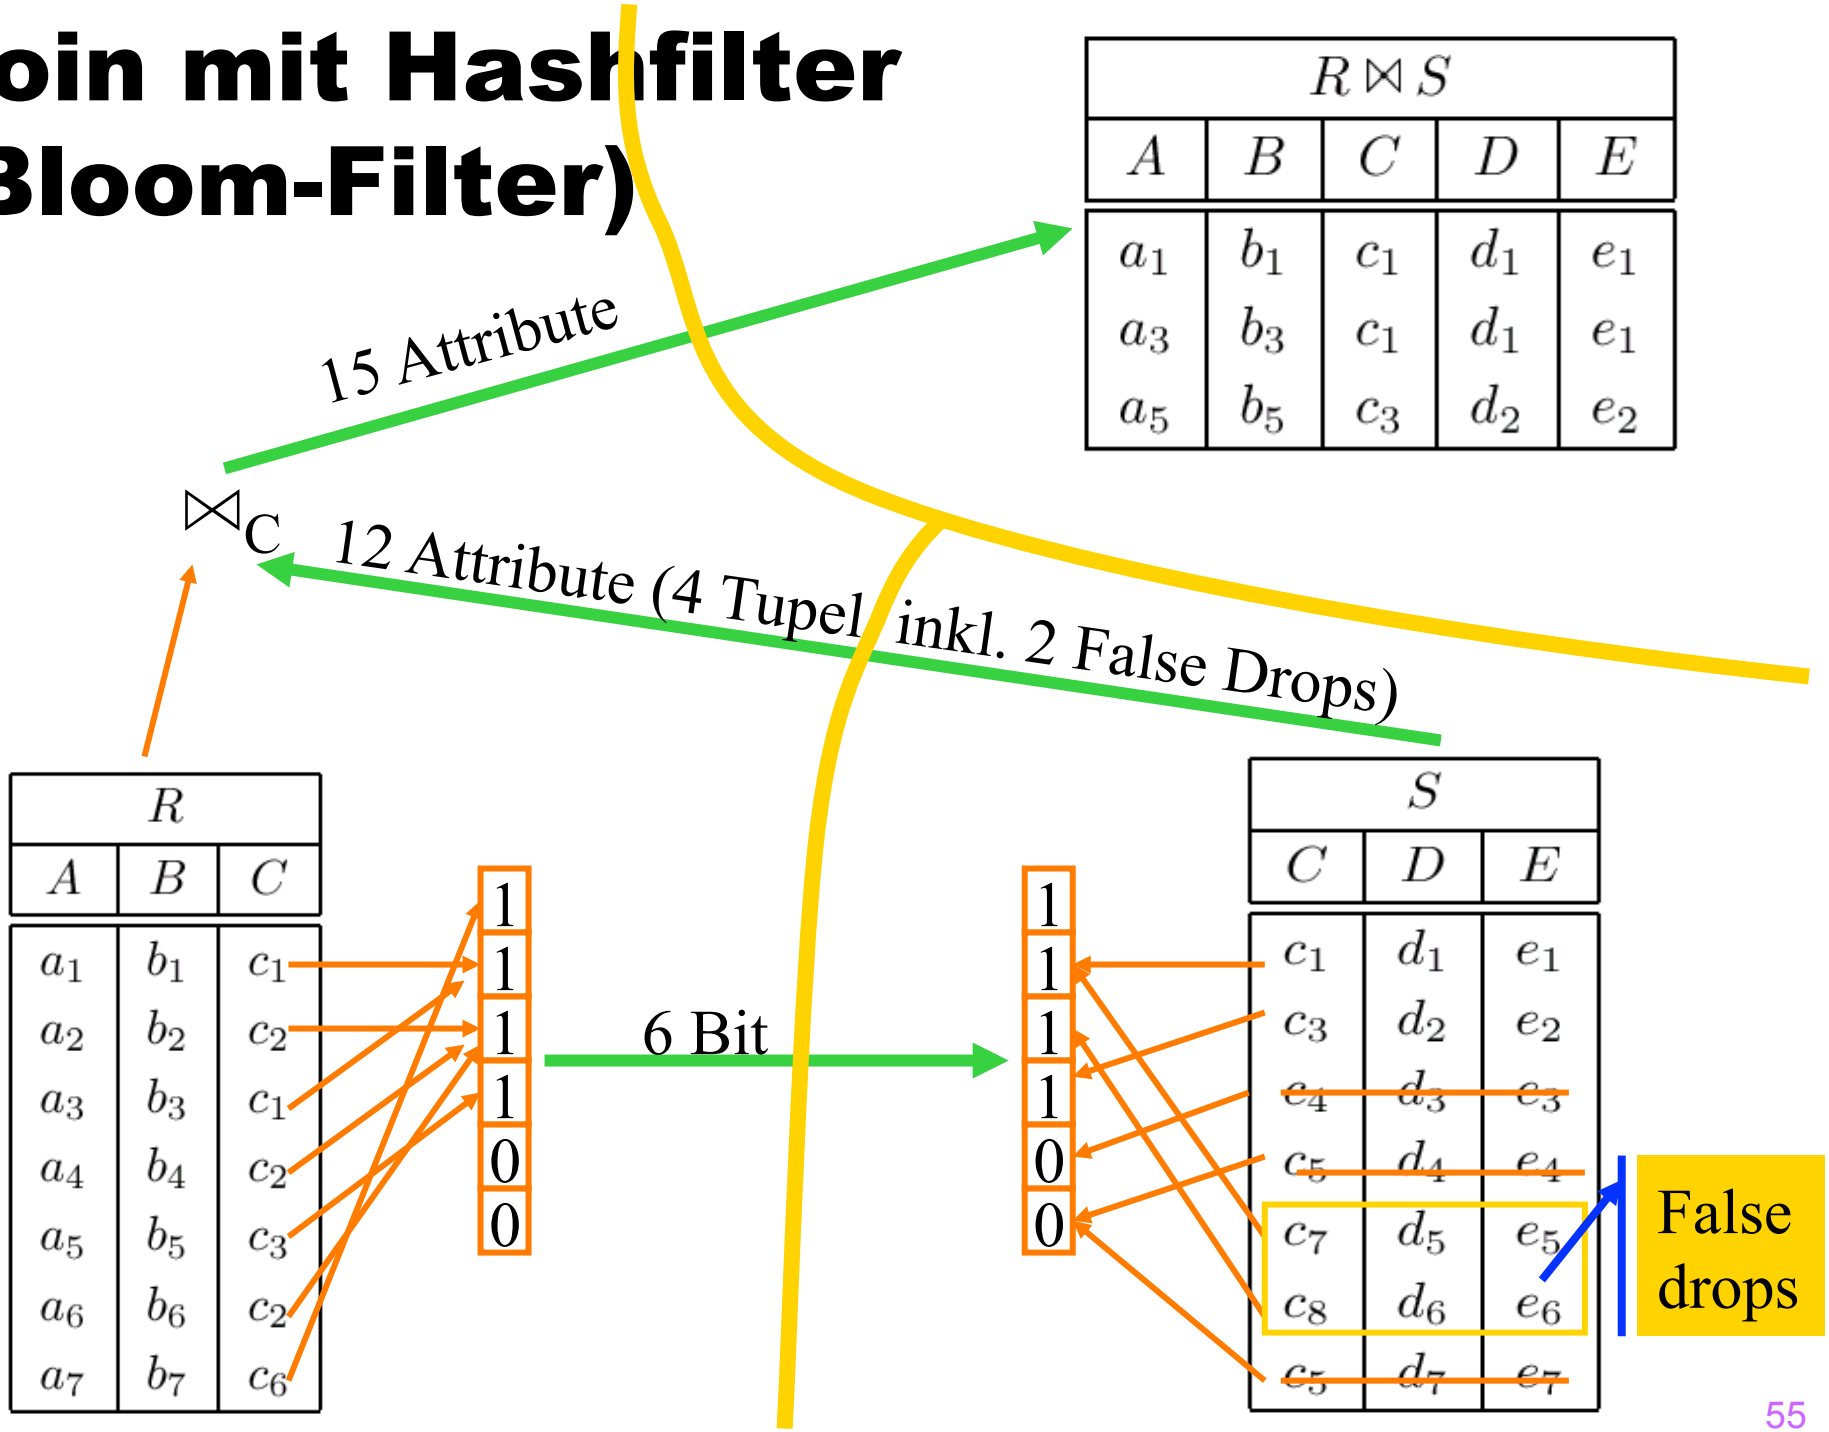

$R \bowtie S$

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

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

1 1 1 1 0 0

1 1 1 1 0 0

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~~

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: $1- (1-1/b)^{|R|}$

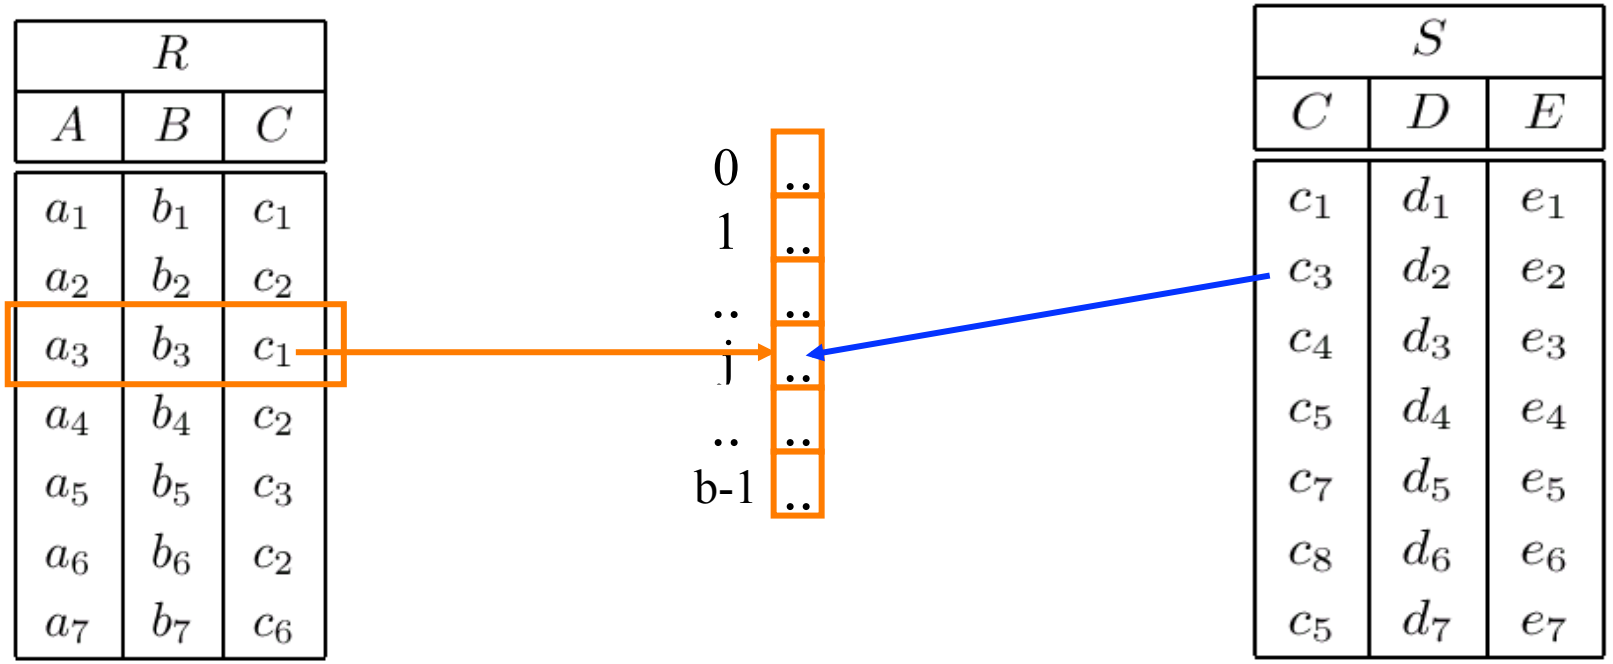

Join mit Hashfilter (False Drop Abschätzung)

- 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|

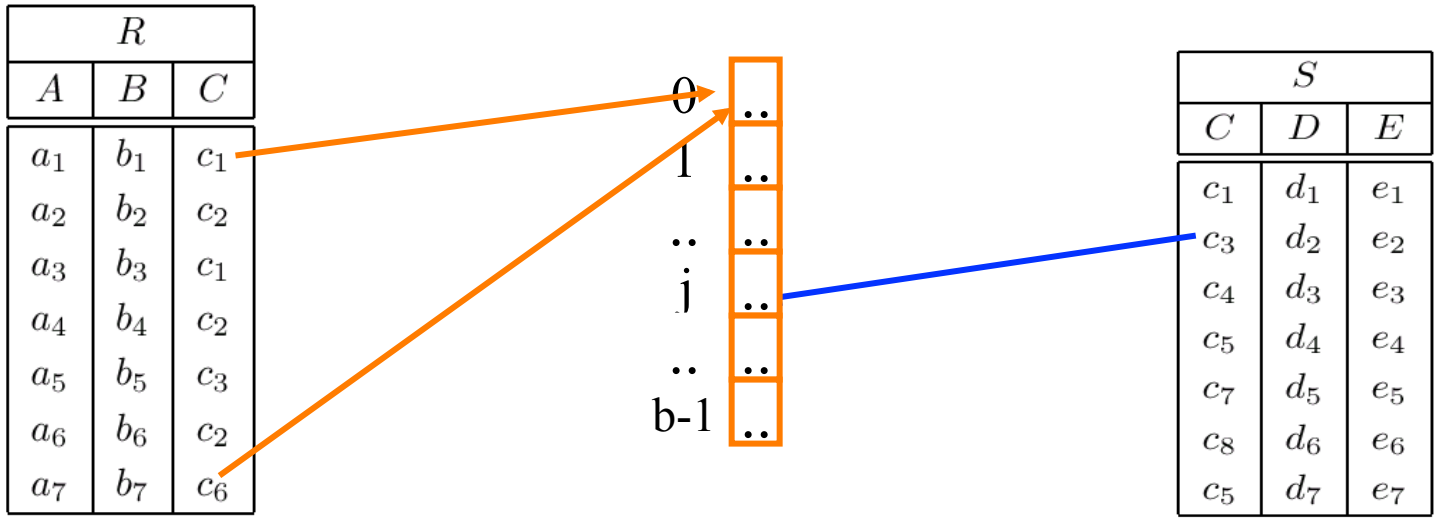

Join mit Hashfilter (False Drop Abschätzung)

- 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

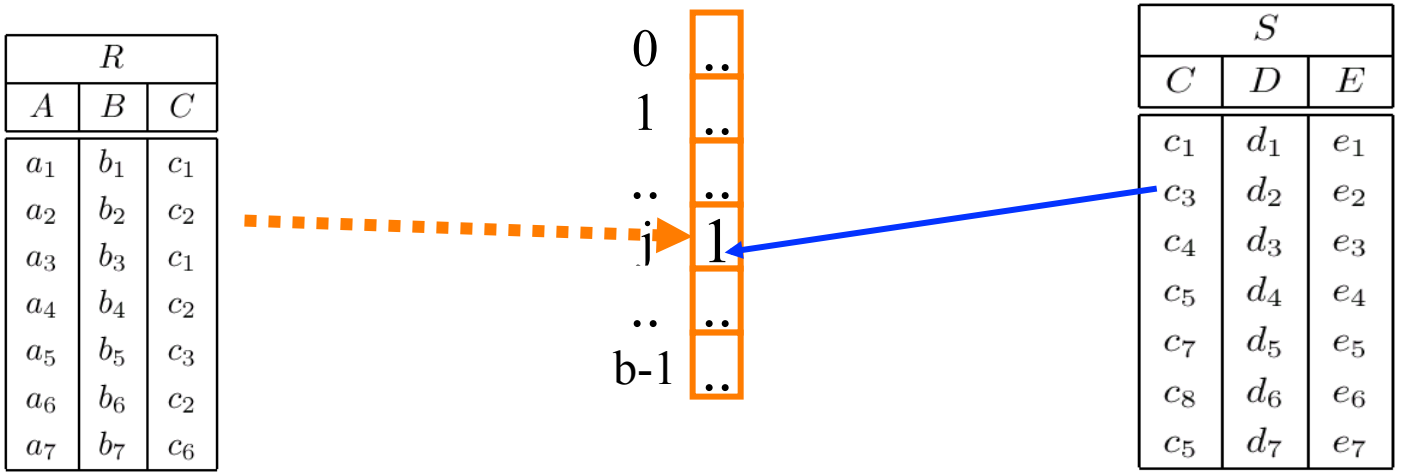

Parameter für die Kosten eines Auswertungsplan

- 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
- 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)

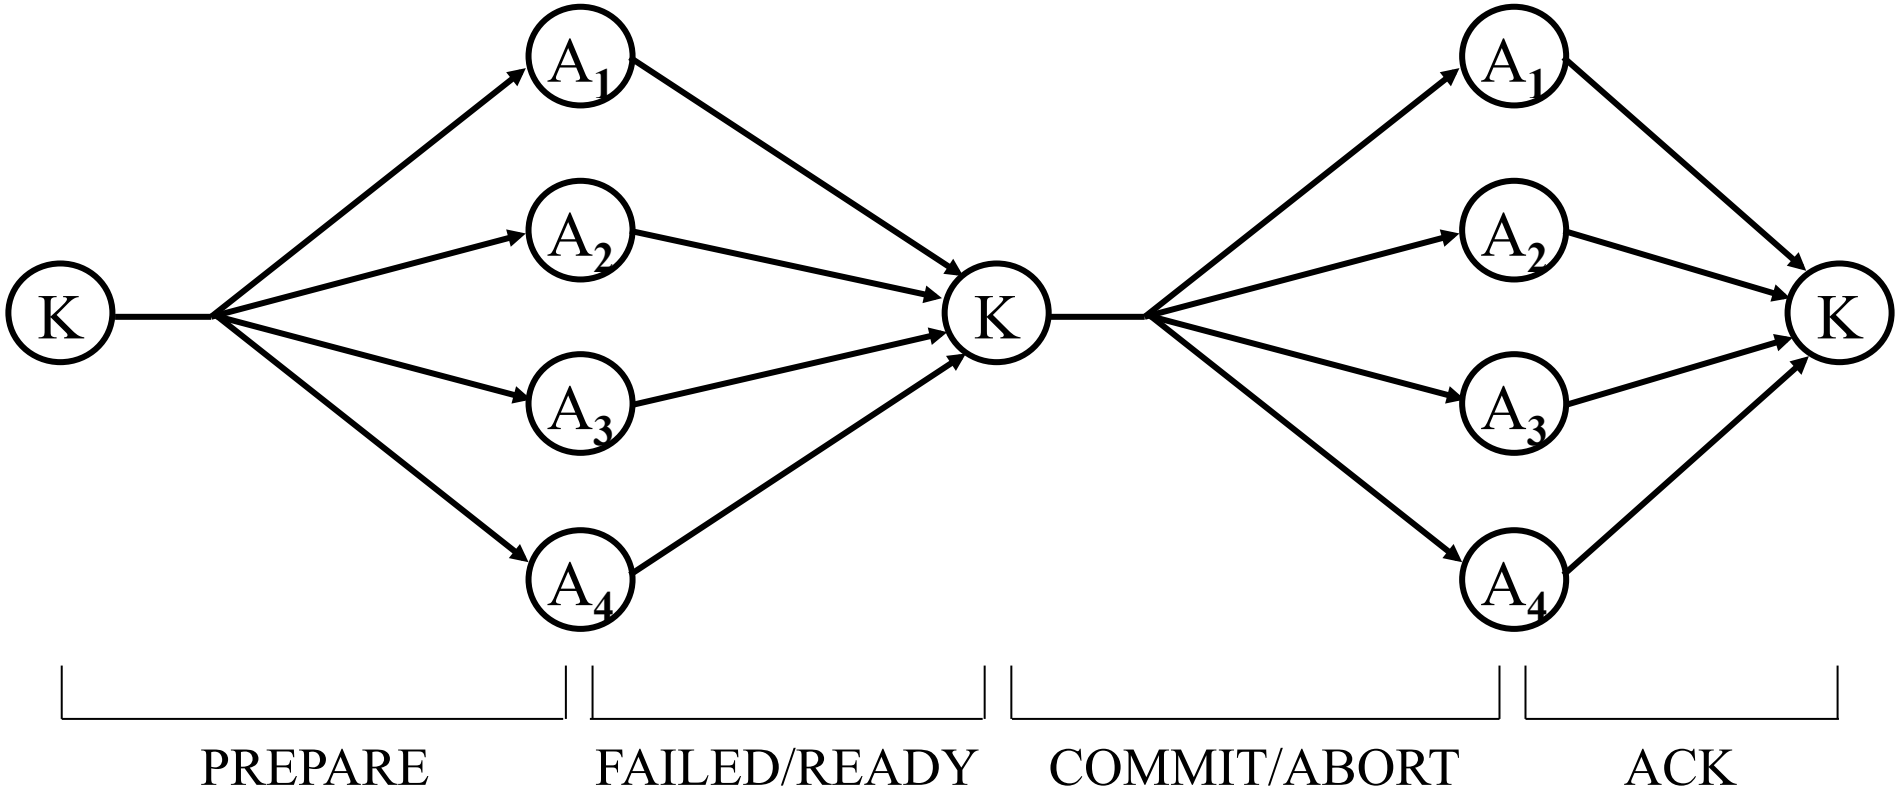

Ablauf der EOT-Behandlung beim 2PC-Protokoll

- *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 $A_1,\ldots,A_n$ 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

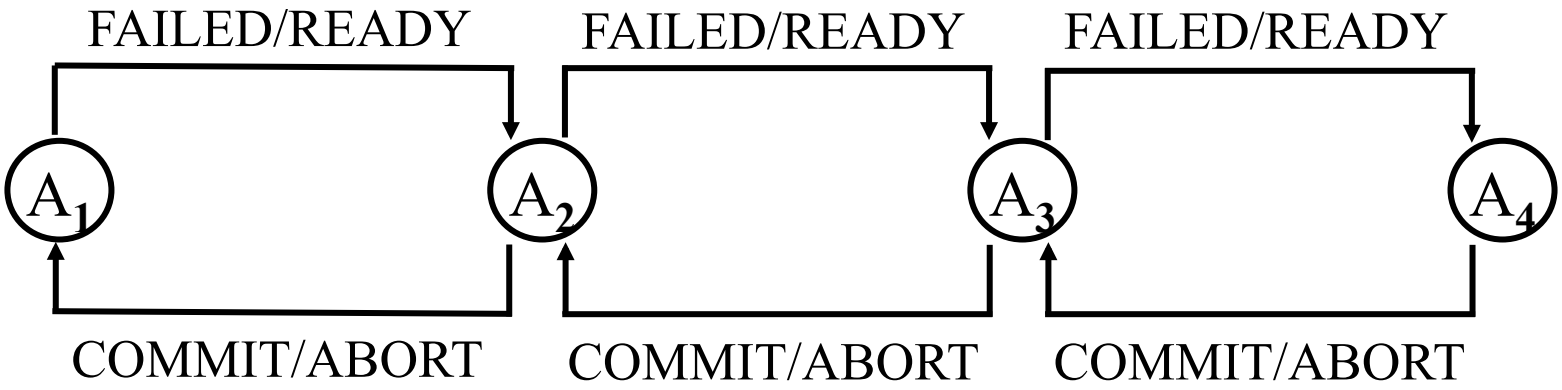

Zustandsübergang beim 2PC-Protokoll: Koordinator

„Bullet“ ●
= wichtigste Aktion(en)

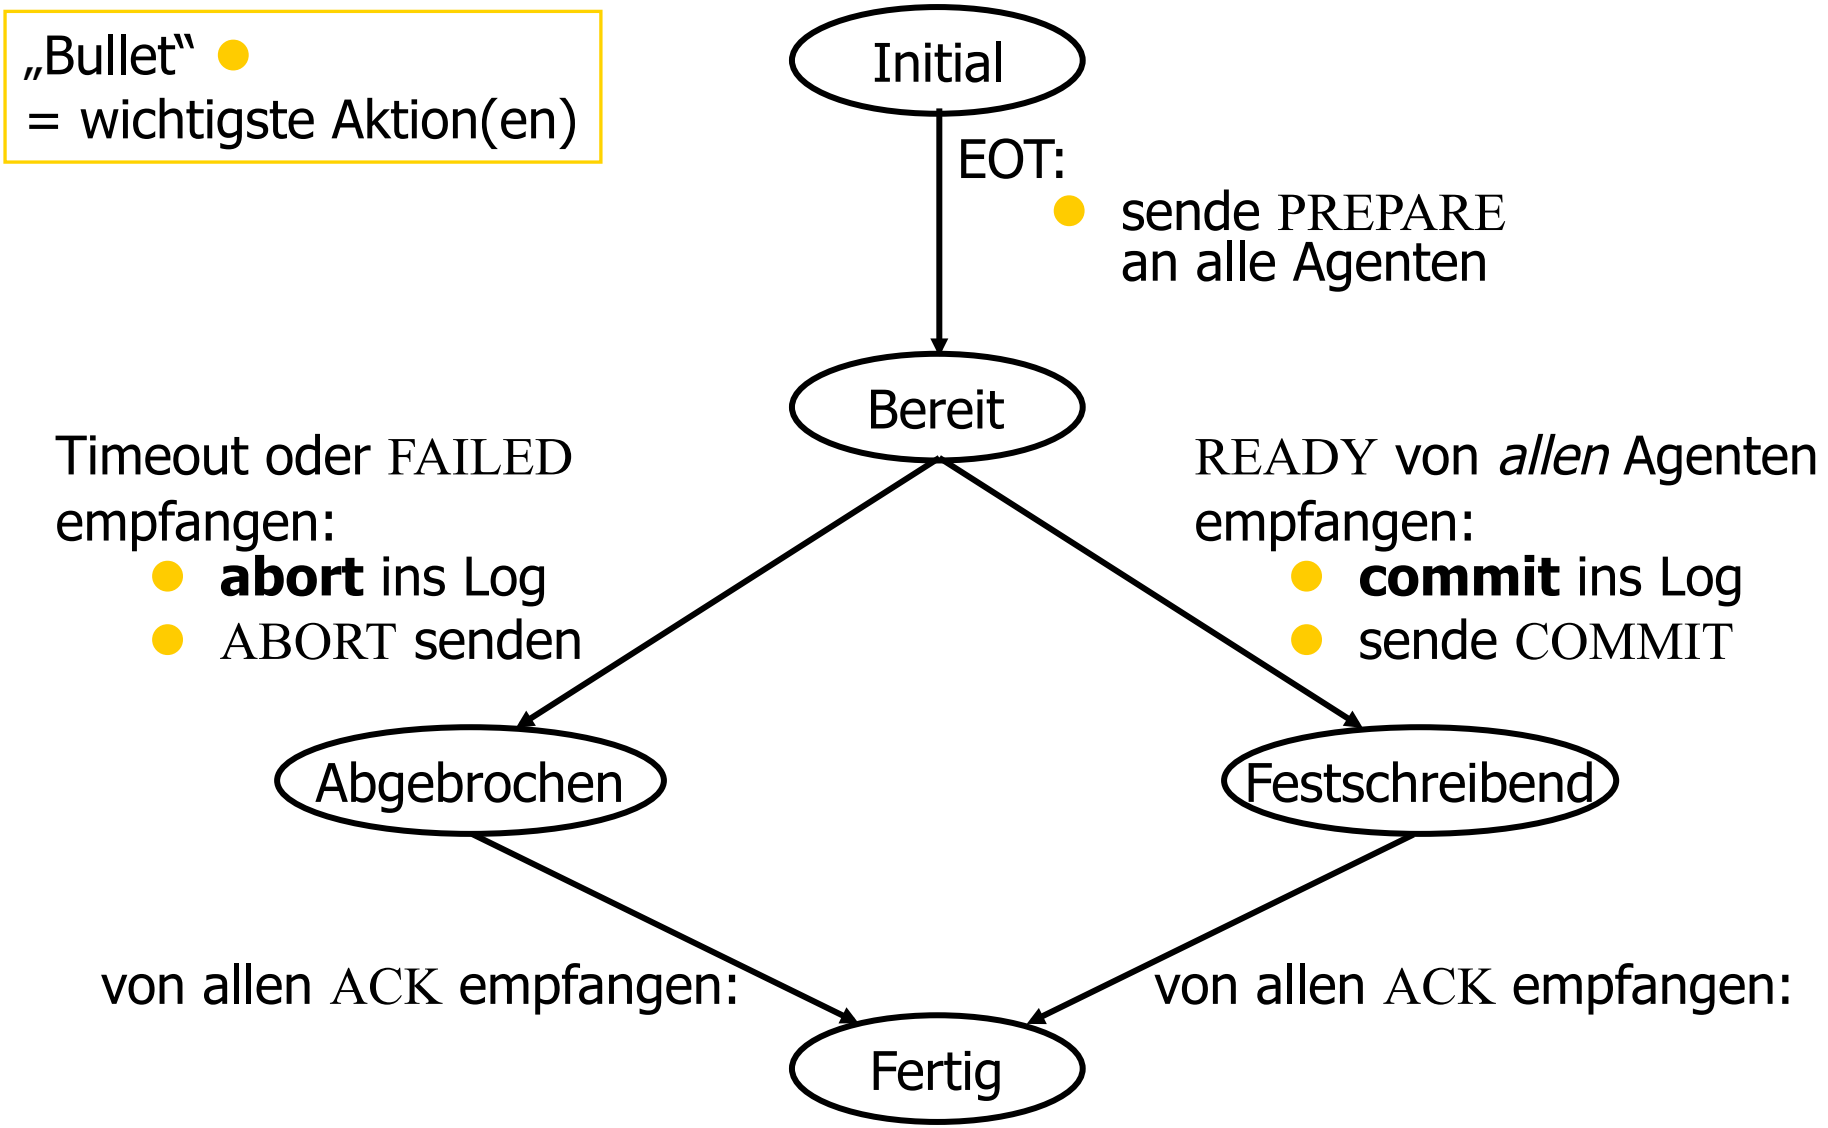

Zustandsübergang beim 2PC-Protokoll: Agent

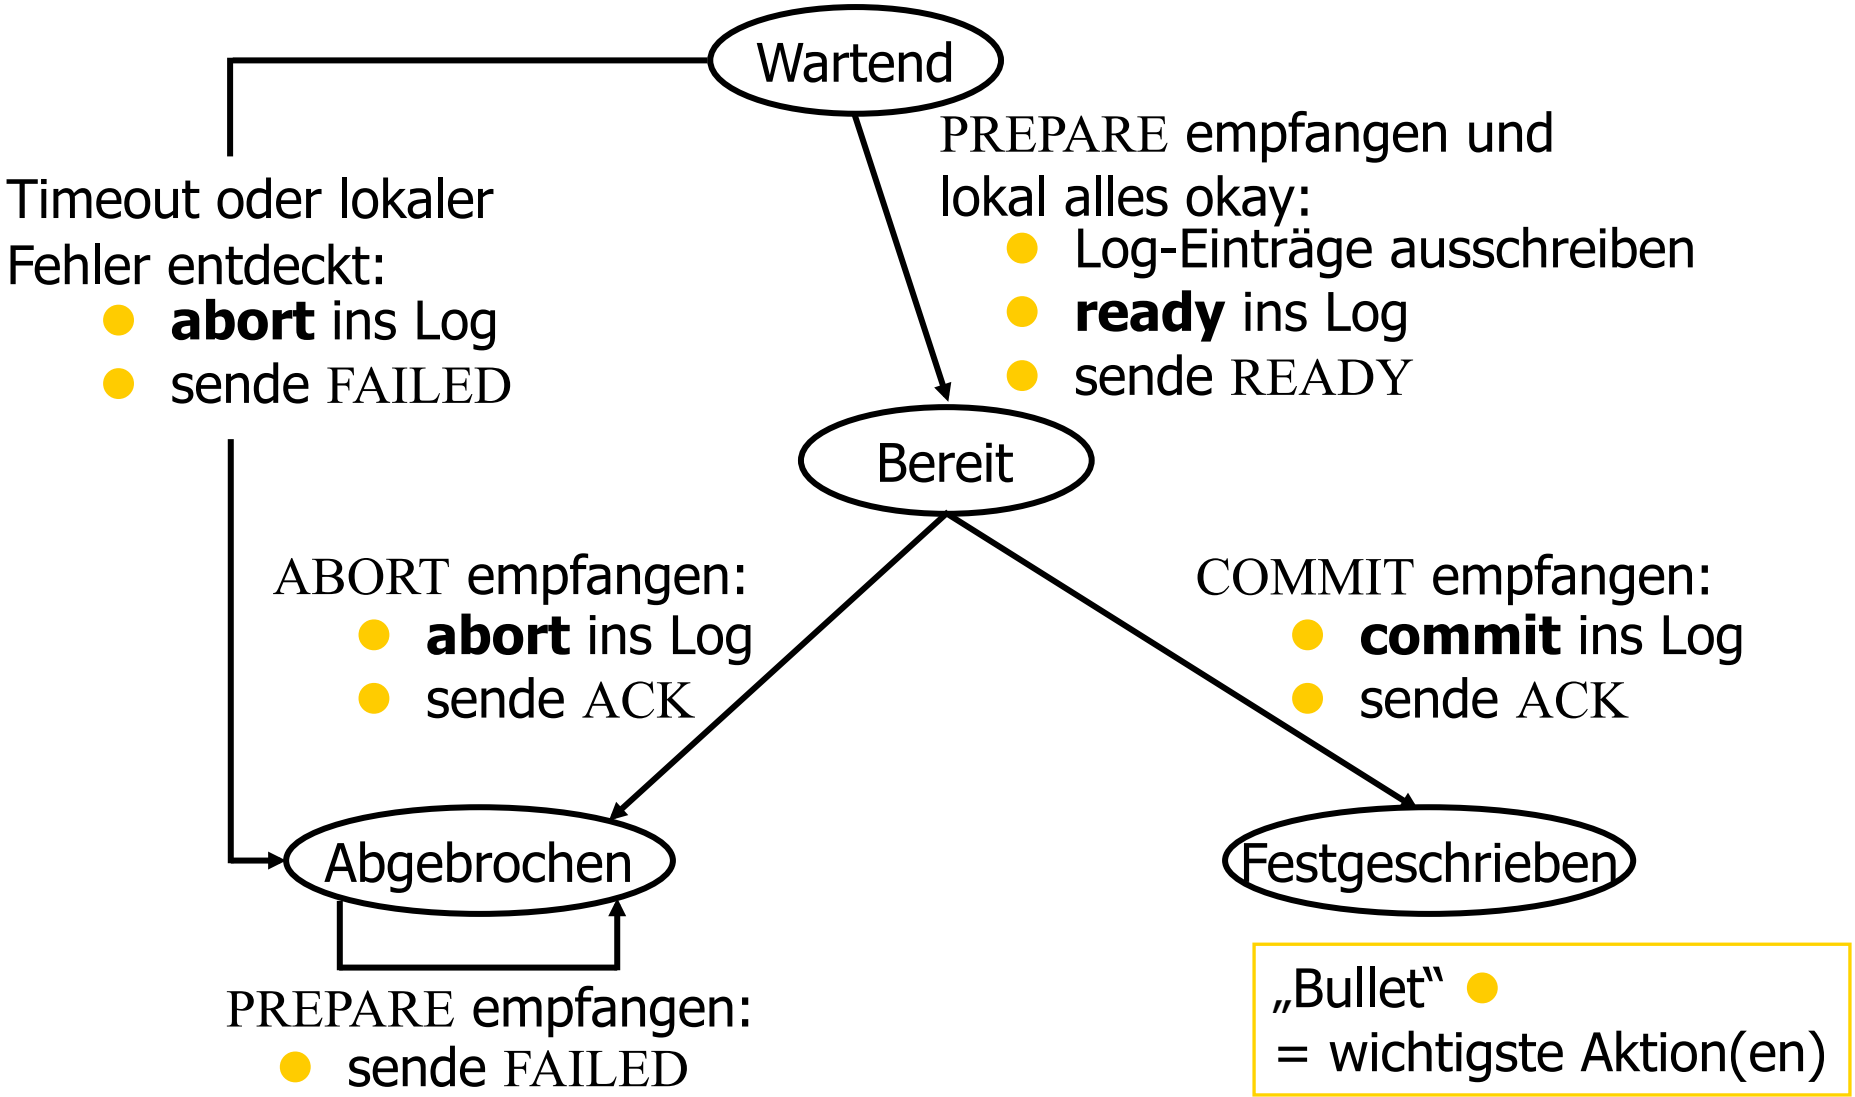

Fehlersituationen des 2PC-Protokolls

- Absturz eines Koordinators
- Absturz eines Agenten
- verlorengegangene Nachrichten

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).

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

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)

Mehrbenutzersynchronisation in VDBMS

- Serialisierbarkeit
- Zwei-Phasen-Sperrprotokoll in VDBMS
  - lokale Sperrverwaltung an jeder Station
  - globale Sperrverwaltung

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).

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**)

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

Voraussetzungen für Deadlockvermeidungsverfahren

- Vergabe global eindeutiger Zeitstempel als Transaktionsidentifikatoren

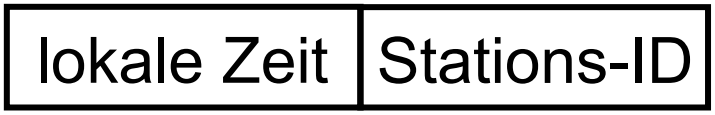

- lokale Uhren müssen hinreichend genau aufeinander abgestimmt sein

Synchronisation bei replizierten Daten

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

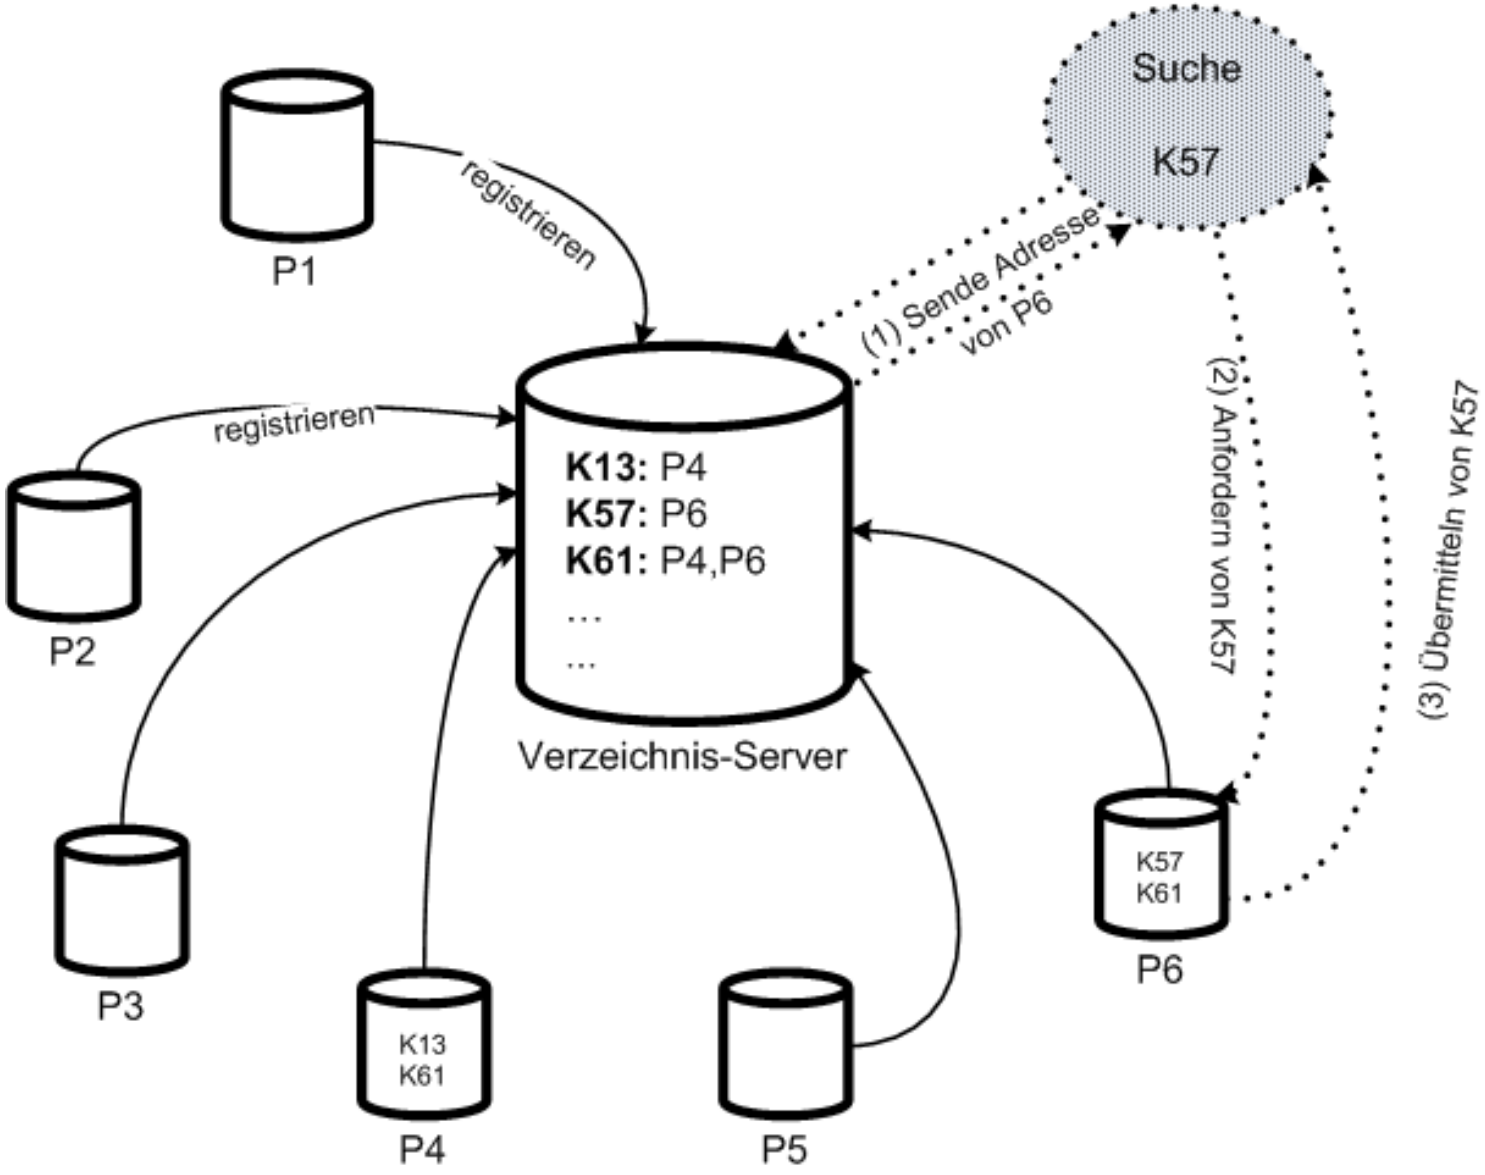

Gnutella-Architektur

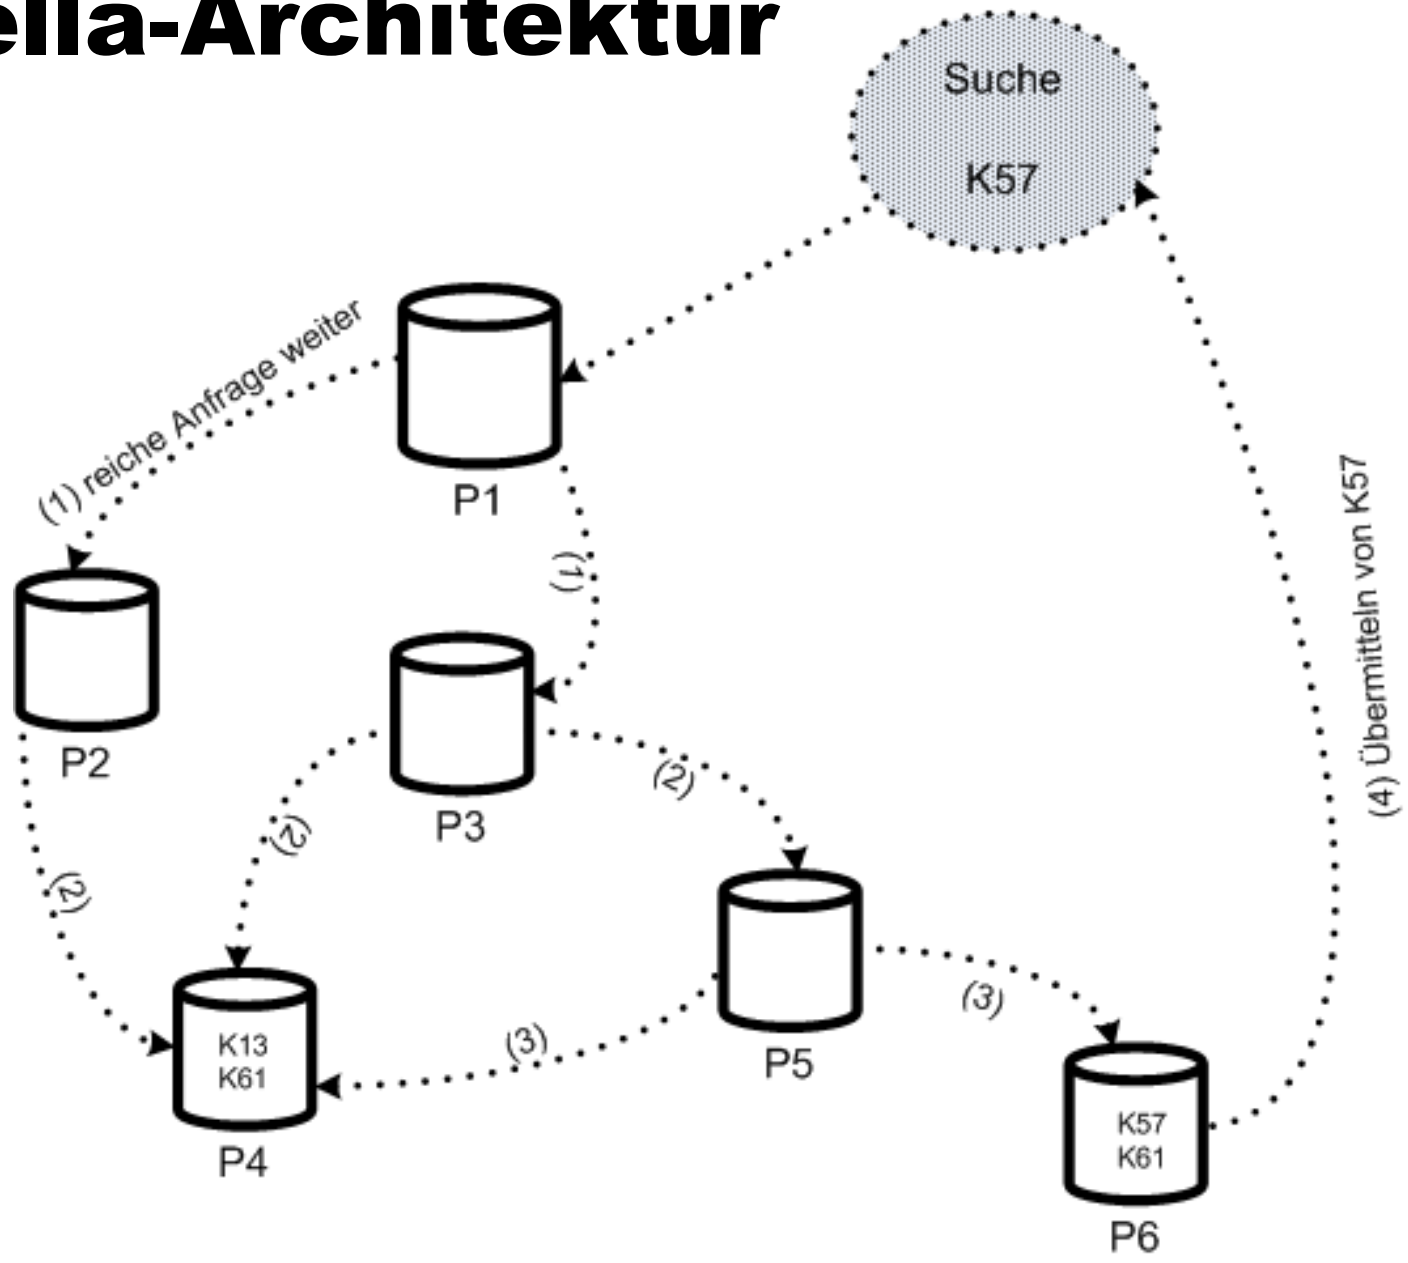

DHT: Distributed Hash Table

- Basieren auf „consistent hashing“
- Vollständige Dezentralisierung der Kontrolle
- Dennoch zielgerichtete Suche

CHORD

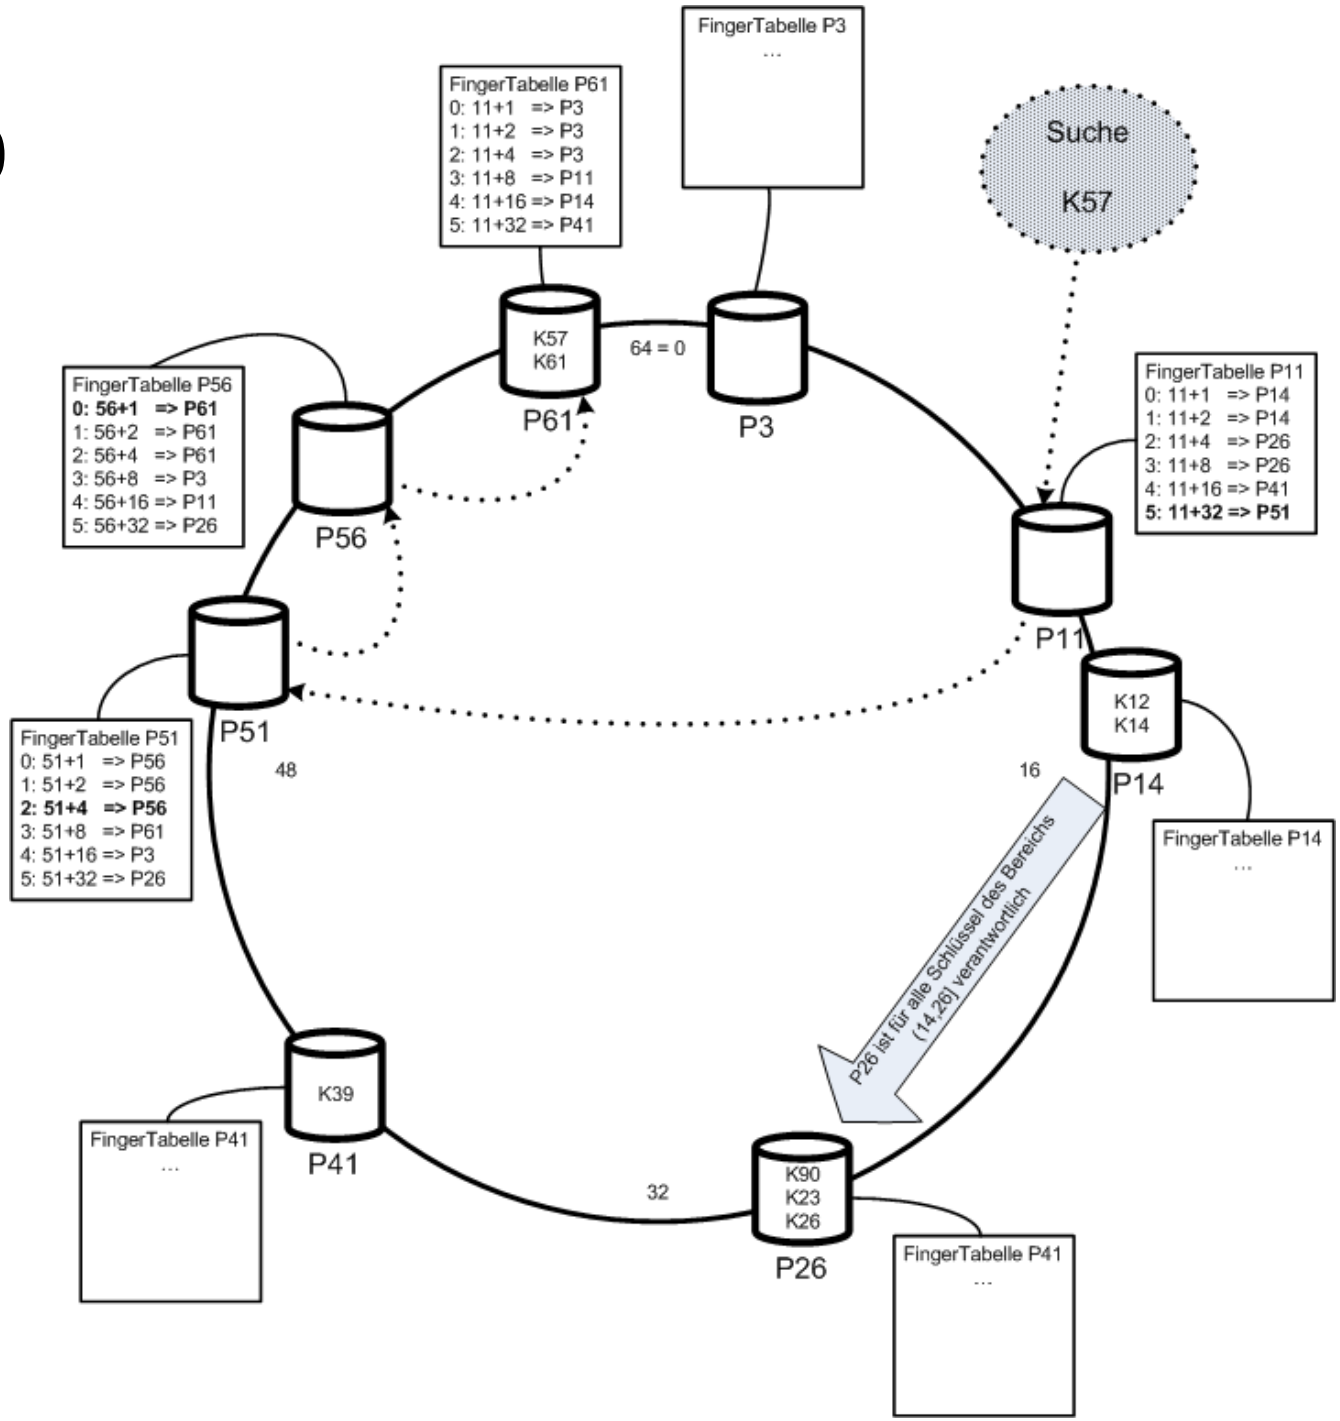
FingerTabelle P3
...
FingerTabelle P61
0: 11+1 => P3
1: 11+2 => P3
2: 11+4 => P3
3: 11+8 => P11
4: 11+16 => P14
5: 11+32 => P41
Suche
K57
K57
K61
P61
64 = 0
P3
FingerTabelle P56
0: 56+1 => P61
1: 56+2 => P61
2: 56+4 => P61
3: 56+8 => P3
4: 56+16 => P11
5: 56+32 => P26
P56
FingerTabelle P11
0: 11+1 => P14
1: 11+2 => P14
2: 11+4 => P26
3: 11+8 => P26
4: 11+16 => P41
5: 11+32 => P51
P11
P51
FingerTabelle P51
0: 51+1 => P56
1: 51+2 => P56
2: 51+4 => P56
3: 51+8 => P61
4: 51+16 => P3
5: 51+32 => P26
48
16
K12
K14
P14
FingerTabelle P14
...
P26 ist für alle Schlüssel des Bereichs (14,26] verantwortlich
K39
P41
FingerTabelle P41
...
32
K90
K23
K26
P26
FingerTabelle P41
...

CAN

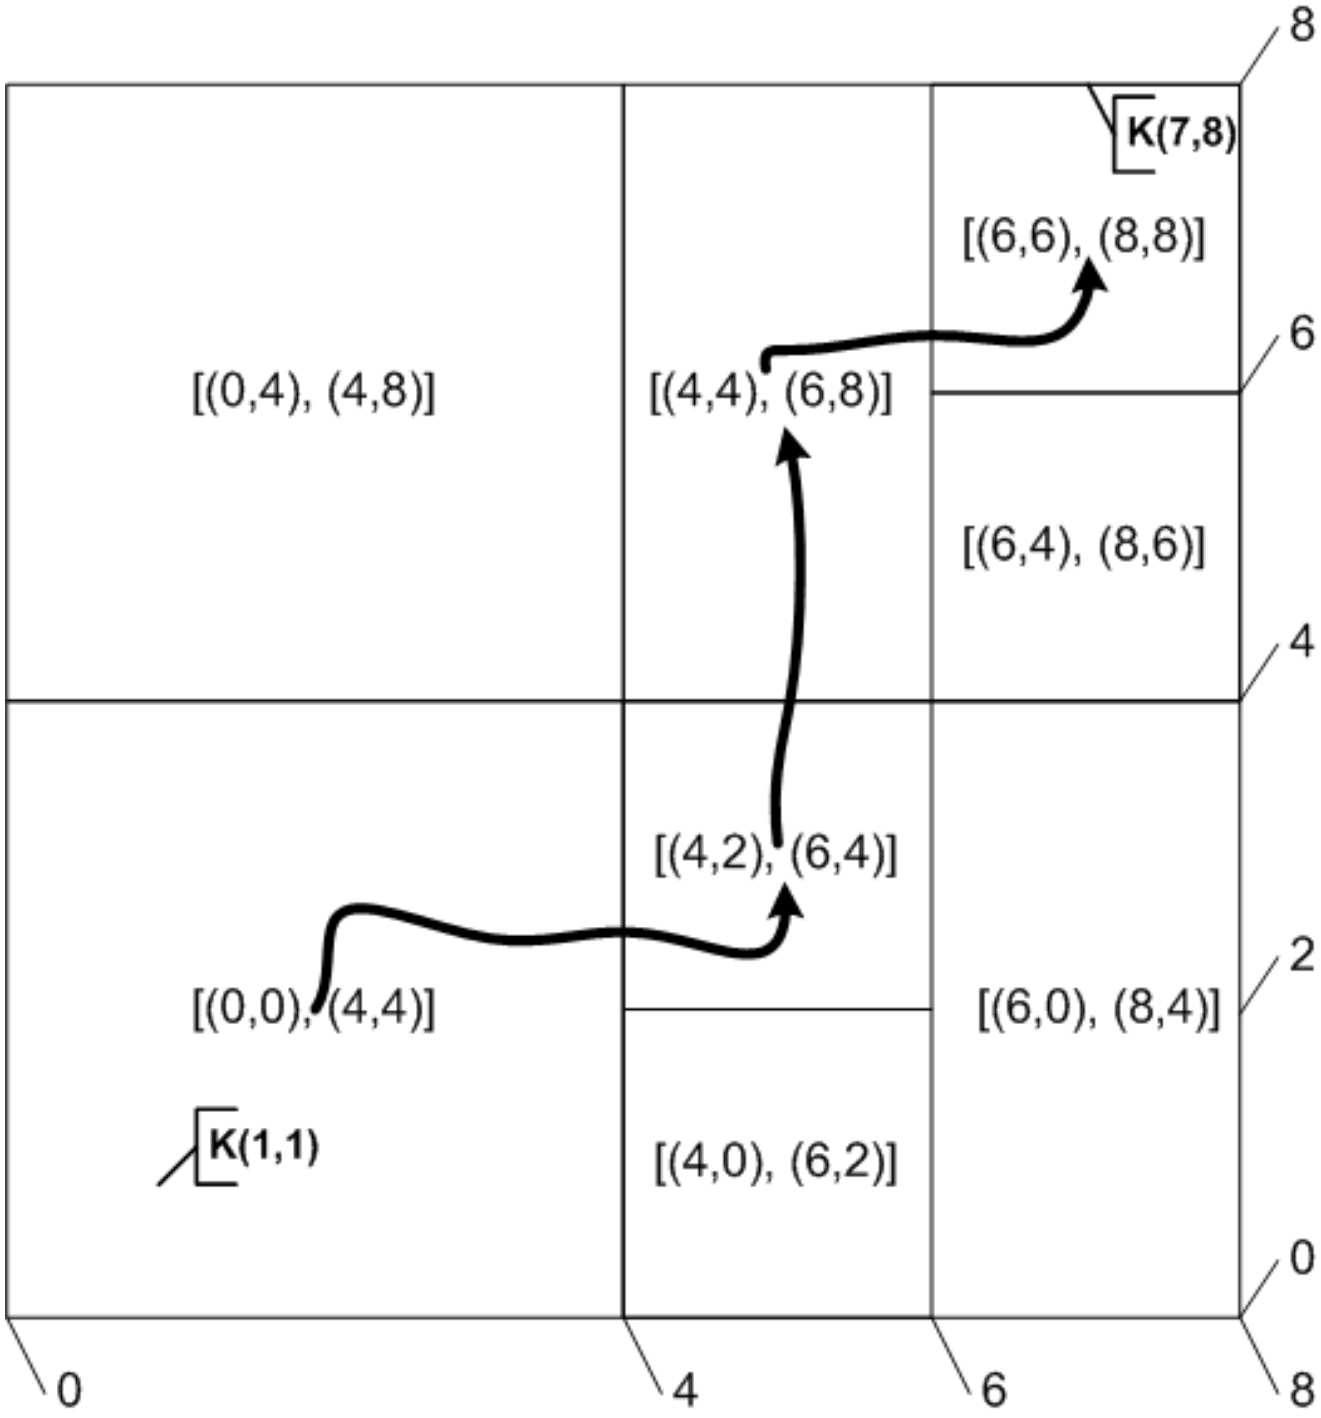

No-SQL Datenbanken

- 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

Systeme

- MongoDB
- Cassandra
- Dynamo
- BigTable
- Hstore
- SimpleDB
- S3