Universität Münster

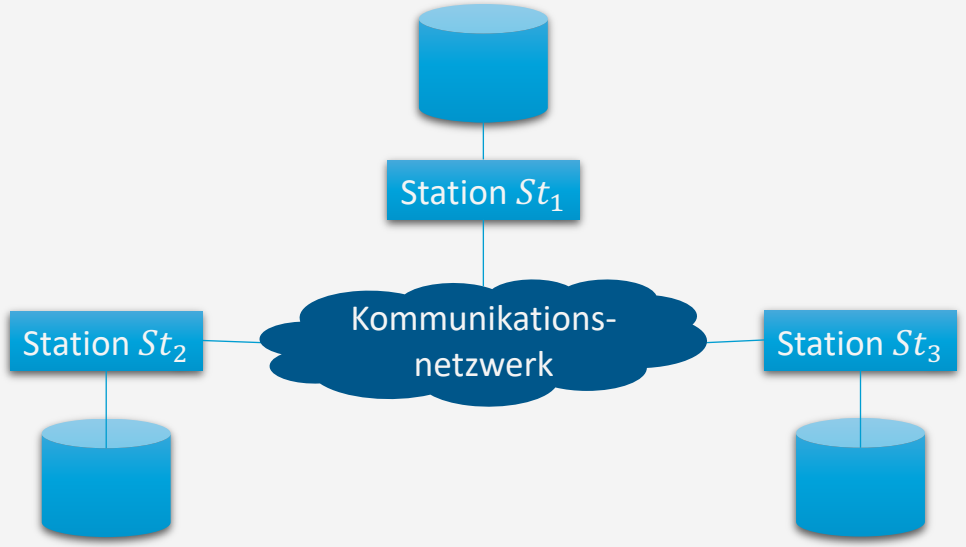

Verteilte Datenbanken

Datenbanken

wissen.leben

Tanya Braun
Arbeitsgruppe Data Science, Institut für Informatik

Inhalte: Datenbanken (DBs)

1. **Einführung**
   - Anwendungen
   - Datenbankmanagementsysteme
2. **Datenbank-Modellierung**
   - Entity-Relationship-Modell (ER-Modell)
   - Beziehung zwischen ER und UML
3. **Das relationale Modell**
   - Relationales Datenmodell (RM)
   - Vom ER-Modell zum RM
   - Relationale Algebra als Anfragesprache
4. **Relationale Entwurfstheorie**
   - Funktionale Abhängigkeiten
   - Normalformen
5. **Structured Query Language (SQL)**
   - Datendefinition
   - Datenmanipulation
6. **Anfrageverarbeitung**
   - Architektur
   - Indexierung
   - Anfragepläne, Optimierung
7. **Transaktionen**
   - Transaktionsverarbeitung, Schedules, Sperren
   - Wiederherstellung
8. **Verteilte Datenbanken**
   - Fragmentierung, Replikation, Allokation; CAP
   - Anfragebeantwortung, föderierte Systeme

Motivation für verteilte Datenbanken

- Verteilung / Dezentralisierung
  - Vor allem bei Neuentwicklungen
  - (Verteilte) Realisierung von Anwendungen auf Basis verteilter (DB-)Systeme
  - (Kontrolliert) verteilte Datenspeicherung zur Lastverteilung, Nutzung von Parallelität Verkürzung von Antwortzeiten, Erhöhung der Ausfallsicherheit

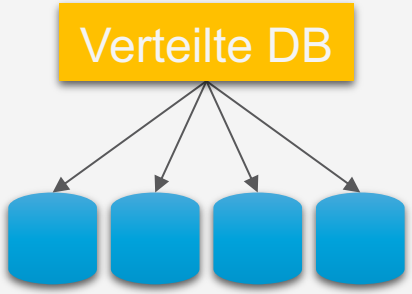

- Integration
  - Bei bestehenden Systemen
  - Verteilt gespeicherte und unabhängig voneinander verwaltete, aber inhaltlich zusammengehörige Daten logisch zusammenbringen
  - Einheitlichen Zugriff auf Gesamtdatenbestand ermöglichen

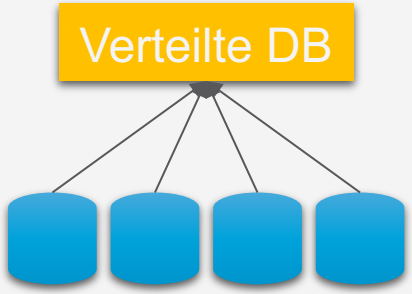

Überblick: 8. Verteilte Datenbanken

A. Verteilte DBMS

- Fragmentierung, Replikation, Allokation
- Transparenz
- CAP-Theorem

B. Anfragenbeantwortung in verteilten Systemen

- Anfrageverarbeitung
- Transaktionskontrolle, Sperrverwaltung, Deadlockvermeidung

C. Föderierte DBS

- Integration
- Migration

Verteiltes DBMS (VDBMS)

- Sammlung von Informationseinheiten, verteilt auf mehreren Rechnern, verbunden mittels Kommunikationsnetz (nach Ceri & Pelagatti, 1984)
- Kooperation zwischen autonom arbeitenden Stationen, zur Durchführung einer globalen Aufgabe

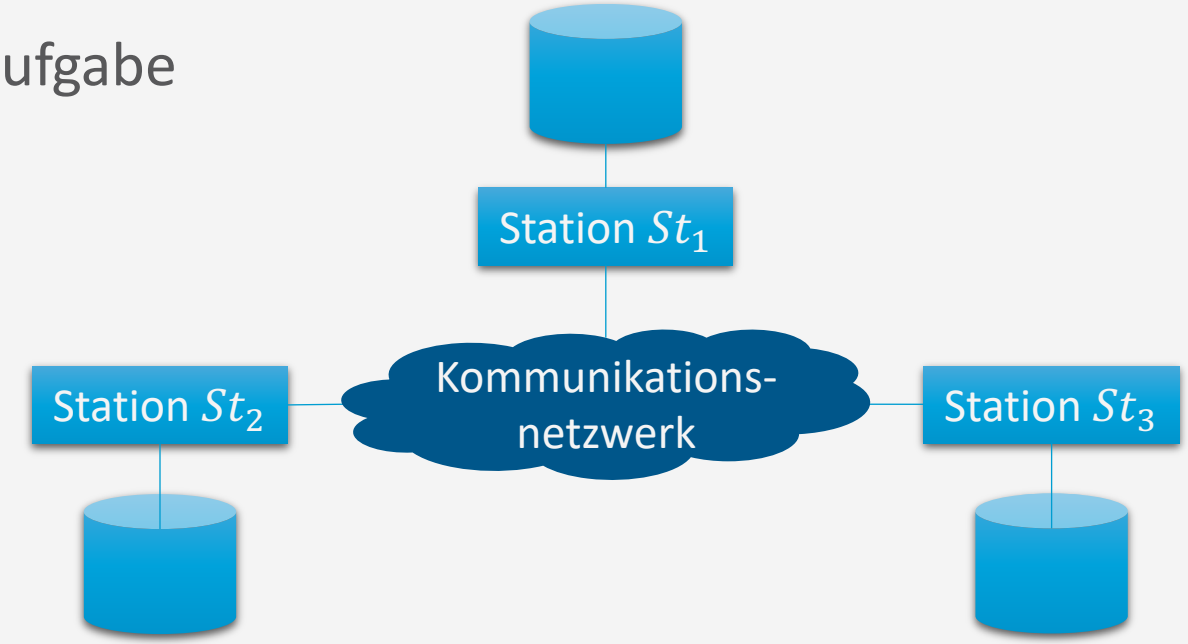

Aufbau eines VDBMS

- Globales Schema
  - Relationales Schema wie zuvor
- Fragmentierungsschema
  - Verteilung der Daten in Fragmente
- Zuordnungsschema
  - Physische Zuordnung (Allokation) der Fragmente auf lokale DBs
  - Möglicherweise mit Replikation
- Lokales Schema / DBMS / DB
  - DB: Menge der lokal gespeicherten Daten
  - DBMS: Lokales System zur Verwaltung und Anfragebeantwortung
  - Schema: Lokale Sicht auf die Daten in lokaler DB

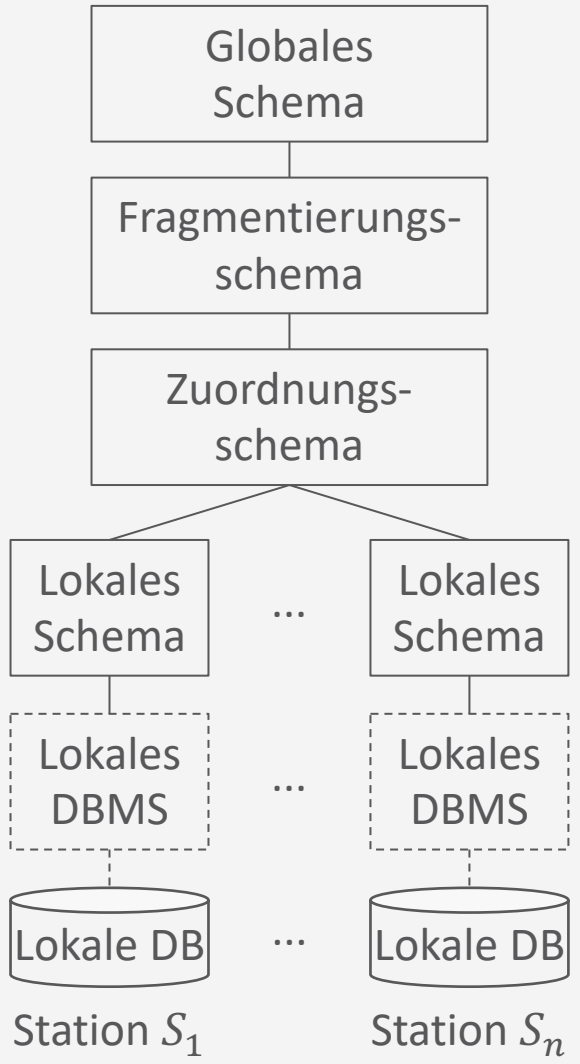

Fragmentierung

- Ziel: Verteilung von Daten
- Arten der Fragmentierung
  - Horizontal: Entlang der Tabellenzeilen
    - Aufteilung durch Selektion
  - Vertikal: Entlang der Tabellenspalten
    - Aufteilung durch Projektion
  - Gemischt: Verschachtelung von Fragmentierung
    - Aufteilung durch verschachtelte Selektion und Projektion
  - Abgeleitet: Anhand von Bedingungen
    - Z.B. über Fremdschlüsselrelation

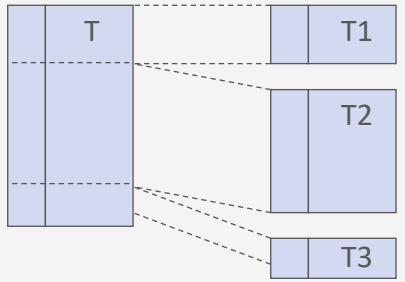

Horizontale Fragmentierung

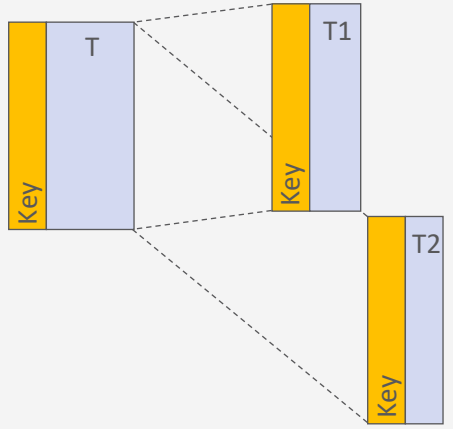

Vertikale Fragmentierung

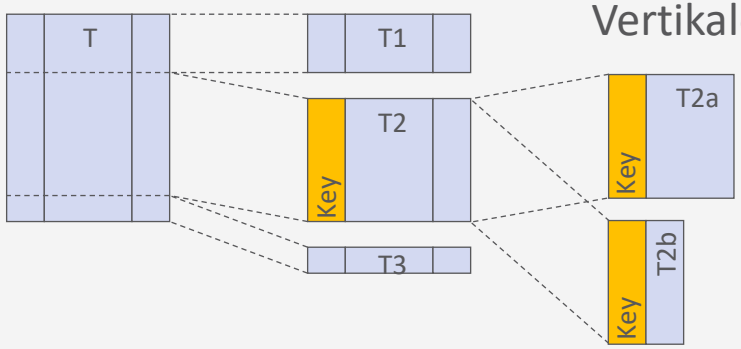

Gemischte Fragmentierung

Beispiel für horizontale Fragmentierung

$$Profs = PhilProfs \cup PhysProfs \cup TheoProfs$$

$$PhilProfs = \sigma_{Fakultaet='Philosophie'}(Profs)$$

$$TheoProfs = \sigma_{Fakultaet='Theologie'}(Profs)$$

$$PhysProfs = \sigma_{Fakultaet='Physik'}(Profs)$$

Profs

PersNr	Name	Rang	Raum	Fakultaet	Gehalt	St.Klasse
2125	Sokrates	W3	226	Philosophie	85000	1
2126	Russel	W3	232	Philosophie	80000	3
2127	Kopernikus	W2	310	Physik	65000	5
2133	Popper	W2	52	Philosophie	68000	1
2134	Augustinus	W2	309	Theologie	55000	5
2136	Curie	W3	36	Physik	95000	3
2137	Kant	W3	7	Philosophie	98000	1

PhilProfs

PersNr	Name	Rang	Raum	Fakultaet	Gehalt	St.Klasse
2125	Sokrates	W3	226	Philosophie	85000	1
2126	Russel	W3	232	Philosophie	80000	3
2133	Popper	W2	52	Philosophie	68000	1
2137	Kant	W3	7	Philosophie	98000	1

TheoProfs

PersNr	Name	Rang	Raum	Fakultaet	Gehalt	St.Klasse
2134	Augustinus	W2	309	Theologie	55000	5

PhysProfs

PersNr	Name	Rang	Raum	Fakultaet	Gehalt	St.Klasse
2127	Kopernikus	W2	310	Physik	65000	5
2136	Curie	W3	36	Physik	95000	3

Beispiel für vertikale Fragmentierung

$$Profs = ProfVerw \bowtie Pfs$$

Profs

PersNr	Name	Rang	Raum	Fakultaet	Gehalt	St.Klasse
2125	Sokrates	W3	226	Philosophie	85000	1
2126	Russel	W3	232	Philosophie	80000	3
2127	Kopernikus	W2	310	Physik	65000	5
2133	Popper	W2	52	Philosophie	68000	1
2134	Augustinus	W2	309	Theologie	55000	5
2136	Curie	W3	36	Physik	95000	3
2137	Kant	W3	7	Philosophie	98000	1

$$ProfVerw = \pi_{PersNr,Name,Gehalt,Steuerklasse}(Profs)$$

ProfVerw

PersNr	Name	Gehalt	St.Klasse
2125	Sokrates	85000	1
2126	Russel	80000	3
2127	Kopernikus	65000	5
2133	Popper	68000	1
2134	Augustinus	55000	5
2136	Curie	95000	3
2137	Kant	98000	1

$$Pfs = \pi_{PersNr,Name,Rang,Raum,,Fakultaet}(Profs)$$

Pfs

PersNr	Name	Rang	Raum	Fakultaet
2125	Sokrates	W3	226	Philosophie
2126	Russel	W3	232	Philosophie
2127	Kopernikus	W2	310	Physik
2133	Popper	W2	52	Philosophie
2134	Augustinus	W2	309	Theologie
2136	Curie	W3	36	Physik
2137	Kant	W3	7	Philosophie

Beispiel für gemischte Fragmentierung

$$Profs = ProfVerw \bowtie (PhilPfs \cup PhysPfs \cup TheoPfs)$$

$$ProfVerw = \pi_{PersNr,Name,Gehalt,Steuerklasse}(Profs)$$

$$Pfs = \pi_{PersNr,Name,Rang,Raum,,Fakultaet}(Profs)$$

$$PhilPrs = \sigma_{Fakultaet='Philosophie'}(Pfs)$$

$$TheoPfs = \sigma_{Fakultaet='Theologie'}(Pfs)$$

$$PhysPfs = \sigma_{Fakultaet='Physik'}(Pfs)$$

Pfs

PersNr	Name	Rang	Raum	Fakultaet
2125	Sokrates	W3	226	Philosophie
2126	Russel	W3	232	Philosophie
2127	Kopernikus	W2	310	Physik
2133	Popper	W2	52	Philosophie
2134	Augustinus	W2	309	Theologie
2136	Curie	W3	36	Physik
2137	Kant	W3	7	Philosophie

PhilPfs

PersNr	Name	Rang	Raum	Fakultaet
2125	Sokrates	W3	226	Philosophie
2126	Russel	W3	232	Philosophie
2133	Popper	W2	52	Philosophie
2137	Kant	W3	7	Philosophie

TheoPfs

PersNr	Name	Rang	Raum	Fakultaet
2134	Augustinus	W2	309	Theologie

PhysPfs

PersNr	Name	Rang	Raum	Fakultaet
2127	Kopernikus	W2	310	Physik
2136	Curie	W3	36	Physik

Abgeleitete Fragmentierung über Fremdschlüsselbeziehung

- Relation S wird auf Basis der Fragmentierung der Relation R abgeleitet (fragmentiert)
  - Fremdschlüssel B in S auf Primärschlüssel A in R
- R durch Selektion horizontal in Fragmente R_i zerlegt
  - Referenzpartitionierung für S
- S aufgrund Fremdschlüsselbeziehungen partitioniert
  - $S_i = S \ltimes_{S.B=A} (\pi_A(R_i))$
- $R_i.A$ bilden disjunkte Menge
  $\rightarrow$ auch S_i disjunkt

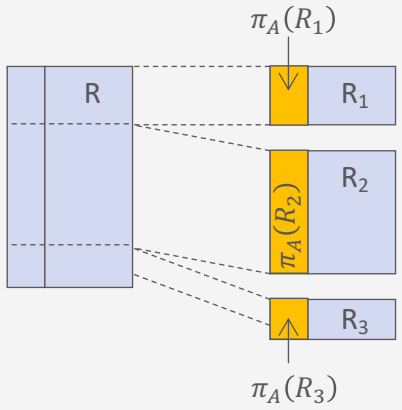

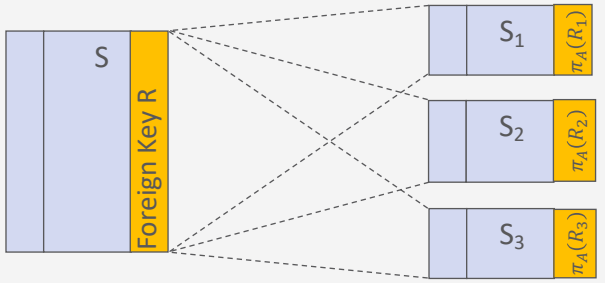

Beispiel für abgeleitete Fragmentierung

- Horizontale Fragmentierung der Relation Pfs
  - Entspricht der Relation R
  - Disjunkte Mengen der Primärschlüssel $PersNr$ von $PhilPfs, TheoPfs, PhysPfs$

Pfs

PersNr	Name	Rang	Raum	Fakultaet
2125	Sokrates	W3	226	Philosophie
2126	Russel	W3	232	Philosophie
2127	Kopernikus	W2	310	Physik
2133	Popper	W2	52	Philosophie
2134	Augustinus	W2	309	Theologie
2136	Curie	W3	36	Physik
2137	Kant	W3	7	Philosophie

$\pi_{PersNr}(PhilPfs)$

PersNr
2125
2126
2133
2137

PhilPfs

PersNr	Name	Rang	Raum	Fakultaet
2125	Sokrates	W3	226	Philosophie
2126	Russel	W3	232	Philosophie
2133	Popper	W2	52	Philosophie
2137	Kant	W3	7	Philosophie

$\pi_{PersNr}(TheoPfs)$

PersNr
2134

TheoPfs

PersNr	Name	Rang	Raum	Fakultaet
2134	Augustinus	W2	309	Theologie

$\pi_{PersNr}(PhysPfs)$

PersNr
2127
2136

PhysPfs

PersNr	Name	Rang	Raum	Fakultaet
2127	Kopernikus	W2	310	Physik
2136	Curie	W3	36	Physik

Beispiel für abgeleitete Fragmentierung

- Horizontale Fragmentierung der Relation Pfs
- Ableitung der Fragmentierung der Relation $Vorlesungen$
  - $Vorlesungen$ entspricht S, $Dozierende$ Fremdschlüssel auf $PersNr$

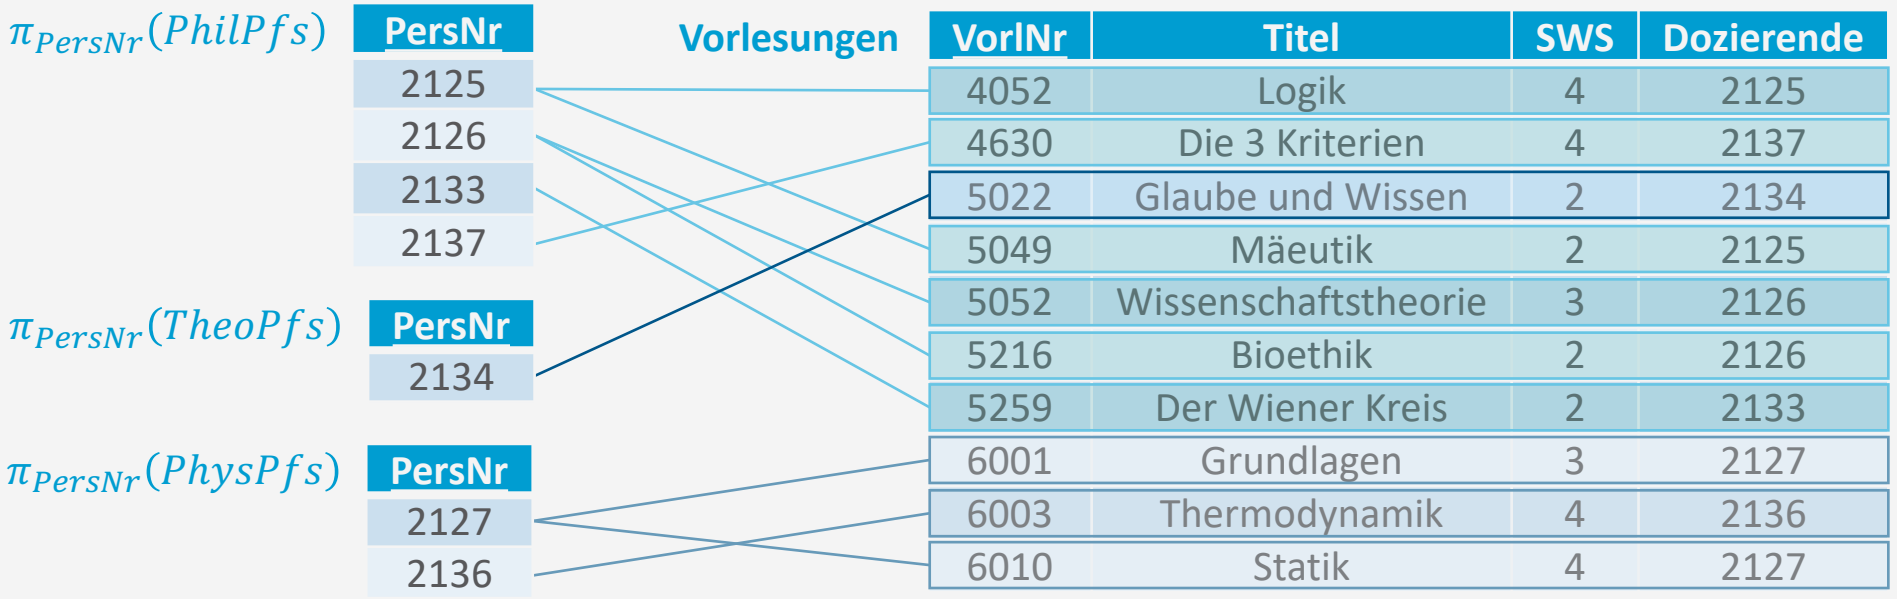

Universität Münster

Beispiel für abgeleitete Fragmentierung

- Abgeleitete Fragmentierung:

Vorlesungen

VorlNr	Titel	SWS	Dozierende
4052	Logik	4	2125
4630	Die 3 Kriterien	4	2137
5022	Glaube und Wissen	2	2134
5049	Mäeutik	2	2125
5052	Wissenschaftstheorie	3	2126
5216	Bioethik	2	2126
5259	Der Wiener Kreis	2	2133
6001	Grundlagen	3	2127
6003	Thermodynamik	4	2136
6010	Statik	4	2127

PhilVorl

VorlNr	Titel	SWS	Doziernde
4052	Logik	4	2125
4630	Die 3 Kriterien	4	2137
5049	Mäeutik	2	2125
5052	Wissenschaftstheorie	3	2126
5216	Bioethik	2	2126
5259	Der Wiener Kreis	2	2133

TheoVorl

VorlNr	Titel	SWS	Doziernde
5022	Glaube und Wissen	2	2134

PhysVorl

VorlNr	Titel	SWS	Doziernde
6001	Grundlagen	3	2127
6003	Thermodynamik	4	2136
6010	Statik	4	2127

PhilPfs

PersNr	Name	Rang	Raum	Fakultaet
2125	Sokrates	W3	226	Philosophie
2126	Russel	W3	232	Philosophie
2133	Popper	W2	52	Philosophie
2137	Kant	W3	7	Philosophie

TheoPfs

PersNr	Name	Rang	Raum	Fakultaet
2134	Augustinus	W2	309	Theologie

PhysPfs

PersNr	Name	Rang	Raum	Fakultaet
2127	Kopernikus	W2	310	Physik
2136	Curie	W3	36	Physik

Beispiele Fragmentierungen: Baumdarstellung

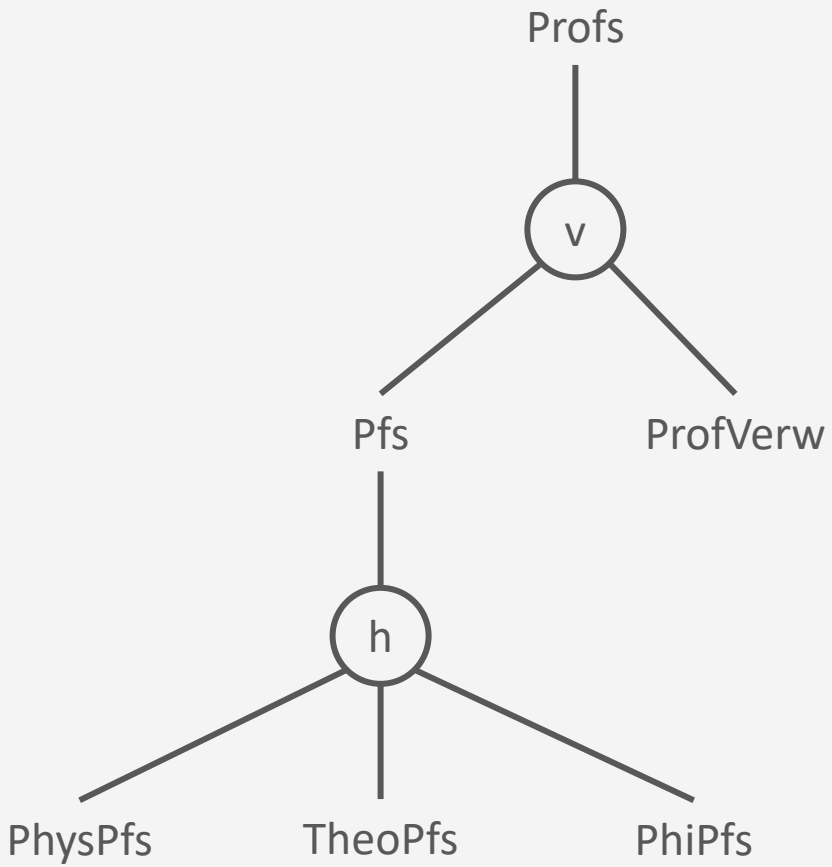

$$Profs = ProfVerw \bowtie (PhilPfs \cup PhysPfs \cup TheoPfs)$$
$$Vorlesungen = PhilVorl \cup PhysVorl \cup TheoVorl$$

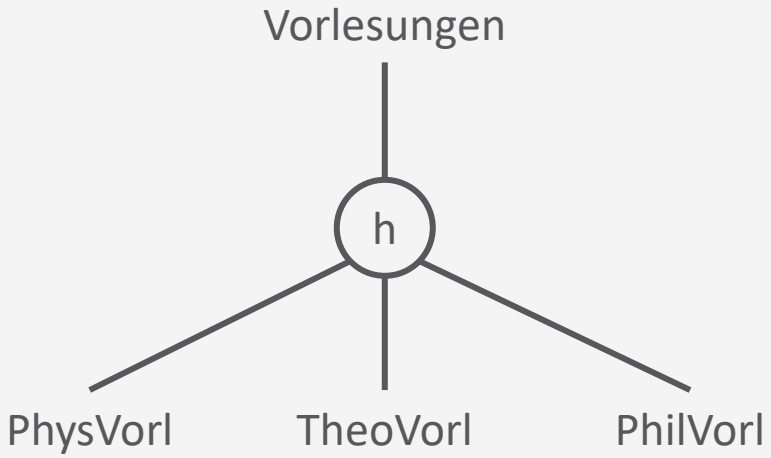

Fragmentierung: Korrektheitsanforderungen

- Korrektheit der Fragmentierung
  - *Rekonstruierbarkeit*
    - Original-Relation lässt sich aus den Fragmenten wiederherstellen
  - *Vollständigkeit*
    - Jedes Tupel ist einem Fragment zugeordnet
  - *Disjunktheit*
    - Die Fragmente überlappen sich nicht

- Bisher betrachtete Fragmentierungen
  - Horizontal
    - Selektion darf keine Tupel auslassen
    - Dann rekonstruierbar, vollständig, disjunkt
  - Vertikal
    - Projektion darf keine Attribute auslassen
    - Zur Rekonstruktion der Originalrelation, Übernahme der Primärschlüssel in die Fragmente notwendig
    - Dann rekonstruierbar, vollständig, aber nicht mehr disjunkt (Primärschlüssel vielfach)
  - Abgeleitet und gemischt
    - Selbe Überlegungen wie oben

Fragmentierung

- Motivation
  - Lastverteilung
  - Nutzung von Parallelität zur Verkürzung von Antwortzeiten
- Art der Fragmentierung abhängig von häufigen Anfragen und Zugriffsmustern
- Herausforderungen
  - DBS muss Verteilung der Daten kennen und bei Anfragen berücksichtigen
    - An welche DB muss welche Teilanfrage?
    - Wie müssen Ergebnismengen zusammengefügt werden?
    - Was passiert, wenn eine DB ausfällt?

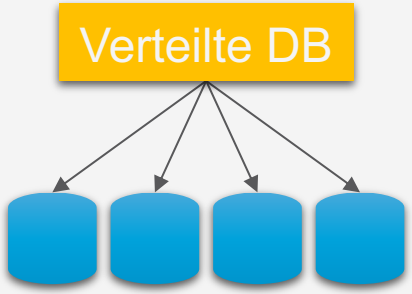

Replikation

- (Logisches) Duplizieren von Daten nach strategischen Gesichtspunkten
- Motivation: Erhöhung der
  - Effizienz (schnellerer Zugriff „vor Ort statt entfernt“)
  - Ausfallsicherheit und Verfügbarkeit (Replikat als „Sicherungskopie“)
  - Autonomie (Unabhängigkeit von ansonsten nur einmal verfügbaren Daten)
- Zielkonflikte bei der Replikation
  - Deutliche Erhöhung der Zugriffseffizienz, Verfügbarkeit und Autonomie
    → Große Anzahl von Replikaten auf möglichst vielen Knoten
  - Erhaltung der Datenkonsistenz
    → Alle Replikate möglichst synchron aktualisieren
  - Erhöhung der Effizienz bei Änderungsoperationen
    → Wenige Replikate wünschenswert; schneller synchron aktualisierbar

Allokation

- (Physische) gezielte Zuordnung von Daten auf Rechner
- Die (physisch orientierte) Allokation legt fest,
  - Auf welchem Rechner ein Fragment gehalten wird
  - Welche Fragmente auf welchen Rechnern repliziert gespeichert werden
- Physische Umsetzung der Überlegung aus Fragmentierung und Replikation
- Bei der Allokation zu berücksichtigende Aspekte:
  - Effizienz
    - Minimierung von Zugriffskosten für Remote-Zugriffe
    - Vermeidung von Flaschenhälsen (Übertragungskapazität im Netz, Leistung einzelner Rechenknoten, ...)
  - Datensicherheit
    - Auswahl von Knoten hinsichtlich Verlässlichkeit
    - Redundante Speicherung von Daten

Fortsetzung Beispiel

- Allokation ohne Replikation

Lokale DB/Station	Bemerkung	Zugeordnete Fragmente
St_{Verw}	Verwaltungsrechner	{ProfVerw}
St_{Phil}	Dekanat Philosophie	{PhilVorl, PhilPfs}
St_{Phys}	Dekanat Physik	{PhysVorl, PhysPfs}
St_{Theo}	Dekanat Theologie	{TheoVorl, TheoPfs}

- Allokation mit Replikation, Beispiele:
  - Erhöhung der Ausfallsicherheit: Zweite St_{Verw}-Station
  - Prüfungsamt benötigt Vorlesungsinformation: Weitere Station St_{Vorl} mit den wiedervereinigten Vorlesungsfragmenten

Transparenz in verteilten Datenbanken

- Grad der Unabhängigkeit, den ein VDBMS dem Benutzer beim Zugriff auf verteilte Daten vermittelt
  - Verschiedene Stufen:
    - Fragmentierungstransparenz: Nutzer stellen Anfragen an das globale Schema, haben kein Wissen über Fragmentierung / Allokation
      - VDBMS muss Anfragen / Änderungen korrekt auf Fragmenten und in Stationen umsetzen
    - Allokationstransparenz: Nutzer müssen die Fragmentierung kennen, aber nicht die Allokation
      - Anfragen an Fragmente/lokale Schemata
    - Lokale Schema-Transparenz: Nutzer müssen Station kennen, auf dem Fragment liegt
      - Transparenz bezieht sich darauf, dass zumindest alle Stationen dasselbe Datenmodell und dieselbe Anfragesprache verwenden

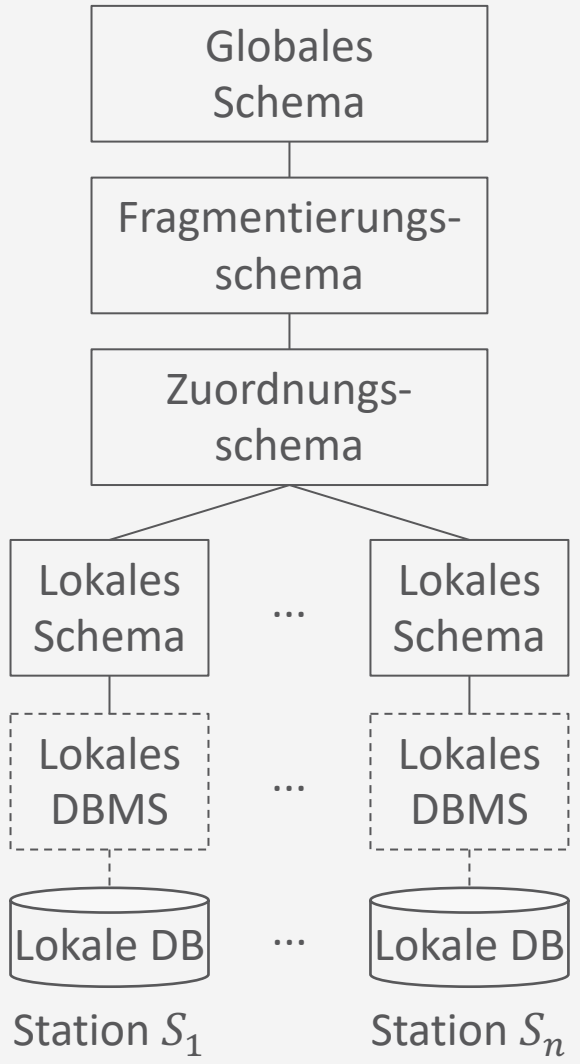

Fragmentierungstranparenz: Beispiel

- Anfrage, die Fragmentierungstransparenz voraussetzt:
  - ```
    select Titel, Name
    from Vorlesungen, Profs
    where Dozierende = PersNr;
    ```
  - Jeweils ein Join von *Vorl mit *Pfs auf der jeweiligen lokalen Station
  - Vereinigung der Join-Ergebnisse auf der Station, auf der die Anfrage liegt

Lokale DB/Station	Bemerkung	Zugeordnete Fragmente
St_{Verw}	Verwaltungsrechner	{ProfVerw}
St_{Phil}	Dekanat Physik	{PhilVorl, PhilPfs}
St_{Phys}	Dekanat Philosophie	{PhysVorl, PhysPfs}
St_{Theo}	Dekanat Theologie	{TheoVorl, TheoPfs}

PhilPfs

PersNr	Name	Rang	Raum	Fakultaet
2125	Sokrates	W3	226	Philosophie
2126	Russel	W3	232	Philosophie
2133	Popper	W2	52	Philosophie
2137	Kant	W3	7	Philosophie

PhilVorl

VorlNr	Titel	SWS	Doziernde
4052	Logik	4	2125
4630	Die 3 Kriterien	4	2137
5049	Mäeutik	2	2125
5052	Wissenschaftstheorie	3	2126
5216	Bioethik	2	2126
5259	Der Wiener Kreis	2	2133
    ```

Fragmentierungstranparenz: Beispiel

- Änderungsoperation, die Fragmentierungstransparenz voraussetzt:
  - `update Professoren set Fakultät='Theologie' where Name='Sokrates';`
  - Transferieren des Tupels aus Fragment PhilPfs in das Fragment TheoPfs
    - Löschen aus PhilPfs, Einfügen in TheoPfs
  - Ändern der abgeleiteten Fragmentierung von Vorlesungen
    - Einfügen der von Sokrates gehaltenen Vorlesungen in TheoVorl, Löschen aus PhilVorl

Verteilte DBs

Lokale DB/Station	Bemerkung	Zugeordnete Fragmente
St_{Verw}	Verwaltungsrechner	{ProfVerw}
St_{Phil}	Dekanat Physik	{PhilVorl, PhilPfs}
St_{Phys}	Dekanat Philosophie	{PhysVorl, PhysPfs}
St_{Theo}	Dekanat Theologie	{TheoVorl, TheoPfs}

PhilPfs

PersNr	Name	Rang	Raum	Fakultaet
2125	Sokrates	W3	226	Philosophie
2126	Russel	W3	232	Philosophie
2133	Popper	W2	52	Philosophie
2137	Kant	W3	7	Philosophie

PhilVorl

VorlNr	Titel	SWS	Doziernde
4052	Logik	4	2125
4630	Die 3 Kriterien	4	2137
5049	Mäeutik	2	2125
5052	Wissenschaftstheorie	3	2126
5216	Bioethik	2	2126
5259	Der Wiener Kreis	2	2133

Allokationstransparenz: Beispiel

- Nutzer*innen müssen Fragmentierung kennen, aber nicht Aufenthaltsort von Fragmenten
  - Beispielanfrage:
    - ```
      select Gehalt
      from ProfVerw
      where Name='Sokrates';
      ```
  - Unter Umständen muss Originalrelation rekonstruiert werden
    - Beispiel: Verwaltung möchte wissen, wieviel die W3-Professoren der Theologie insgesamt verdienen
      - ```
        select sum(Gehalt)
        from ProfVerw, TheoPfs
        where ProfVerw.PersNr=TheoPfs.PersNr and
        Rang='W3';
        ```

Lokale DB/Station	Bemerkung	Zugeordnete Fragmente
St_{Verw}	Verwaltungsrechner	{ProfVerw}
St_{Phil}	Dekanat Physik	{PhilVorl, PhilPfs}
St_{Phys}	Dekanat Philosophie	{PhysVorl, PhysPfs}
St_{Theo}	Dekanat Theologie	{TheoVorl, TheoPfs}

ProfVerw

PersNr	Name	Gehalt	St.Klasse
2125	Sokrates	85000	1
2126	Russel	80000	3
2127	Kopernikus	65000	5
2133	Popper	68000	1
2134	Augustinus	55000	5
2136	Curie	95000	3
2137	Kant	98000	1

TheoPfs

PersNr	Name	Rang	Raum	Fakultaet
2134	Augustinus	W2	309	Theologie

Lokale Schema-Transparenz

- Der Benutzer muss auch noch den Rechner kennen, auf dem ein Fragment liegt
  - Beispielanfrage:
    - ```
      select Name
      from TheoPfs at St_Theo
      where Rang='W2';
      ```
  - Ist überhaupt Transparenz gegeben?
    - Lokale Schema-Transparenz setzt voraus, dass alle Rechner dasselbe Datenmodell und dieselbe Anfragesprache verwenden.
      - Anfrage kann somit analog auch an Station St_{Phil} ausgeführt werden
      - Nicht möglich bei Kopplung unterschiedlicher DBMS

Lokale DB/Station	Bemerkung	Zugeordnete Fragmente
St_{Verw}	Verwaltungsrechner	{ProfVerw}
St_{Phil}	Dekanat Physik	{PhilVorl, PhilPfs}
St_{Phys}	Dekanat Philosophie	{PhysVorl, PhysPfs}
St_{Theo}	Dekanat Theologie	{TheoVorl, TheoPfs}

ProfVerw

PersNr	Name	Gehalt	St.Klasse
2125	Sokrates	85000	1
2126	Russel	80000	3
2127	Kopernikus	65000	5
2133	Popper	68000	1
2134	Augustinus	55000	5
2136	Curie	95000	3
2137	Kant	98000	1

TheoPfs

PersNr	Name	Rang	Raum	Fakultaet
2134	Augustinus	W2	309	Theologie

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

Konsistenzmodell: CAP

- Neben Transparenz, weitere Anforderungen an verteilte DBs: Konsistenz, Verfügbarkeit, Ausfalltoleranz
  - Consistency, Availability, Partition tolerance = CAP
  - *Konsistenz*: Alle Knoten liefern identische Daten
  - *Verfügbarkeit*: Akzeptable Reaktionszeit (Station muss antworten)
  - *Ausfalltoleranz*: Knoten / Kommunikationsverbindung kann ausfallen
- CAP-Theorem:
  Nur zwei der drei Anforderungen in verteilten Systemen erfüllbar
  - Vermutung von Brewer (2000)
  - Beweis von Gilbert und Lynch (2002)

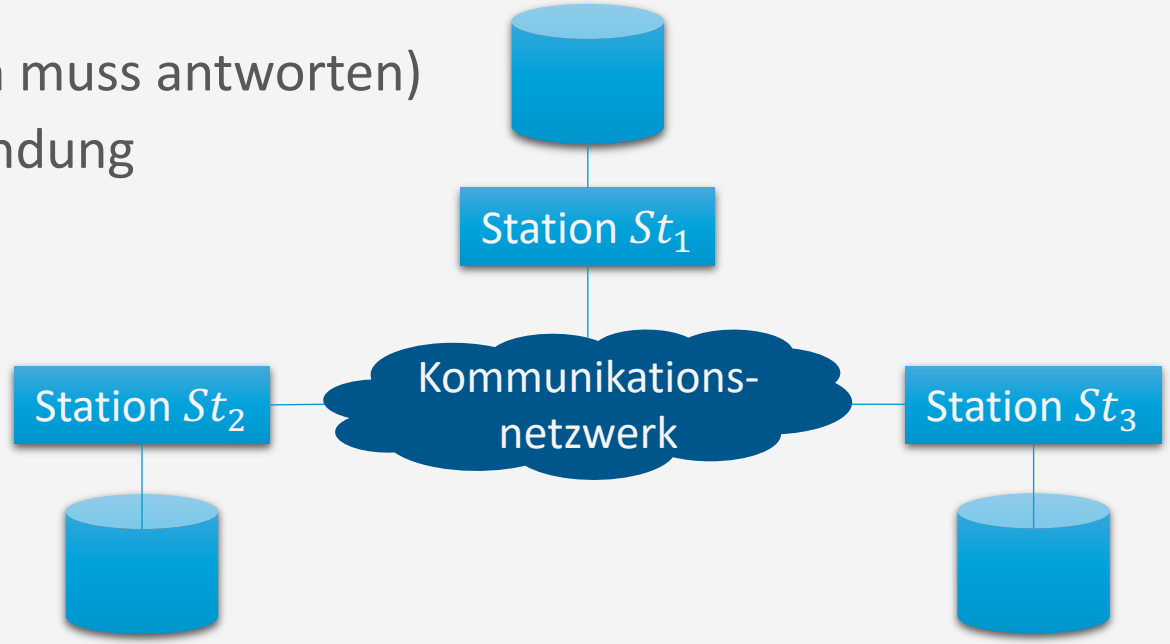

CAP-Theorem

- Beweis-Idee (über Widerspruch)
  - Annahme: Es gibt ein CAP System
  1. AP geht nicht mit C
     - Annahme: System ist partitioniert (keine Verbindung zwischen St_1 und St_2), was zu tolerieren ist (P)
     - Anfrage an Station St_1 Datum X zu schreiben mit Wert x_1
       - Da das System verfügbar ist (A), muss St_1 antworten
       - Da das System partitioniert ist, kann St_1 die Änderung aber nicht an die anderen Stationen weitergeben
     - Dann Anfrage an Station St_2 Datum X zu lesen
       - Da das System verfügbar ist (A), muss St_2 antworten
       - Da das System partitioniert ist, kann St_2 nur den veralteten Wert x_0 zurückgeben
         → Inkonsistenz (kein C)

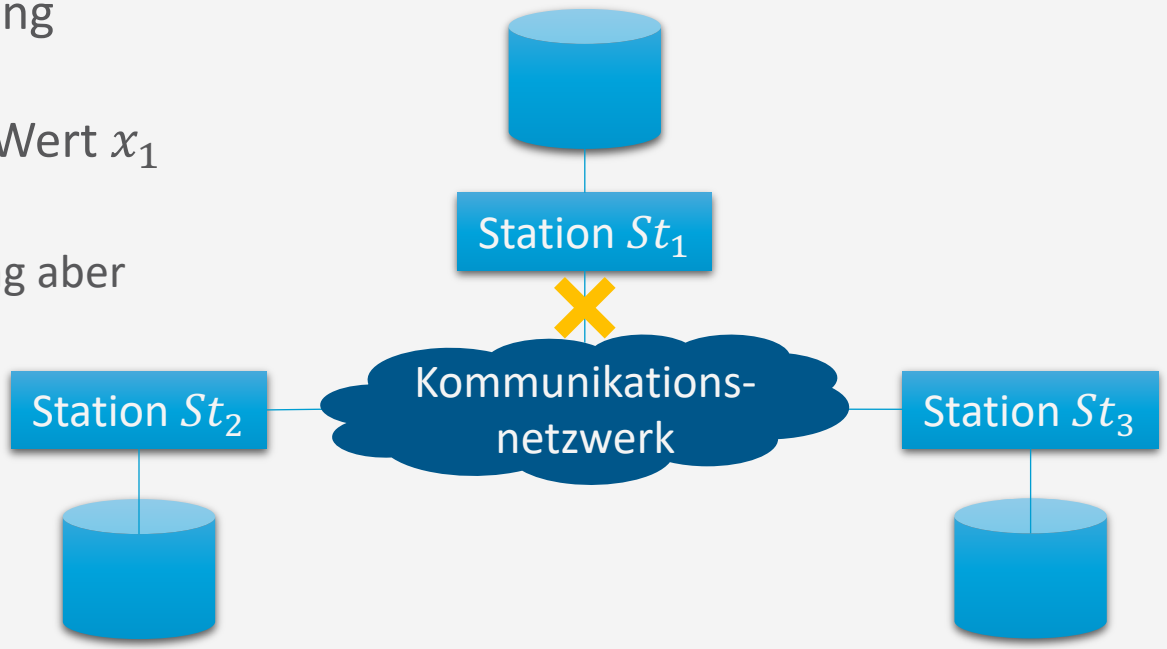

CAP-Theorem

- Beweis-Idee (über Widerspruch)
  - Annahme: Es gibt ein CAP System
  2. CP geht nicht mit A
     - Annahme: System ist partitioniert (keine Verbindung zwischen St_1 und St_2), was zu tolerieren ist (P)
     - Anfrage an Station St_1 X zu schreiben mit Wert x_1
       - Da das System partitioniert ist, kann St_1 die Änderung nicht an die anderen Stationen weitergeben, da es sonst inkonsistente Daten hätte (C erhalten)
       - St_1 muss die Anfrage ablehnen bzw. kann nicht antworten → Keine Verfügbarkeit (kein A)

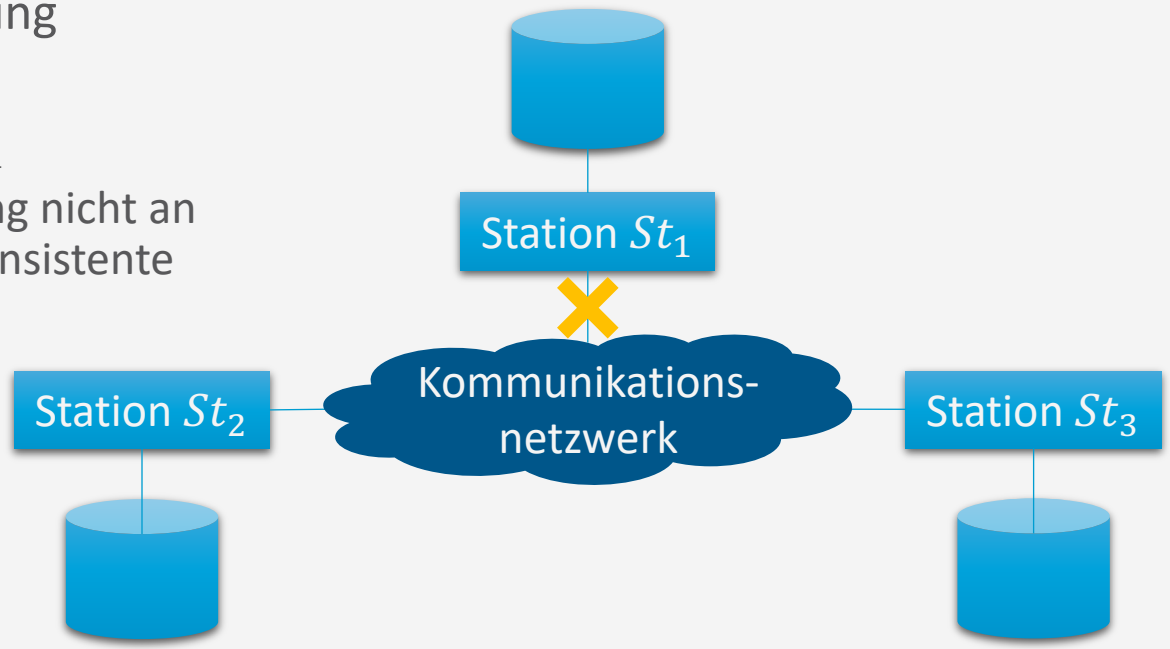

CAP-Theorem

- Beweis-Idee (über Widerspruch)
  - Annahme: Es gibt ein CAP System
  3. CA geht nicht mit P
     - Anfrage an Station St_1 X zu schreiben mit Wert x_1
       - Da das System verfügbar ist (A), muss St_1 antworten
       - Die Änderung muss an die anderen Stationen weitergegeben werden (C), darf also nicht partitioniert sein
         → Ausfalltoleranz nicht gegeben (kein P)

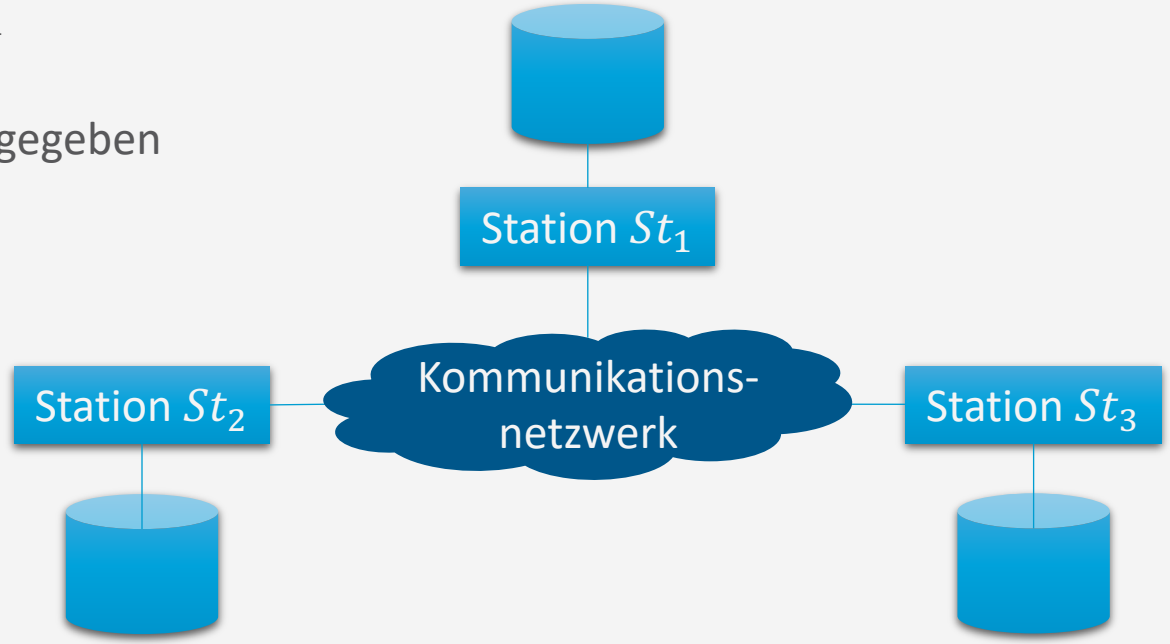

CAP-Theorem

- Welche der Eigenschaften nicht berücksichtigt wird, gilt nicht unbedingt systemweit
  - CAP Eigenschaften in der Regel nicht binär, sondern graduell
- CA-Systeme (Konsistenz und Verfügbarkeit)
  - Beispiel: relationale Datenbank mit verteilten Transaktionen
  - Voraussetzung: Verbindung zwischen den Knoten besteht; sonst Schreiben ggf. blockieren
- CP-Systeme (Konsistenz und Ausfalltoleranz)
  - Beispiel: Bank-Anwendungen
  - Hohe Verfügbarkeit bei lesenden Operationen, bei Unterbrechung der Netzwerkverbindung geringere Verfügbarkeit
- AP-Systeme (Verfügbarkeit und Ausfalltoleranz)
  - Beispiel: Domain Name System (DNS)
  - Hohe Verfügbarkeit bei schreibenden und lesenden Operationen, eingeschränkte Konsistenz

Konsistenzmodell: ~~C~~AP

Not-only SQL (NoSQL)-Datenbanken verzichten zeit- bzw. teilweise auf Konsistenz und betonen Verfügbarkeit und Ausfalltoleranz

- Relaxiertes Konsistenzmodell:
  - Basically Available, Soft State, Eventually Consistent (BASE)
    - Ordnet Konsistenz der Verfügbarkeit unter
      - Konsistenz kein fester Zustand nach einer Transaktion, wird später erreicht
    - Replizierte Daten haben nicht alle den neuesten Zustand
      - Vermeidung des (teuren) Zwei-Phasen-Commit-Protokolls (später)
      - Transaktionen könnten veraltete Daten zu lesen bekommen
    - Eventual Consistency
      - Würde man das System anhalten, würden alle Kopien irgendwann in denselben Zustand übergehen
  - Read your Writes-Garantie
    - T_i leistet auf jeden Fall ihre eigenen Änderungen
  - Monotonic Read-Garantie
    - T_i würde beim wiederholten Lesen keinen älteren Zustand als den vorher mal sichtbaren lesen

Zwischenzusammenfassung

- Fragmentierung: Verteilung der Daten in Fragmente
  - Horizontal, vertikal, gemischt (hor. + vert.), abgeleitet (i.d.R. über Fremdschlüssel)
  - Korrektheit: Rekonstruierbarkeit, Vollständigkeit, Disjunktheit
- Replikation: Erhöhung der Verfügbarkeit / Effizienz
  - Nachteil: Daten müssen konsistenz gehalten werden
- Allokation: Physische Zuordnung auf Stationen (lokale DBs)
- Transparenz
  - Fragmentierungstransparenz, Allokationstransparenz, lokale Schema-Transparenz
  - Von nur globales Schema genutzt bis hin zu lokale Stationen müssen bekannt sein
- CAP: Konsistenz, Verfügbarkeit, Ausfalltoleranz
  - CAP-Theorem: Nur zwei von drei Eigenschaften zur Zeit erreichbar

Überblick: 8. Verteilte Datenbanken

A. Verteilte DBMS
- Fragmentierung, Replikation, Allokation
- Transparenz
- CAP-Theorem

B. Anfragenbeantwortung in verteilten Systemen
- Anfrageverarbeitung
- Transaktionskontrolle, Sperrverwaltung, Deadlockvermeidung

C. Föderierte DBS
- Integration
- Migration

Anfrageübersetzung und Anfrageoptimierung

- Voraussetzung: Fragmentierungstransparenz
- Aufgabe des Operator-Evaluierers: 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

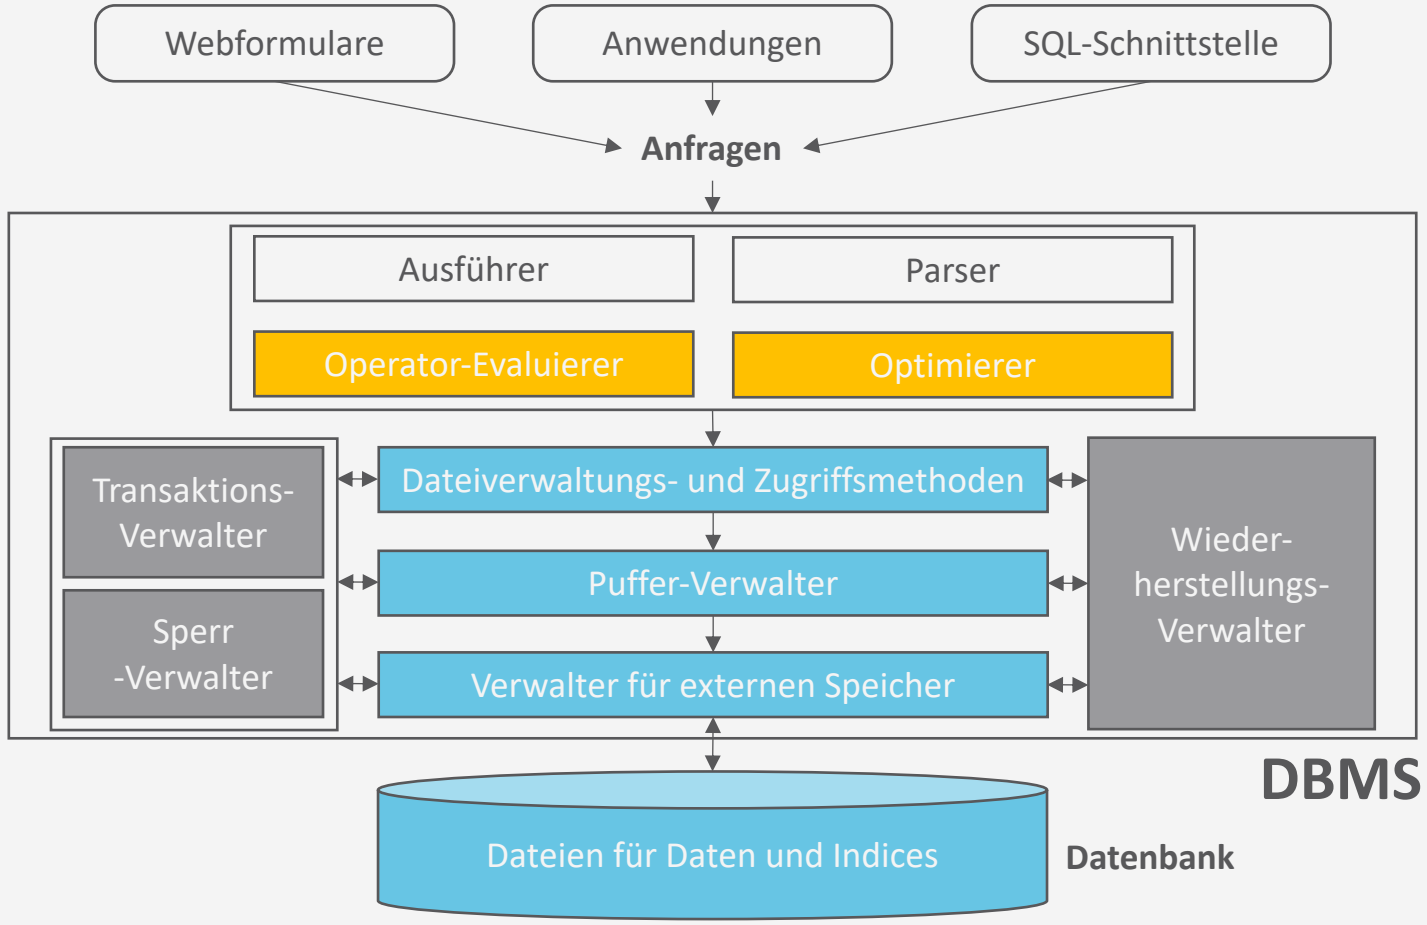

Anfragebearbeitung bei horizontaler Fragmentierung

- Übersetzung einer SQL-Anfrage auf dem globalen Schema in eine äquivalente Anfrage auf den Fragmenten benötigt zwei 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 = kanonische Form der Anfrage
  2. Kombination des Rekonstruktionsausdrucks mit dem algebraischen Anfrageausdruck, der sich aus der Übersetzung der SQL-Anfrage ergibt

Algebraischer Ausdruck: Beispiel

- Anfrage
  - ```
    select Titel, Name
    from Vorlesungen, Profs
    where Dozierende = PersNr and Rang='W3';
    ```
- Algebraischer Ausdruck in Baumform
  - I.e., kanonische Form der Anfrage

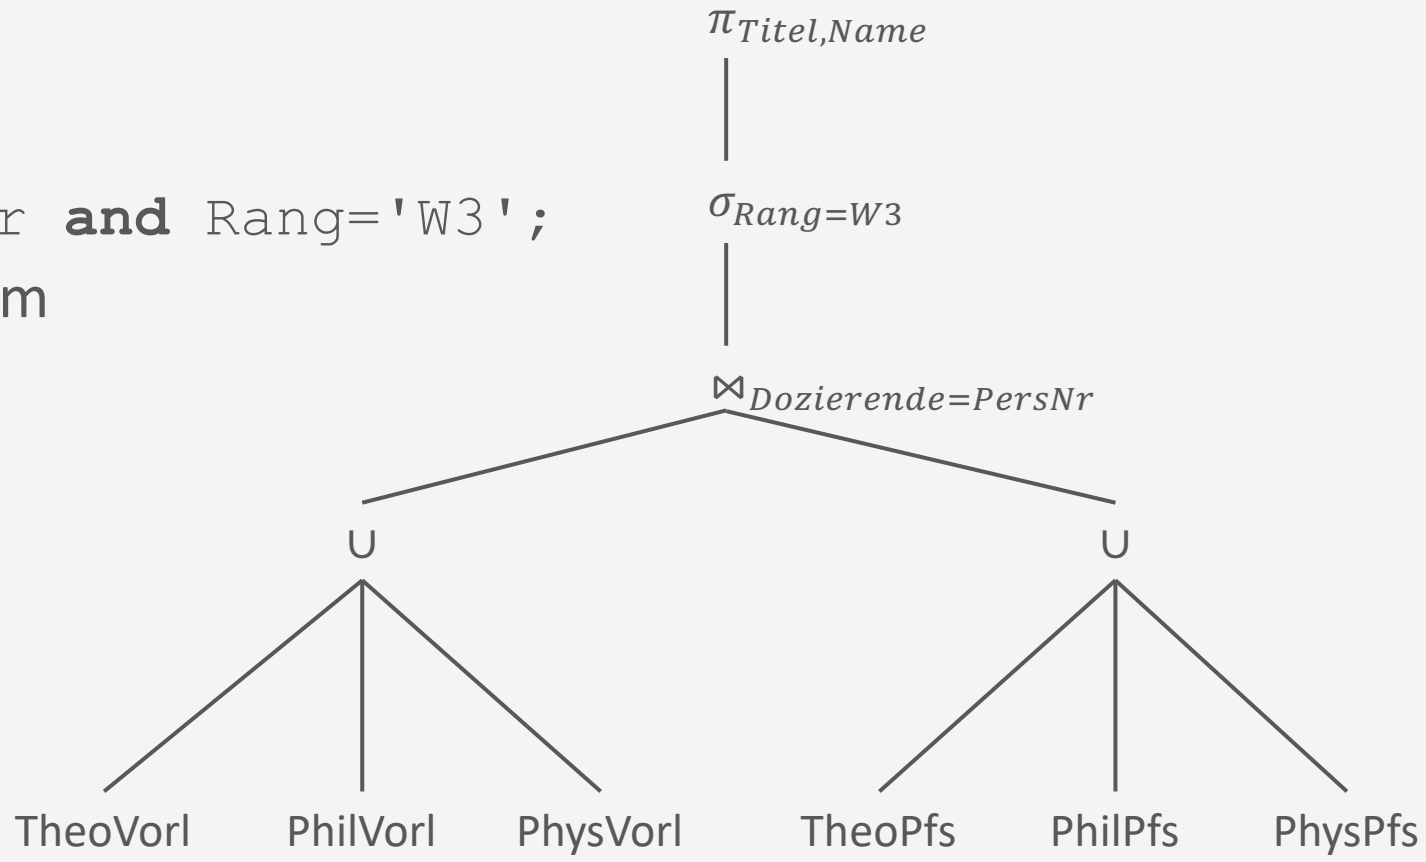
    ```

Algebraische Äquivalenzen

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

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

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

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

- Falls gilt $S_i = S \ltimes_p R_i$ mit $S = S_1 \cup \cdots \cup S_m$, dann gilt immer: $R \bowtie_p S = \bigcup_{i=1}^{m} (R_i \bowtie_p S_i)$
  - *Semi-Join* $\ltimes_p$: $T \ltimes_p U$ wählt diejenigen Tupel aus T, die ein Join-Tupel in U haben
    - Gegeben Attribute $A_1, \dots, A_k$ in T, $\ltimes_p$ ausdrückbar als: $T \ltimes_p U = \pi_{A_1,\dots,A_k}(T \bowtie_p U)$
  - Bei derart abgeleiteten horizontalen Fragmentierungen gilt somit immer:

$$(R_1 \cup \cdots \cup R_n) \bowtie_p (S_1 \cup \cdots \cup S_m) = (R_1 \bowtie_p S_1) \cup \cdots \cup (R_m \bowtie_p S_m)$$

Algebraischer Ausdruck: Beispiel

- Anfrage
  - ```
    select Titel, Name
    from Vorlesungen, Profs
    where Dozierende = PersNr and Rang='W3';
    ```
- Algebraischer Ausdruck in Baumform
  - I.e., kanonische Form der Anfrage
- Umformung: $p \triangleq Dozierende = PersNr$

$$(TheoVorl \cup PhilVorl \cup PhysVorl) \bowtie_p (TheoPfs \cup PhilPfs \cup PhysPfs)$$
$$= (TheoVorl \bowtie_p TheoPfs) \cup (PhilVorl \bowtie_p PhilPfs) \cup (PhysVorl \bowtie_p PhysPfs)$$

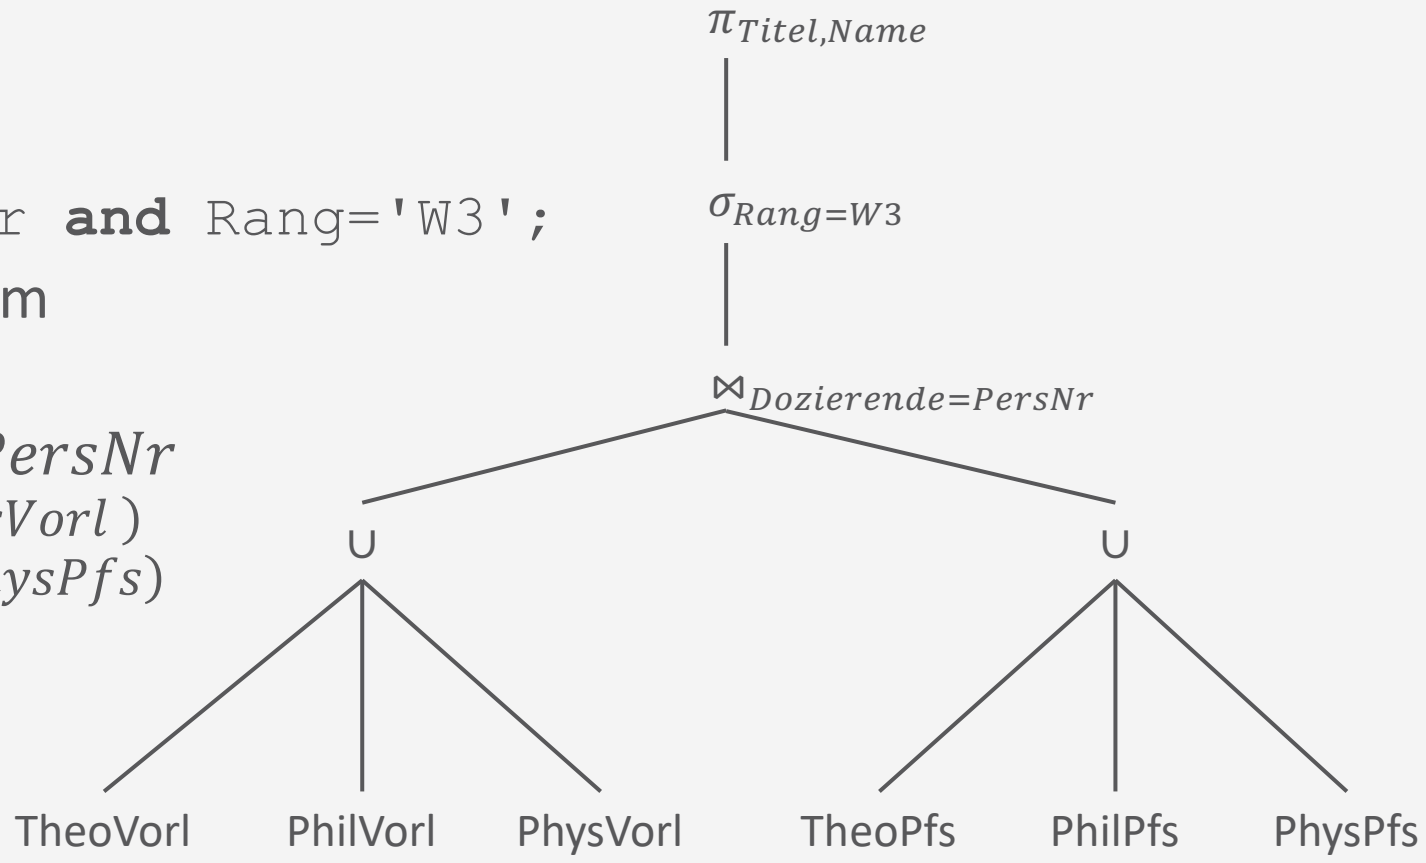
    ```

Optimale Form der Anfrage

- Selektionen und Projektionen über den Vereinigungsoperator hinweg „nach unten drücken“:
  - $\sigma_p(R_1 \cup R_2) = \sigma_p(R_1) \cup \sigma_p(R_2)$
  - $\pi_{List}(R_1 \cup R_2) = \pi_{List}(R_1) \cup \pi_{List}(R_2)$
- Ergibt folgenden Auswertungsplan:
  - Auswertungen lokal auf den Stationen St_{Theo}, St_{Phys} und St_{Phil} ausführen
    → Stationen können parallel abarbeiten und lokales Ergebnis voneinander unabhängig an die Station, die die abschließende Vereinigung durchführt, übermitteln

Lokale DB/Station	Bemerkung	Zugeordnete Fragmente
St_{Verw}	Verwaltungsrechner	{ProfVerw}
St_{Phil}	Dekanat Physik	{PhilVorl, PhilPfs}
St_{Phys}	Dekanat Philosophie	{PhysVorl, PhysPfs}
St_{Theo}	Dekanat Theologie	{TheoVorl, TheoPfs}

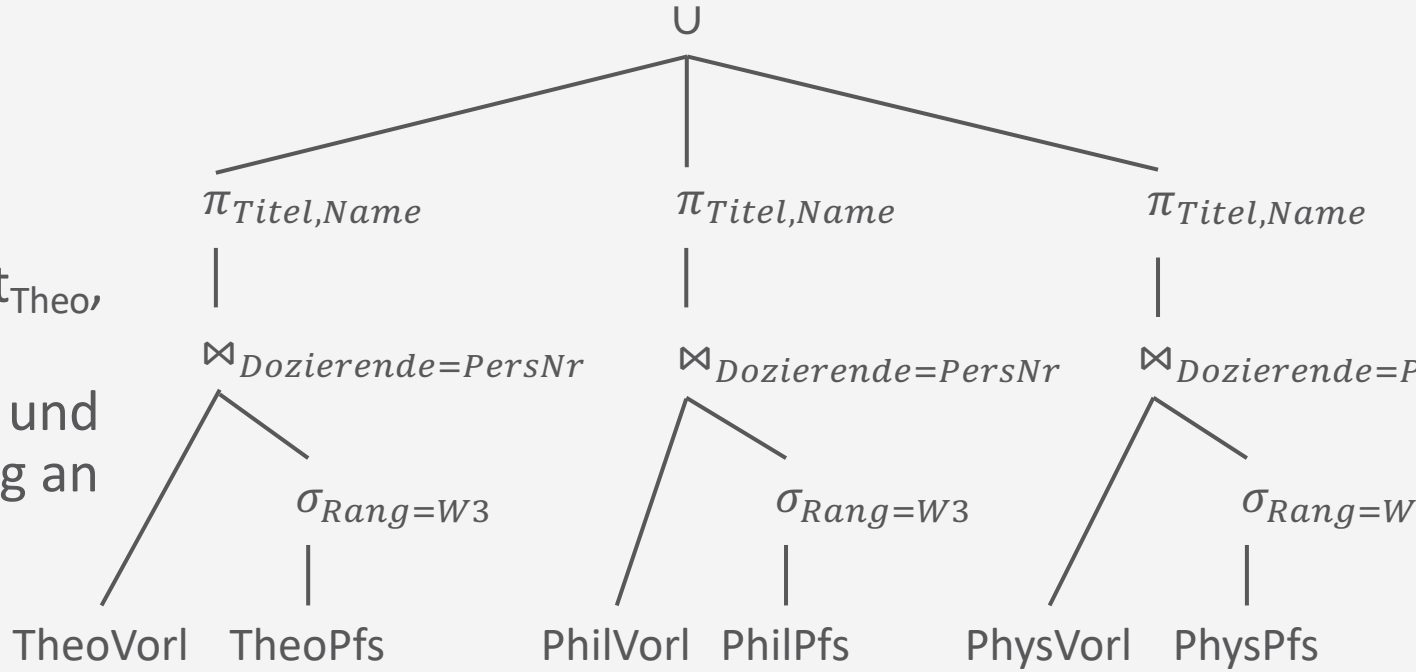

Anfragebearbeitung bei vertikaler Fragmentierung

- Beispiel mit kanonischem Auswertungsplan rechts:
  - **select** Name, Gehalt
    from Profs
    where Gehalt > 80000;
  - Alle notwendigen Informationen sind in ProfVerw enthalten → Teil mit Vereinigung und Join kann abgeschnitten werden
    - Das ergibt einen optimierten Auswertungsplan
    - Beispiel für schlecht zu optimierende Anfrage
      - Dazu noch Rang ausgeben wollen

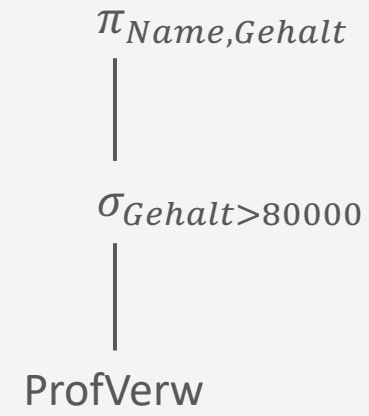

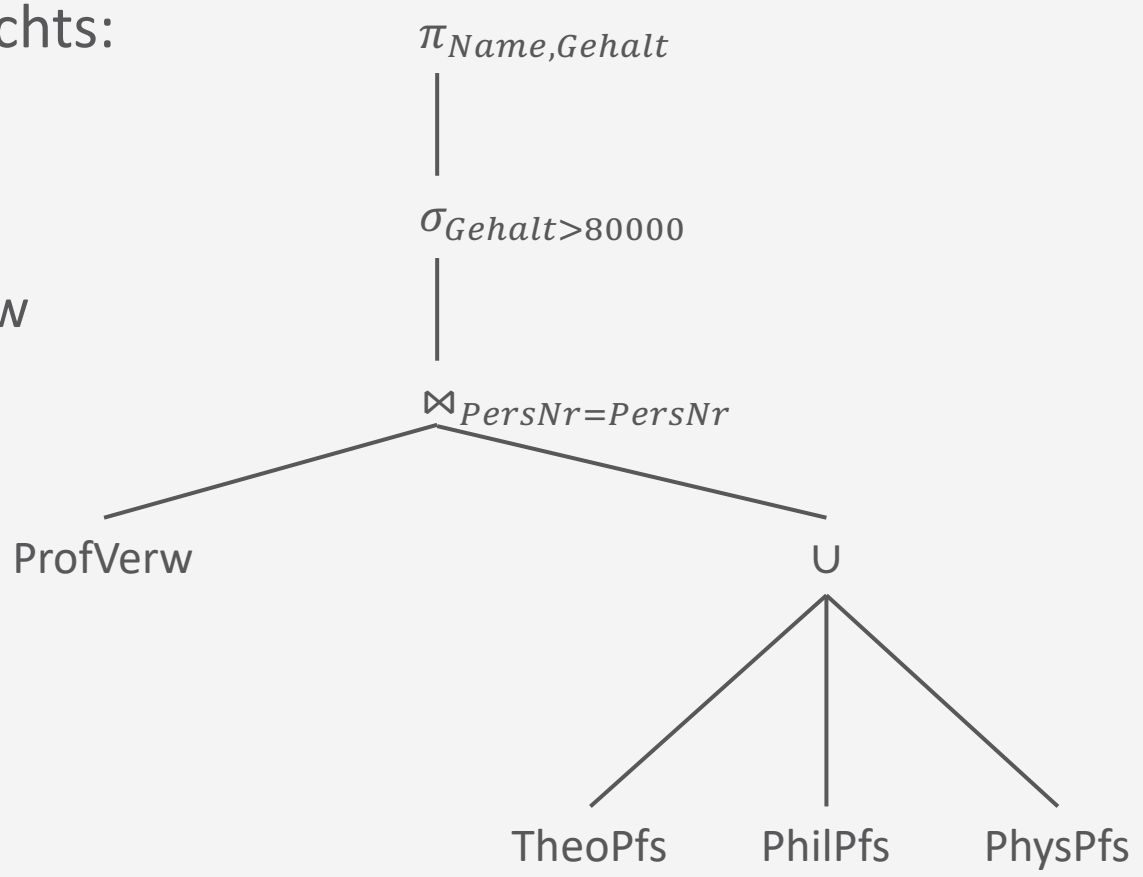

Join-Auswertung in VDBMS

- Join-Auswertung spielt kritischere Rolle als in zentralisierten Datenbanken
  - Problem: Argumente eines Joins zweier Relationen können auf unterschiedlichen Stationen liegen
  - Allgemeinster Fall:
    - 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
- Zwei Möglichkeiten: Join-Auswertung mit und ohne Filterung
  - Ohne Filterung: Nested-Loops, Transfer einer Argumentrelation, Transfer beider Argumentrelationen
  - Mit Filterung: Semi-Join zur Filterung

$R \bowtie S$

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

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

Nested-Loops

- Iteration durch die äußere Relation R mittels Laufvariable r und Anforderung des/der zu jedem Tupel r passenden Tupel $s \in S$ mit $r.C = s.C$ (über Kommunikationsnetz bei St_S)
  - C die Join-Variable
- 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 $2 \cdot |R|$ Nachrichten benötigt

$R \bowtie S$

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

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

$R \bowtie S$

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

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)

$R \bowtie S$

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

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-Auswertung mit Filterung

- Idee: Nur Transfer von Tupeln mit passendem Join-Partner über Semi-Join
  - Benutzung der folgenden algebraischen Eigenschaften:
    - Bei zwei Relationen R, S mit Filterung von S über Join-Attribut C
    - $R \bowtie S = R \bowtie (R \rtimes S)$
    - $R \rtimes S = \pi_C(R) \rtimes S$
  - Vorgehen
    1. Transfer der unterschiedlichen C-Werte von R $(= \pi_{List}(R))$ nach St_S
    2. Auswertung des Semi-Joins $R \rtimes S = \pi_C(R) \rtimes S$ 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 $\|R\|$ = Größe (in Byte) einer Relation

$R \bowtie S$

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

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

Beispiel

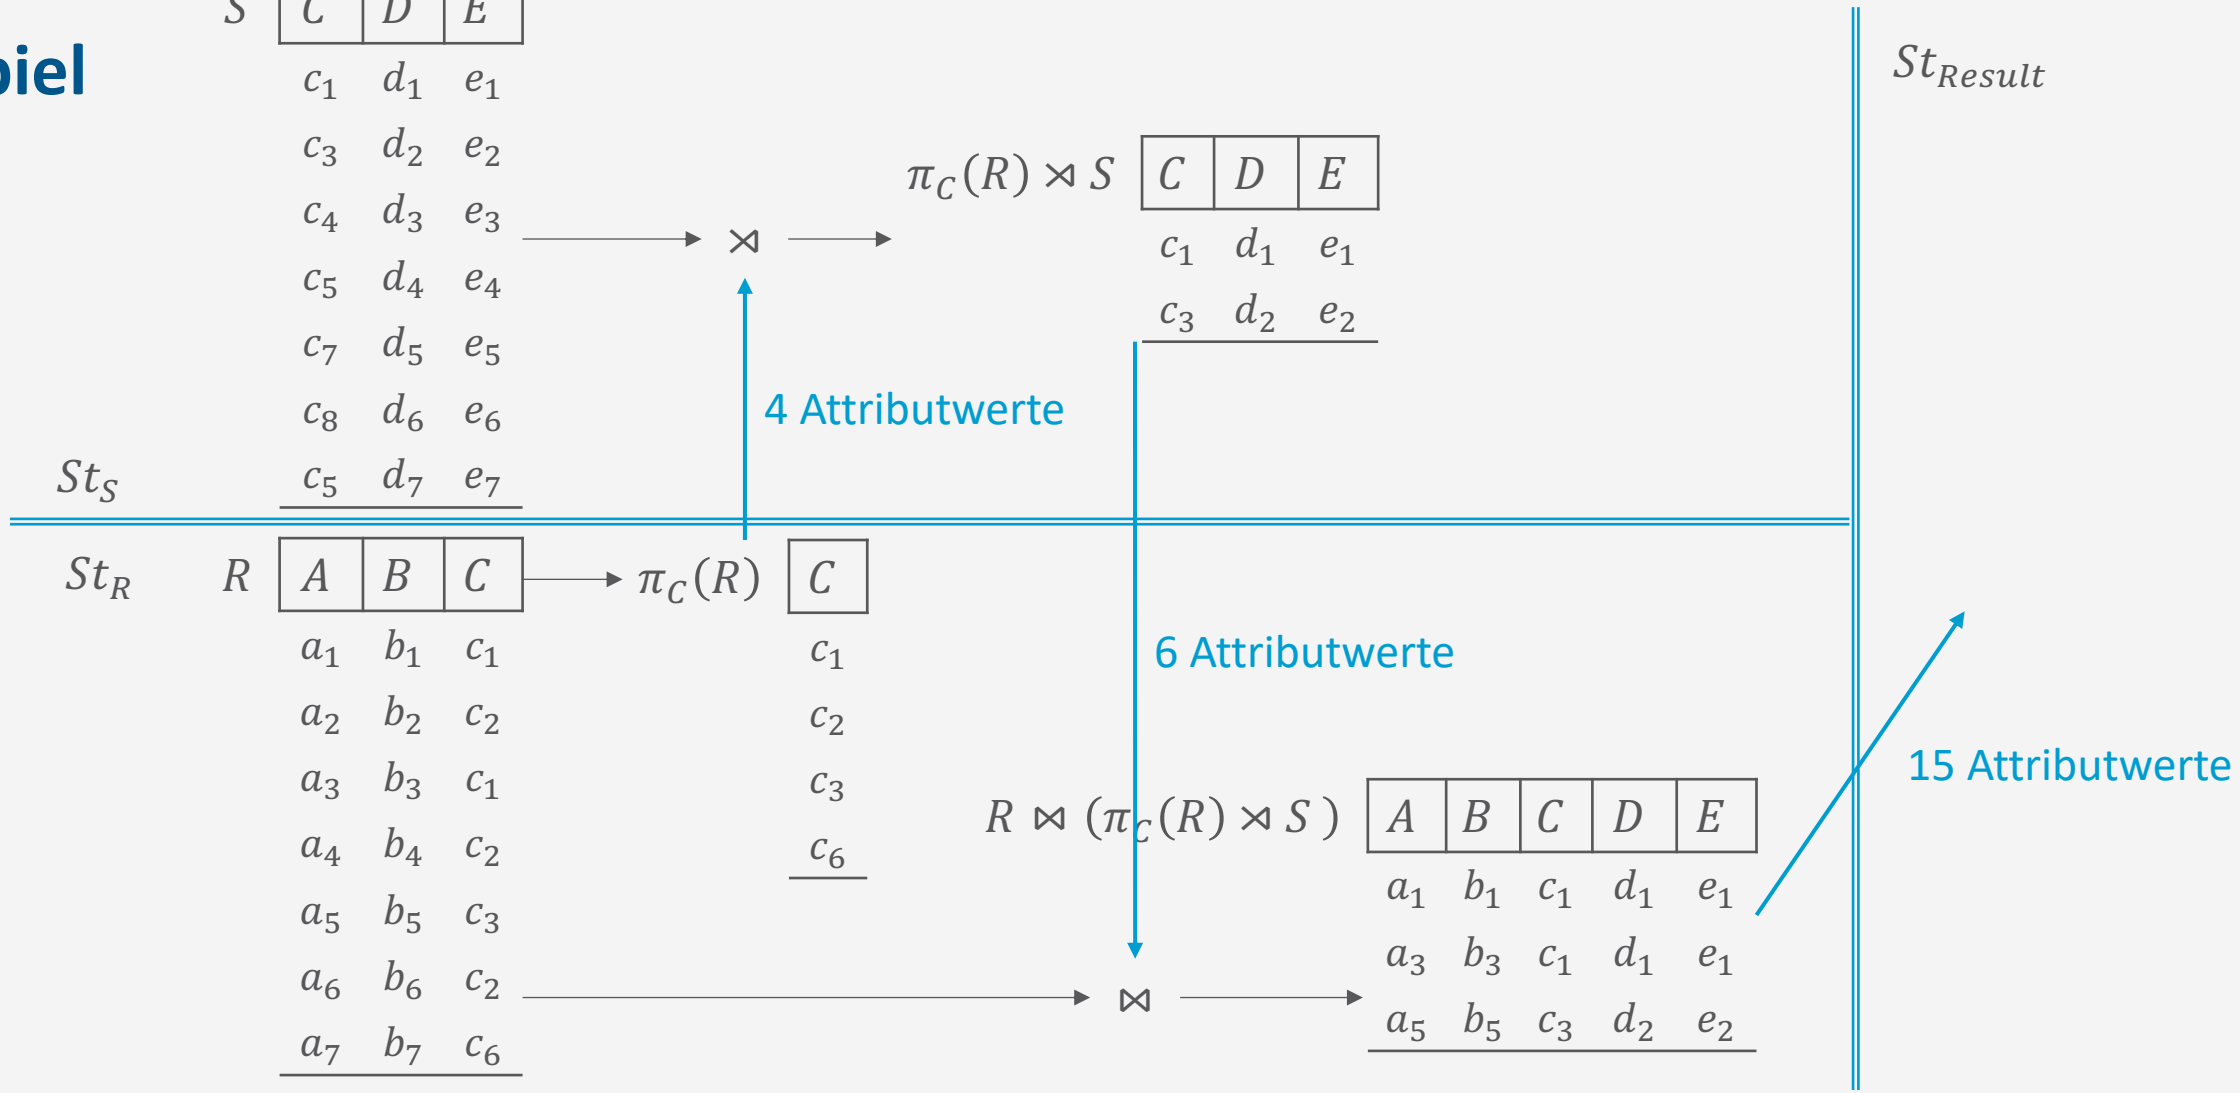
St_{Result}
St_S
St_R
S
C D E
c_1 d_1 e_1
c_3 d_2 e_2
c_4 d_3 e_3
c_5 d_4 e_4
c_7 d_5 e_5
c_8 d_6 e_6
c_5 d_7 e_7
$\pi_C(R) \bowtie S$
C D E
c_1 d_1 e_1
c_3 d_2 e_2
$\bowtie$
4 Attributwerte
R
A B C
a_1 b_1 c_1
a_2 b_2 c_2
a_3 b_3 c_1
a_4 b_4 c_2
a_5 b_5 c_3
a_6 b_6 c_2
a_7 b_7 c_6
$\pi_C(R)$
C
c_1
c_2
c_3
c_6
6 Attributwerte
$R \bowtie (\pi_C(R) \bowtie S)$
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
$\bowtie$
15 Attributwerte

Parameter für die Kosten eines Auswertungsplan

- Kardinalitäten von Argumentrelationen
  - Wie bisher
- Selektivitäten von Joins und Selektionen
  - Wie bisher
- *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.

Transaktionsmanagement in VDBMS

- Transaktionen können sich bei VDBMS über mehrere Rechnerknoten erstrecken

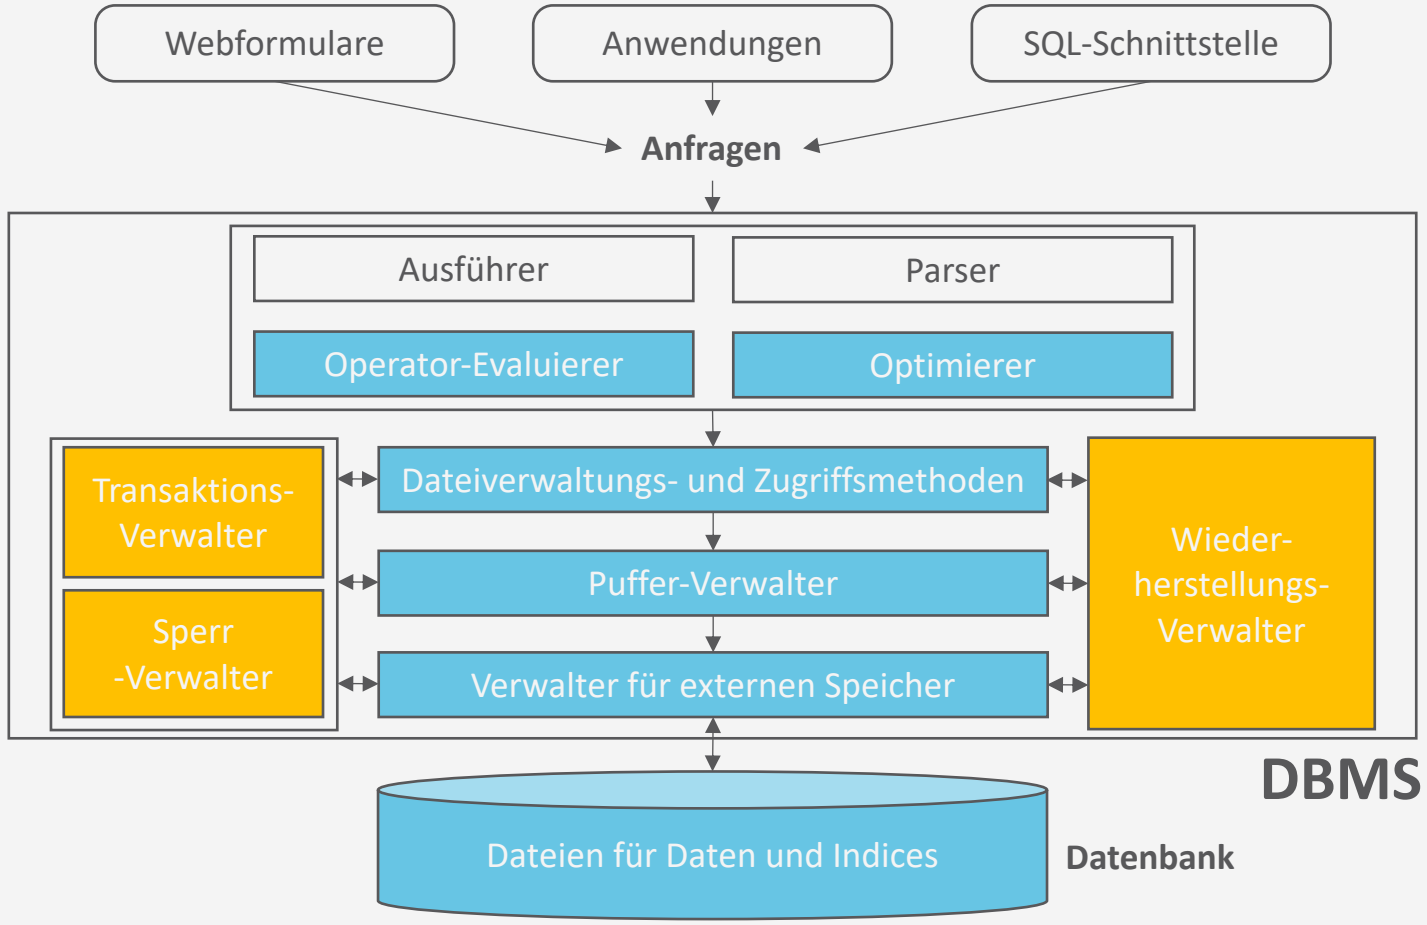

Widerherstellungsverwaltung in VDBMS

- 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: Zwei-Phasen-Commit-Protokoll

- Zwei-Phasen-Commit-Protokoll (2PC) gewährleistet Atomarität der EOT-Behandlung
- 2PC-Verfahren wird von sogenanntem Koordinator K überwacht
- Gewährleistet, dass die n Agenten (Stationen im VDBMS) $A_1, \ldots, A_n$, 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:

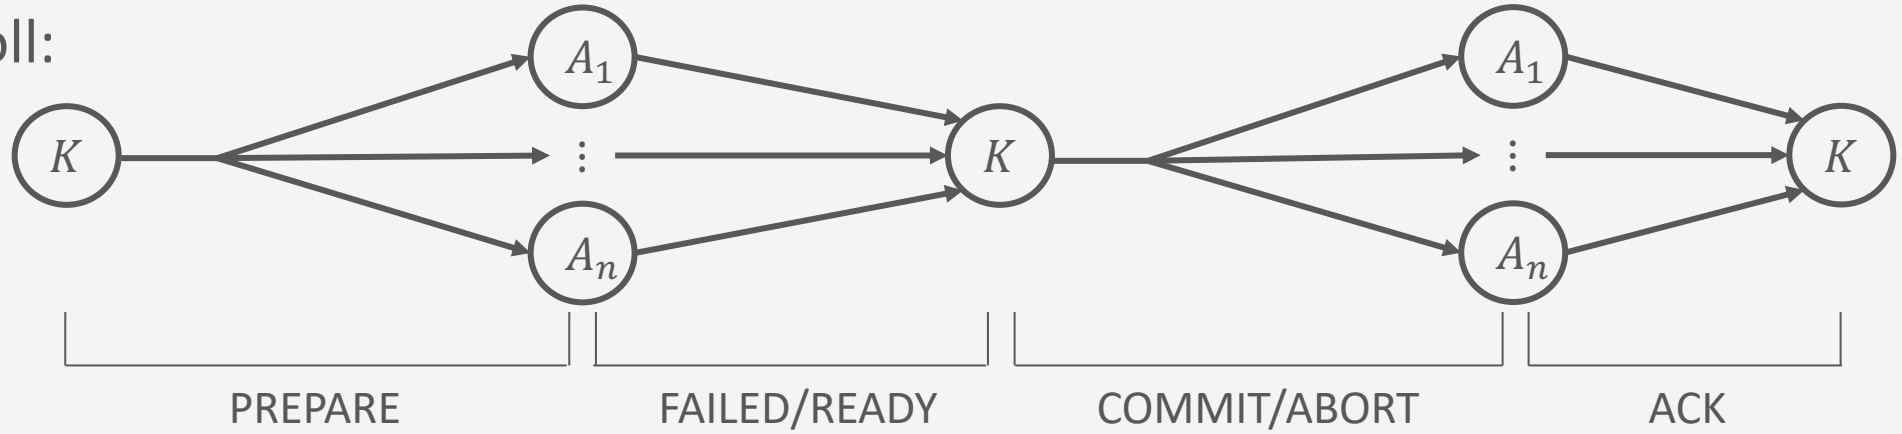

Ablauf der EOT-Behandlung beim 2PC-Protokoll

- 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 oder 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

Zustandsübergang beim 2PC-Protokoll: Koordinator

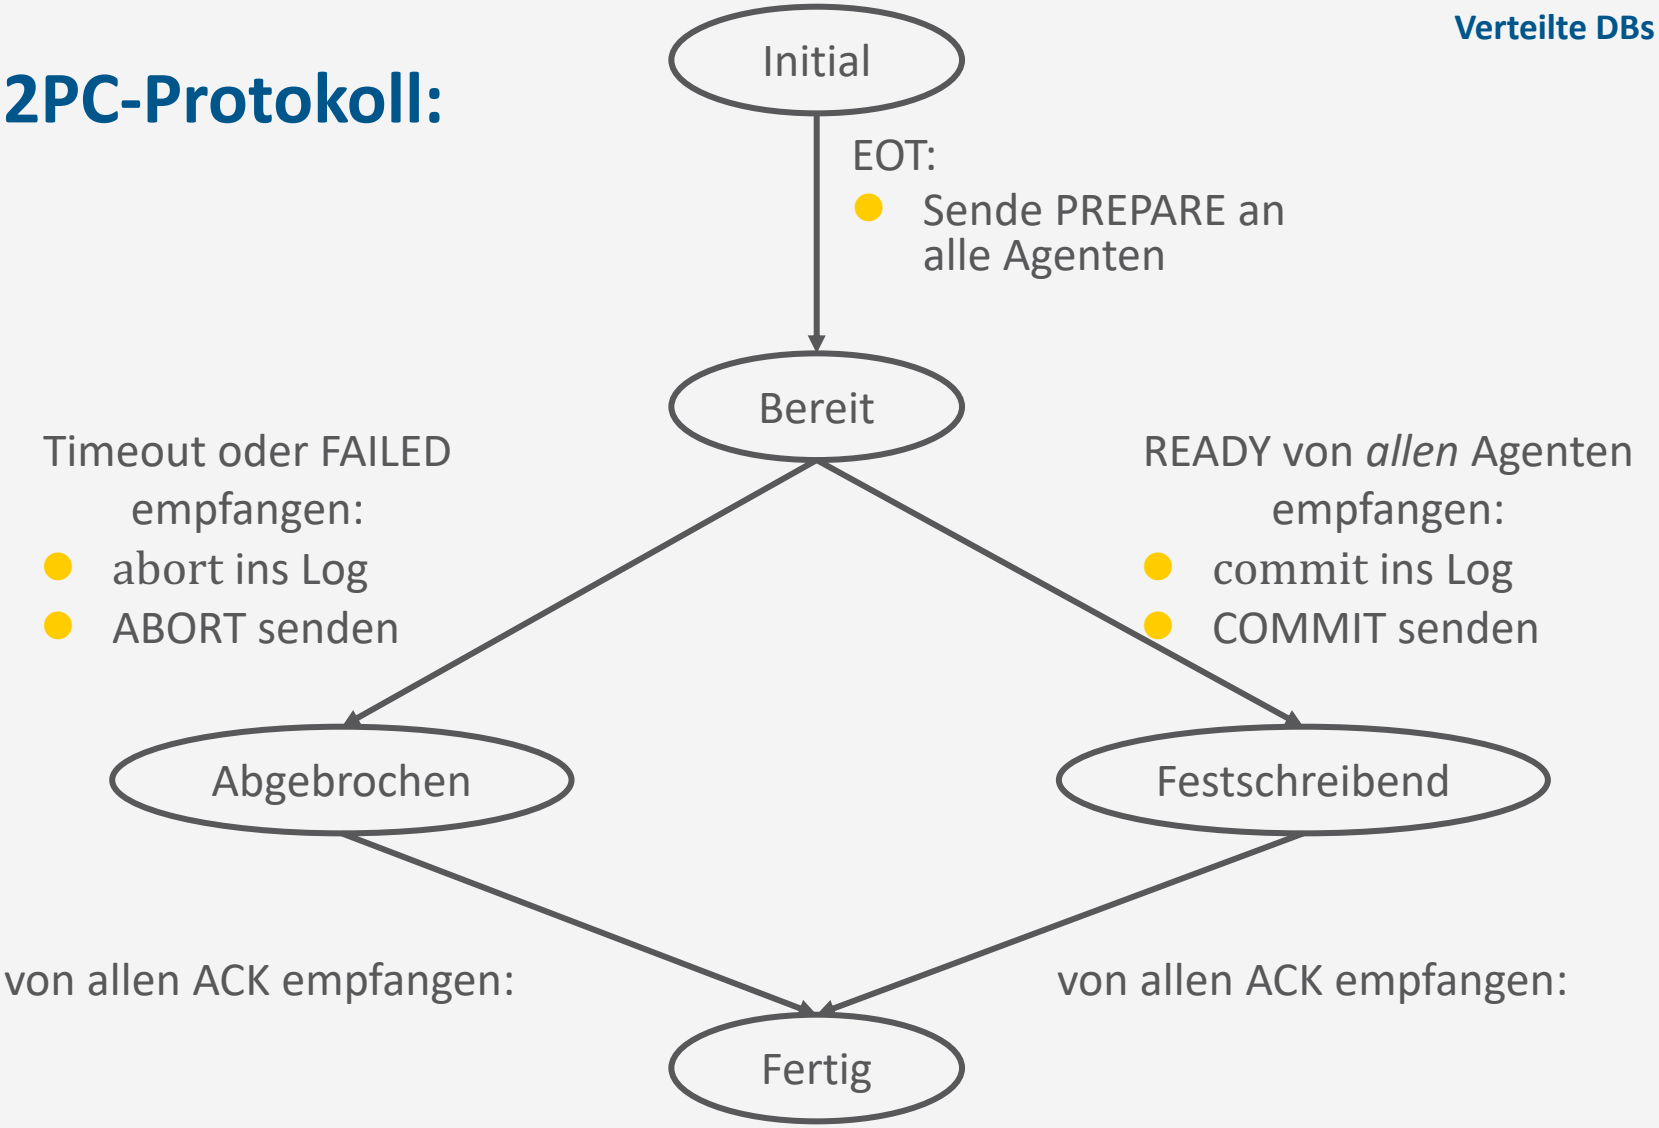

„Bullet“ ●
= wichtigste Aktion(en)

Zustandsübergang beim 2PC-Protokoll: Agent

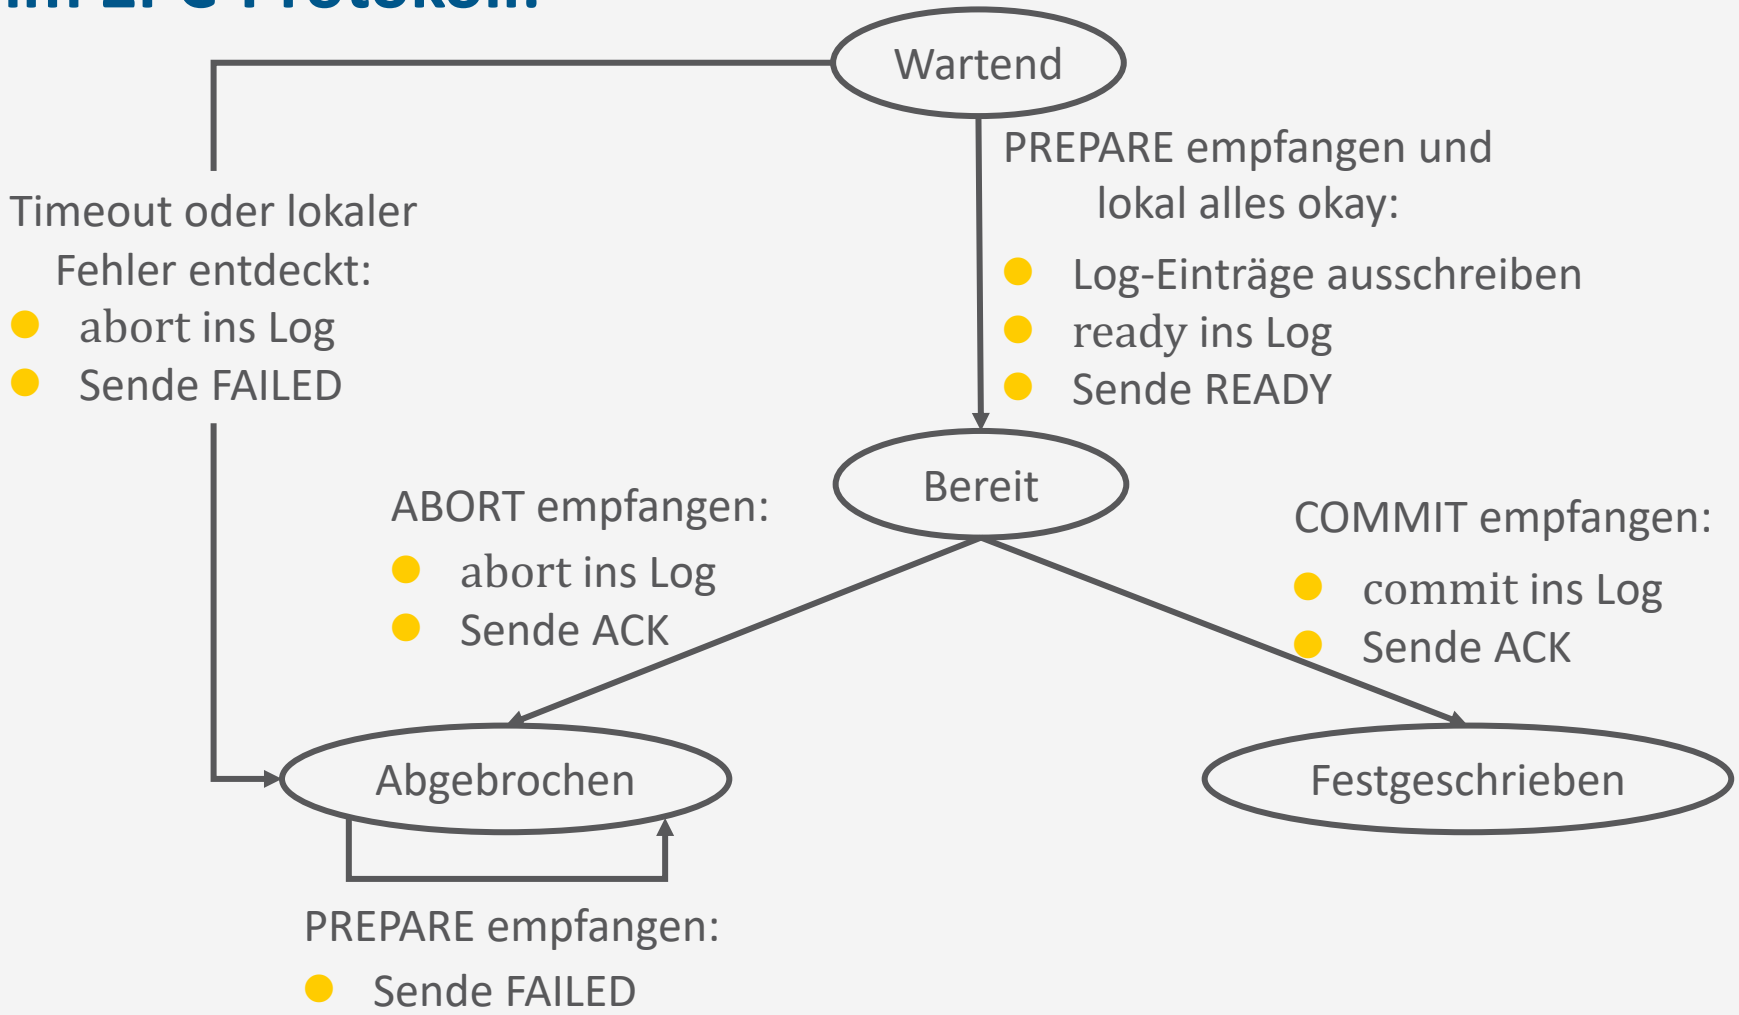

„Bullet“ ●
= wichtigste Aktion(en)

Problemlösung: Zweiphasen-Commit-Protokoll

1. Transaktion kann nicht durchgeführt werden
2. Station crasht, bevor READY gesendet wird (timeout bei K)
3. Station crasht, bevor COMMIT empfangen wird
   - Nach Restart bei K anfragen, ob undo / redo der Transaktion

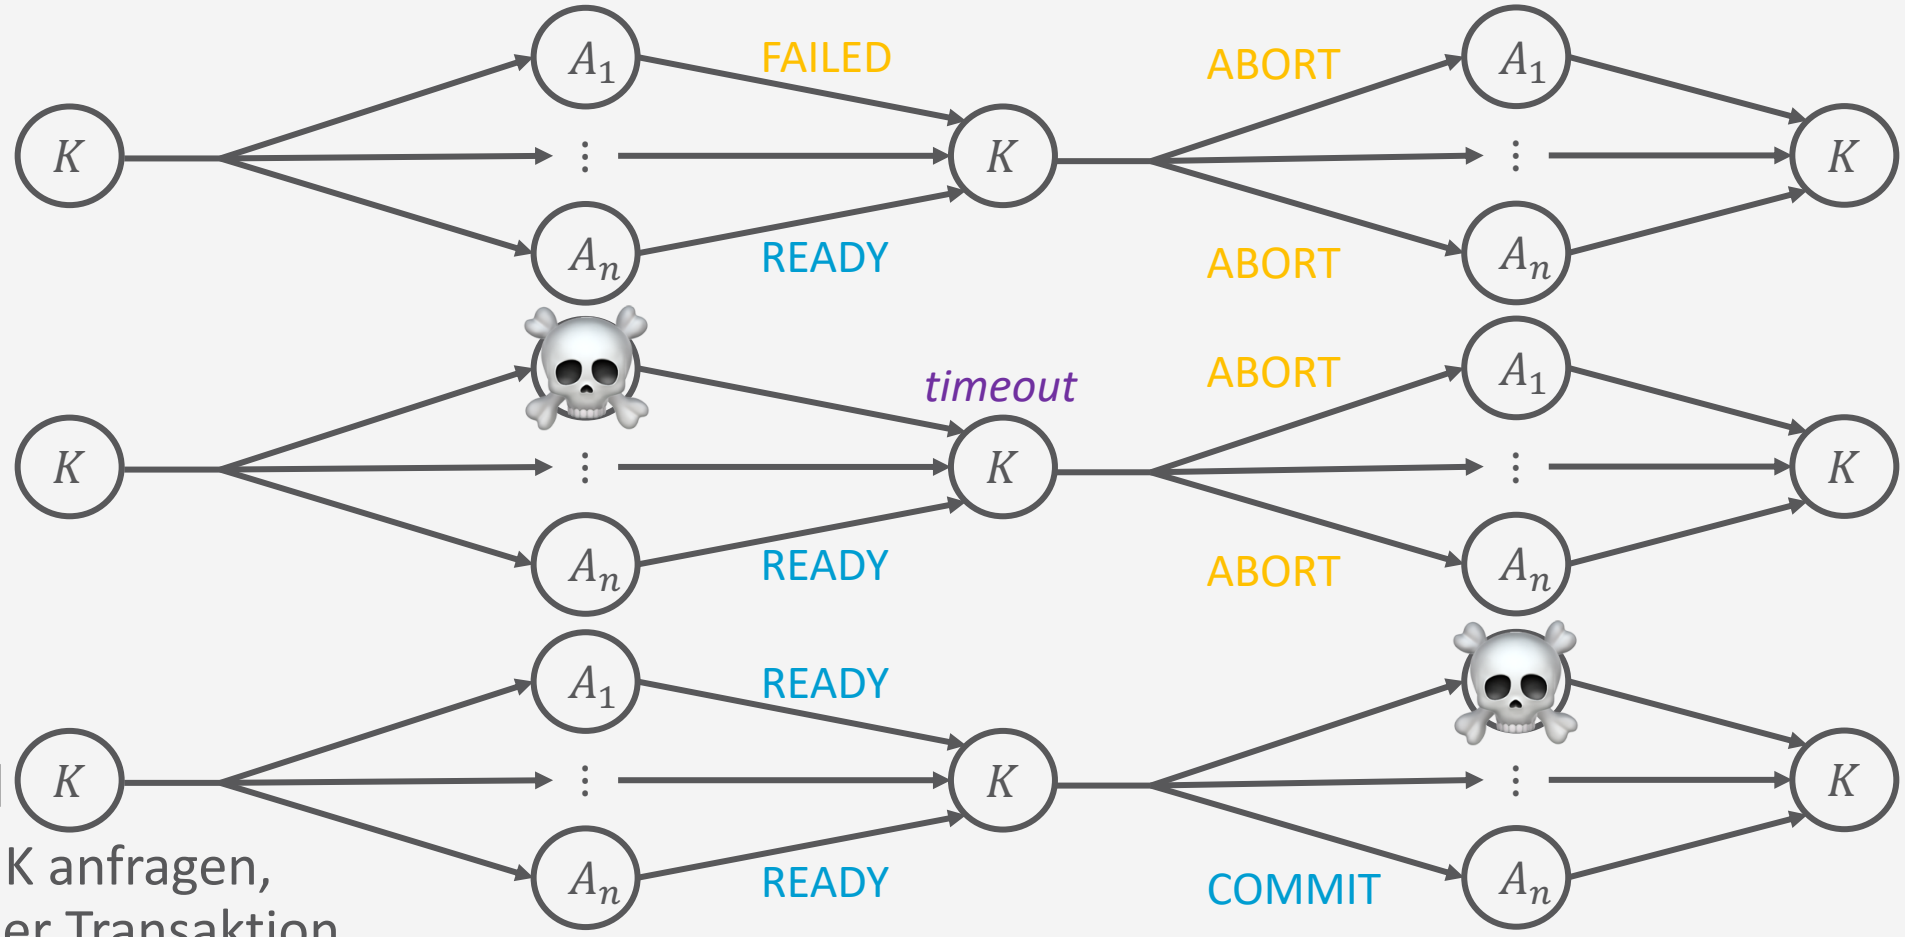

Absturz eines Agenten

- 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 (ACK senden)

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 anderer 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)

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)

2PC-Protokoll ohne Koordinator

- Lineare Organisationsform: Reihenfolge der Agenten festlegen
- Nacheinander kommunizieren
  1. Agenten reichen ihren eigenen Status und den der vorherigen Nachbarn an den nächsten weiter, nachdem sie den entsprechenden Statusbericht vom Vorgänger bekommen haben
  2. Der letzte Agent trifft die Entscheidung und reicht sie zurück

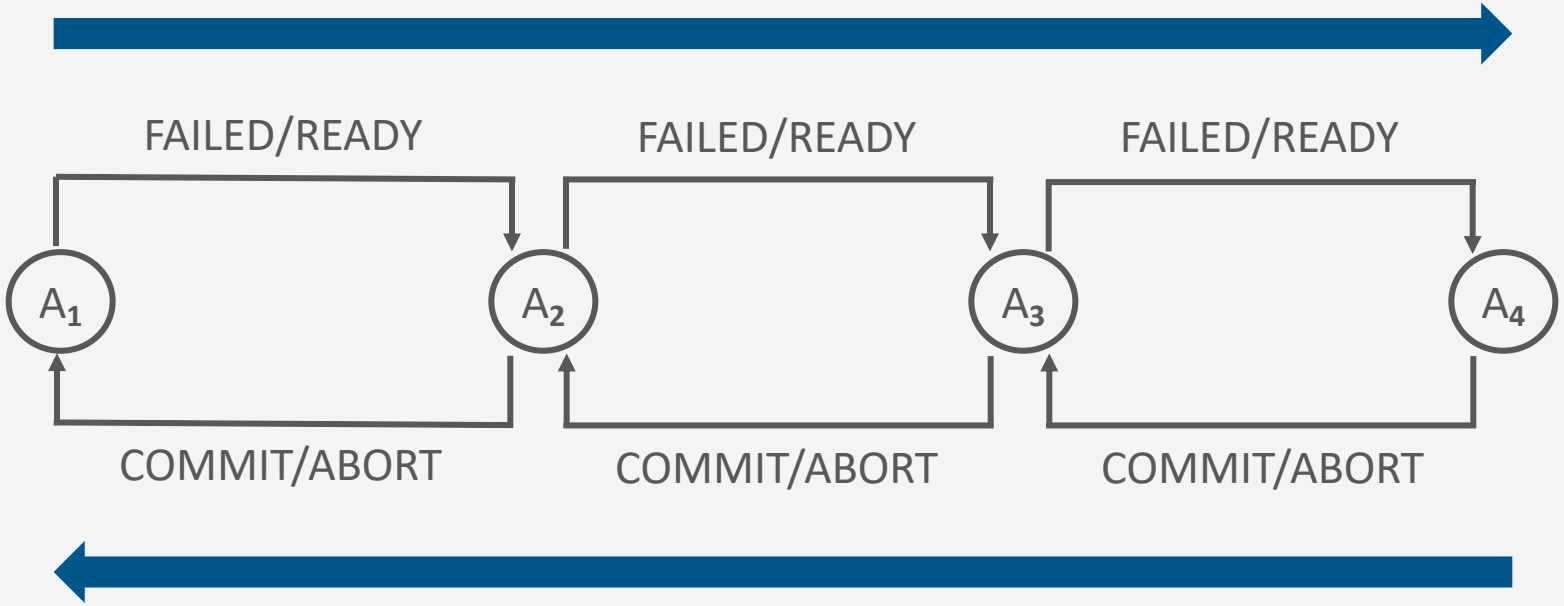

Mehrbenutzersynchronisation in VDBMS

- 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
      - St_1: lokal ausgeführte Operationen seriell ausgeführt
      - St_2: lokal ausgeführte Operationen seriell ausgeführt
    - Global nicht serialisierbar
      - p_i^a: a identifiziert die Station, i die Transaktion
      - Schedule: $r_1^1(X), w_2^1(X), w_2^2(X), r_1^2(X)$
      - Nicht umformbar zu seriellen Schedule

St_1	T_1	T_2
1	$r(X)$	
2		$w(X)$

St_2	T_1	T_2
3		$w(Y)$
4	$r(Y)$	

Sperrverwaltung in VDBMS

- Lokale Sperrverwaltung: Globale Transaktion muss vor Zugriff / Modifikation eines Datums X, 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
    - Verletzung der lokalen Autonomie der Stationen, da auch lokale Transaktionen ihre Sperren bei der zentralisierten Sperrverwaltung anfordern müssen

  → Zentrale Sperrverwaltung im Allgemeinen nicht akzeptabel

Deadlocks in VDBMS

- Erkennung von Deadlocks (Verklemmungen)
  - Beispiel: Verteilter Deadlock
    - T_2 bei St_2 wartet auf Freigabe von X bei St_1
    - T_1 bei St_1 wartet auf Freigabe von Y bei St_2
    - Lokale Wartegraphen: zyklenfrei

    - Globaler Wartegraph: mit Zyklus

- Vorgehen zur Erkennung:
  - Timeout, zentralisiert, dezentral

Erkennung von Deadlocks: Wartegraph

- Wartegraph: Gerichteter Graph
  - Enthält für jede aktive Transaktion T_i einen Knoten
  - Wenn T_i auf eine Sperre von T_j wartet:
    - Füge Kante $(T_i \longrightarrow T_j)$ in den Graphen ein (Kante bei Freigabe löschen)
  - Weist der Wartegraph Zyklen auf, so liegt ein Deadlock vor

St_1	T_1	T_2
0	BOT	
1	$lockS(X)$	
2	$r(X)$	
6		$lockX(X)$
		...

St_2	T_1	T_2
3		BOT
4		$lockX(Y)$
5		$w(Y)$
7	$lockS(Y)$	
	...	

Erkennung von Deadlocks: 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

St_1	T_1	T_2
0	BOT	
1	$lockS(X)$	
2	$r(X)$	
6		$lockX(X)$
		...

St_2	T_1	T_2
3		BOT
4		$lockX(Y)$
5		$w(Y)$
7	$lockS(Y)$	
	...	

Zentralisierte Deadlock-Erkennung

- Stationen melden lokal vorliegende Wartebeziehungen an neutralen Knoten, der daraus globalen Wartegraphen aufbaut (Zyklus im Graphen → Deadlock)
  - Sichere Lösung
  - Beispiel: Globaler Wartegraph

- Nachteile:
  - Hoher Aufwand (viele Nachrichten)
  - Entstehung von Phantom-Deadlocks (= nicht-existierende Deadlocks) durch Überholen von Nachrichten im Kommunikationssystem

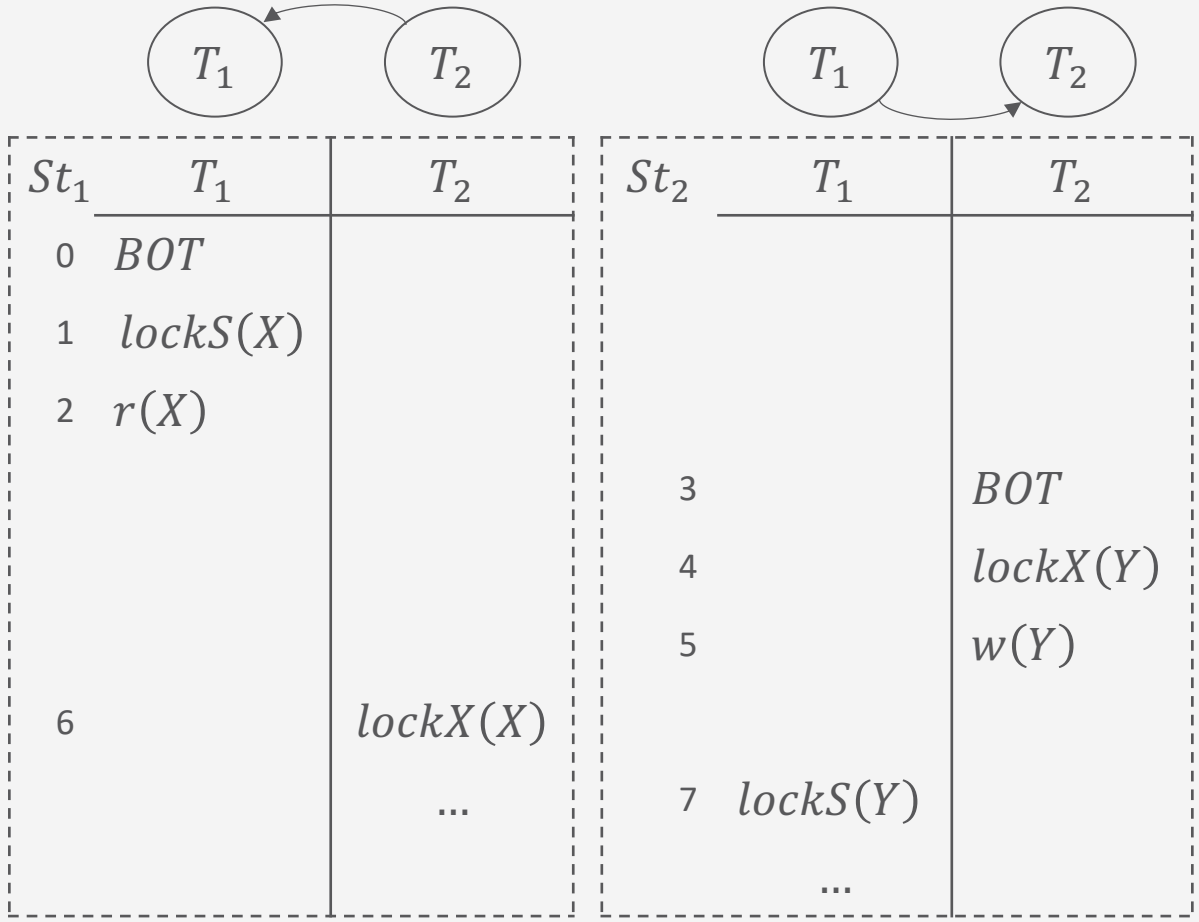

Dezentrale Deadlock-Erkennung: Obermarck‘s Path Pushing Algorithmus

- Zur Erkennung von globalen Deadlocks
- Zuordnung jeder Transaktion zu einem Heimatknoten (Station), von wo aus externe Subtransaktionen auf anderen Stationen initiiert werden
  - Globale Ordnung der Transaktionen (z.B. eindeutiger String mit lexikographischer Ordnung)
- Jede Station hat einen lokalen Wartegraphen, erweitert um einen Knoten Ext (*external*)
  - Ext modelliert die stationenübergreifenden Wartebeziehungen zu externen Subtransaktionen
- Formal: Wartegraph G mit initial
  - Für jede Transaktion T_i ein Knoten T_i (beheimatete und fremde) mit Kanten wie bisher
    - Kante $T_i \rightarrow T_j$, wenn T_i auf T_j wartet
  - Dazu einen Knoten Ext mit Kanten wie folgt
    - Kante $Ext \rightarrow T_i$ für jede von außen kommende Transaktion T_i
    - Kante $T_j \rightarrow Ext$ für jede Transaktion T_j dieser Station, falls T_j nach außen geht

Dezentrale Deadlock-Erkennung: Obermarck‘s Path Pushing Algorithmus

- Vorgehen an jeder Station (asynchron)
  1. Einkommende Informationen aus Schritt 3 von anderen Stationen einbauen
     - Gestoppte Transaktionen T_a und deren Kanten löschen
     - Knoten T_i für unbekannte T_i und Kanten einfügen aus Pfaden, die nicht T_a beinhalten
  2. Liste von elementaren Zyklen in Wartegraph erstellen
     - Elementare Zyklen: Zyklen, so dass keine Subzyklen enthalten sind
  3. Zyklen bearbeiten
     - Lokale Zyklen (ohne Ext Beteiligung) beheben durch Stoppen von Transaktionen
       - Entferne Knoten T_i sowie verbundene Kanten aus Wartegraph, lösche Zyklen mit T_i aus Liste
       - Falls T_i verteilt ausgeführte Transaktion, Information an andere Stationen senden
     - Für alle Zyklen $Ext \rightarrow T_1 \rightarrow T_2 \rightarrow \cdots \rightarrow T_n \rightarrow Ext$:
       - Pfad an Stationen schicken, die Subtransaktionen von T_n gestartet haben
       - Nachrichtenaufkommen reduzieren: Nur schicken, wenn $T_1 \prec T_n$

Dezentrale Deadlock-Erkennung: Beispiel

- St_1 Heimatknoten von T_1, St_2 Heimatknoten von T_2; Ordnung $T_1 \prec T_2$
  - Wartegraphen

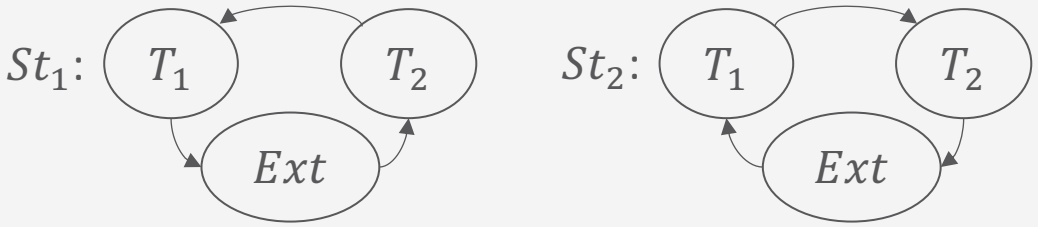

  - St_1 Pfad $Ext \rightarrow T_2 \rightarrow T_1 \rightarrow Ext$: $T_1 \prec T_2$
  - St_2 sendet Pfad $Ext \rightarrow T_1 \rightarrow T_2 \rightarrow Ext$ an St_1
    - St_1: Lokaler Zyklus
      → T_1 stoppen
      → Zyklenfrei
      → Info über T_1 an St_2

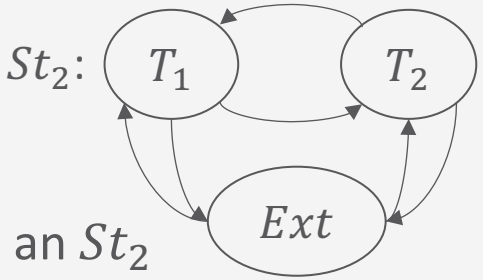

  - St_1 sendet stop von T_1 an St_2
    - Nach Einbau Wartegraph zyklenfrei

St_1	T_1	T_2
0	BOT	
1	$lockS(X)$	
2	$r(X)$	
6		$lockX(X)$
		…

St_2	T_1	T_2
3		BOT
4		$lockX(Y)$
5		$w(Y)$
7	$lockS(Y)$	
	…	

Dezentrale Deadlock-Erkennung

- Path Pushing Algorithmus hat seine Nachteile
  - Viele Nachrichten, Phantom-Deadlocks
- Weitere Ansätze, aber weiterhin offenes Forschungsproblem
  - Edge Chasing (entlang virtueller Kanten des Wartegraphen)
    - Wartende Transaktion sendet eine Nachricht an die Transaktion, auf die sie wartet
    - Transaktion leitet solch eine Nachricht an andere Transaktionen weiter, auf die sie selber wartet
    - Kommt die Nachricht an die Initiatorin zurück → Deadlock / Zyklus
  - Deadlock Detection Agents (DDAs)
    - DDA zuständig für eine Zusammenhangskomponente (ZHK) in einem Wartegraphen
    - Wenn Kante dazukommt, die ZHKs verbindet, verschmilzt jüngerer DDA mit älterem DDA
    - Irgendwann wird die gesamte ZHK des Wartegraphen (in der sich der Zyklus befindet) in einem DDA landen, der den Zyklus dann entdeckt

Deadlock-Vermeidung

- Optimistische Mehrbenutzersynchronisation:
  Nach Abschluss der Transaktionsbearbeitung wird Validierung durchgeführt
- Zeitstempel-basierte 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 (wie vorher)
  - wait/die: Nur ältere Transaktionen warten auf jüngere (wie vorher)
- Voraussetzungen für Deadlockvermeidungsverfahren:
  Vergabe global eindeutiger Zeitstempel als Transaktionsidentifikatoren
  - Lokale Uhren müssen hinreichend genau aufeinander abgestimmt sein

Synchronisation bei replizierten Daten: Read One, Write All (ROWA)

- Zu einem Datum X gibt es Kopien $X_1, \ldots, X_n$, die auf unterschiedlichen Stationen liegen
- Eine logische Leseoperation auf einer beliebigen Kopie durchführen
  - Z. B. die am nächsten Netzwerk verfügbare Kopie
- Eine logische Schreiboperation wird zu physischen Schreiboperationen auf allen Kopien
  - Synchrones Schreiben aller Kopien in derselben Transaktion
  - 2PL sperrt alle Kopien von X
  - 2PC um ein Commit für die Schreiboperation atomar auf allen Kopien durchzuführen
- Vorteil: Sehr einfach zu implementieren, da es nahtlos mit den Protokollen zusammenpasst; effizientes Lesen; alle Kopien auf gleichem Stand
- Nachteil: Hohe Laufzeit, Verfügbarkeitsprobleme (alle kopienhaltenden Stationen stehen in Abhängigkeit; Änderungstransaktionen werden n mal so lang → hohe Deadlock-Rate)

Synchronisation bei replizierten Daten: Quorum-Consensus Verfahren

- Idee: Änderung auf einer Kopie wird nur dann ausgeführt, wenn die Transaktion in der Lage ist, die Mehrheit der Kopien dafür zu gewinnen (z.B. geeignet zu sperren)
  - Gewichtung der individuellen Stimmen: Entweder eine Stimme pro Kopie oder Gewichte pro Stimme (z.B. mehr Gewicht für hoch verfügbare Stationen)
  - Anzahl der Stimmen, die für das Erreichen der Mehrheit erforderlich sind: Statisch (fest vorgegeben), dynamisch (nur Stationen, die beim letzten Update dabei waren, haben Stimme)
- Für Lesezugriffe (Lesequorum Q_r) und Schreibzugriffe (Schreibquorum Q_w) können unterschiedliche Anzahlen von erforderlichen Stimmen festgelegt werden
  - Ein-Kopie-Serialisierbarkeit bei $Q_w + Q_w > Q$ und $Q_w + Q_r > Q$, Q Gesamtgewicht
    - Dazu Zeitstempel pro Kopie; beim Lesen: Zeitstempel prüfen, neueste Kopie lesen
      - Durch $Q_w + Q_r > Q$ müssen Lese- und Schreiboperationen überlappen, weswegen Lese-Operationen nicht nur veraltete Kopien lesen (mindestens eine ist aktuell)
- Auch ohne Sperren möglich (Stationen im Ring angeordnet); Erweiterung: Tree Quorum

Zwischenzusammenfassung

- Anfrageoptimierung unter Berücksichtigung der Fragmentierung
- Verteilte Join-Auswertung aufwendig, da u.U. viele Nachrichten nötig
- Wiederherstellung: redo / undo
- EOT-Behandlung durch 2PC-Protokoll
  - Fehlersituationen: Absturz eines Agenten im Rahmen des Protokolls behandelbar, Absturz des Koordinators u.U. schwierig (Agenten blockiert), verlorengegangene Nachricht (Koordinator wartet behandelbar; Agent wartet → Agent blockiert)
- Transaktionsverwaltung
  - Lokale Serialisierbarkeit bedeutet keine globale Serialisierbarkeit
  - Sperrverwaltung: Lokale Sperren einfach, globale Sperren sicherer aber schwierig umzusetzen
  - Deadlockerkennung schwierig: dezentrale Lösung existiert, aber aufwendig
  - Synchronisation bei replizierten Daten schwierig

Überblick: 8. Verteilte Datenbanken

A. Verteilte DBMS
- Fragmentierung, Replikation, Allokation
- Transparenz
- CAP-Theorem

B. Anfragenbeantwortung in verteilten Systemen
- Anfrageverarbeitung
- Transaktionskontrolle, Sperrverwaltung, Deadlockvermeidung

C. Föderierte DBS
- Integration
- Migration

Anwendungsbeispiel

- Typische Situation in Unternehmen und Organisationen:
  - Unabhängig voneinander entstandene Datenbestände in verschiedenen Abteilungen / Arbeitsgruppen
    - Unterschiedliche Strukturierung gleich(artig)er Daten
    - Teilweise redundante Datenhaltung
    - Global inkonsistente Datensituation möglich
  - Autonome, nicht abgestimmte Entscheidungen über Anschaffung von Hardware und Software
- Entstehung von „Insellösungen“, die einen einheitlichen Zugriff auf verteilte Daten erschweren oder sogar unterbinden

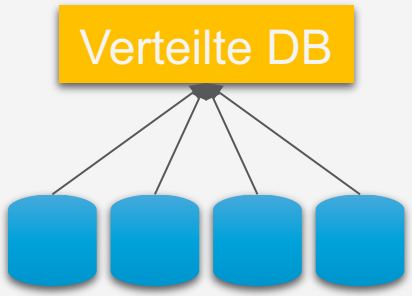

Anwendungsbeispiel

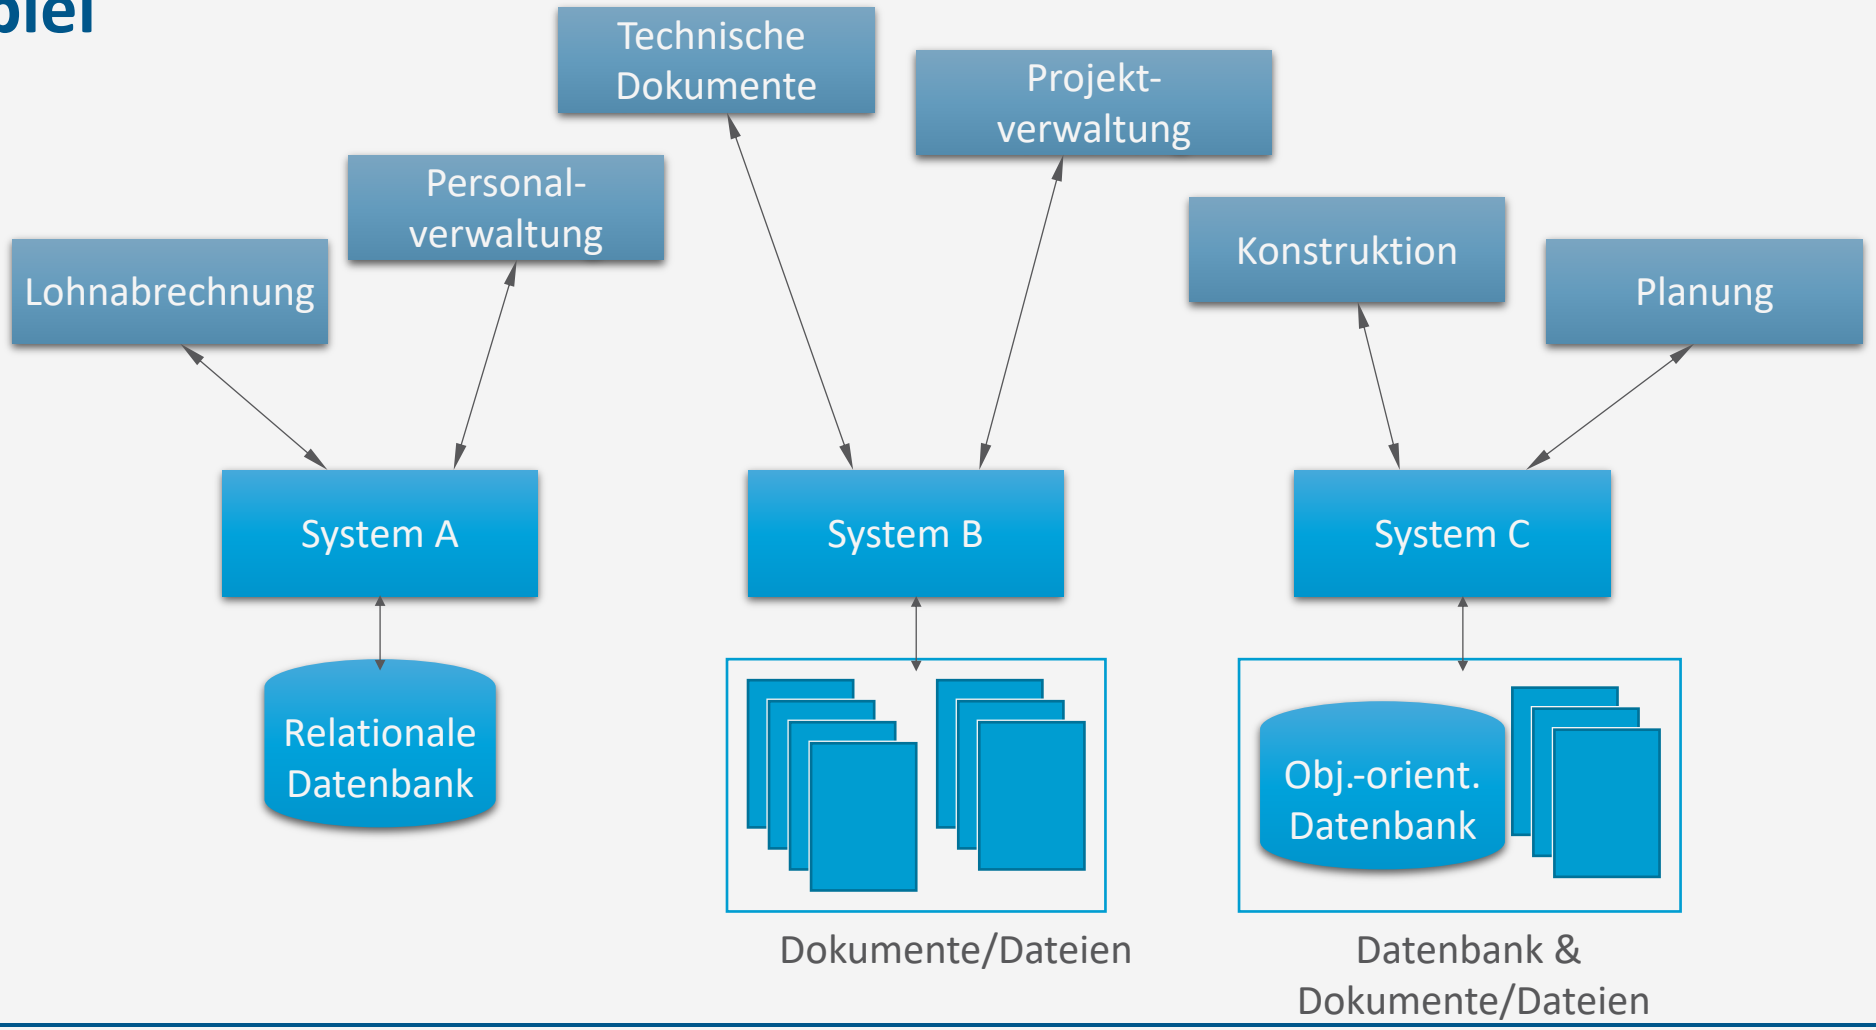

Anwendungsbeispiel

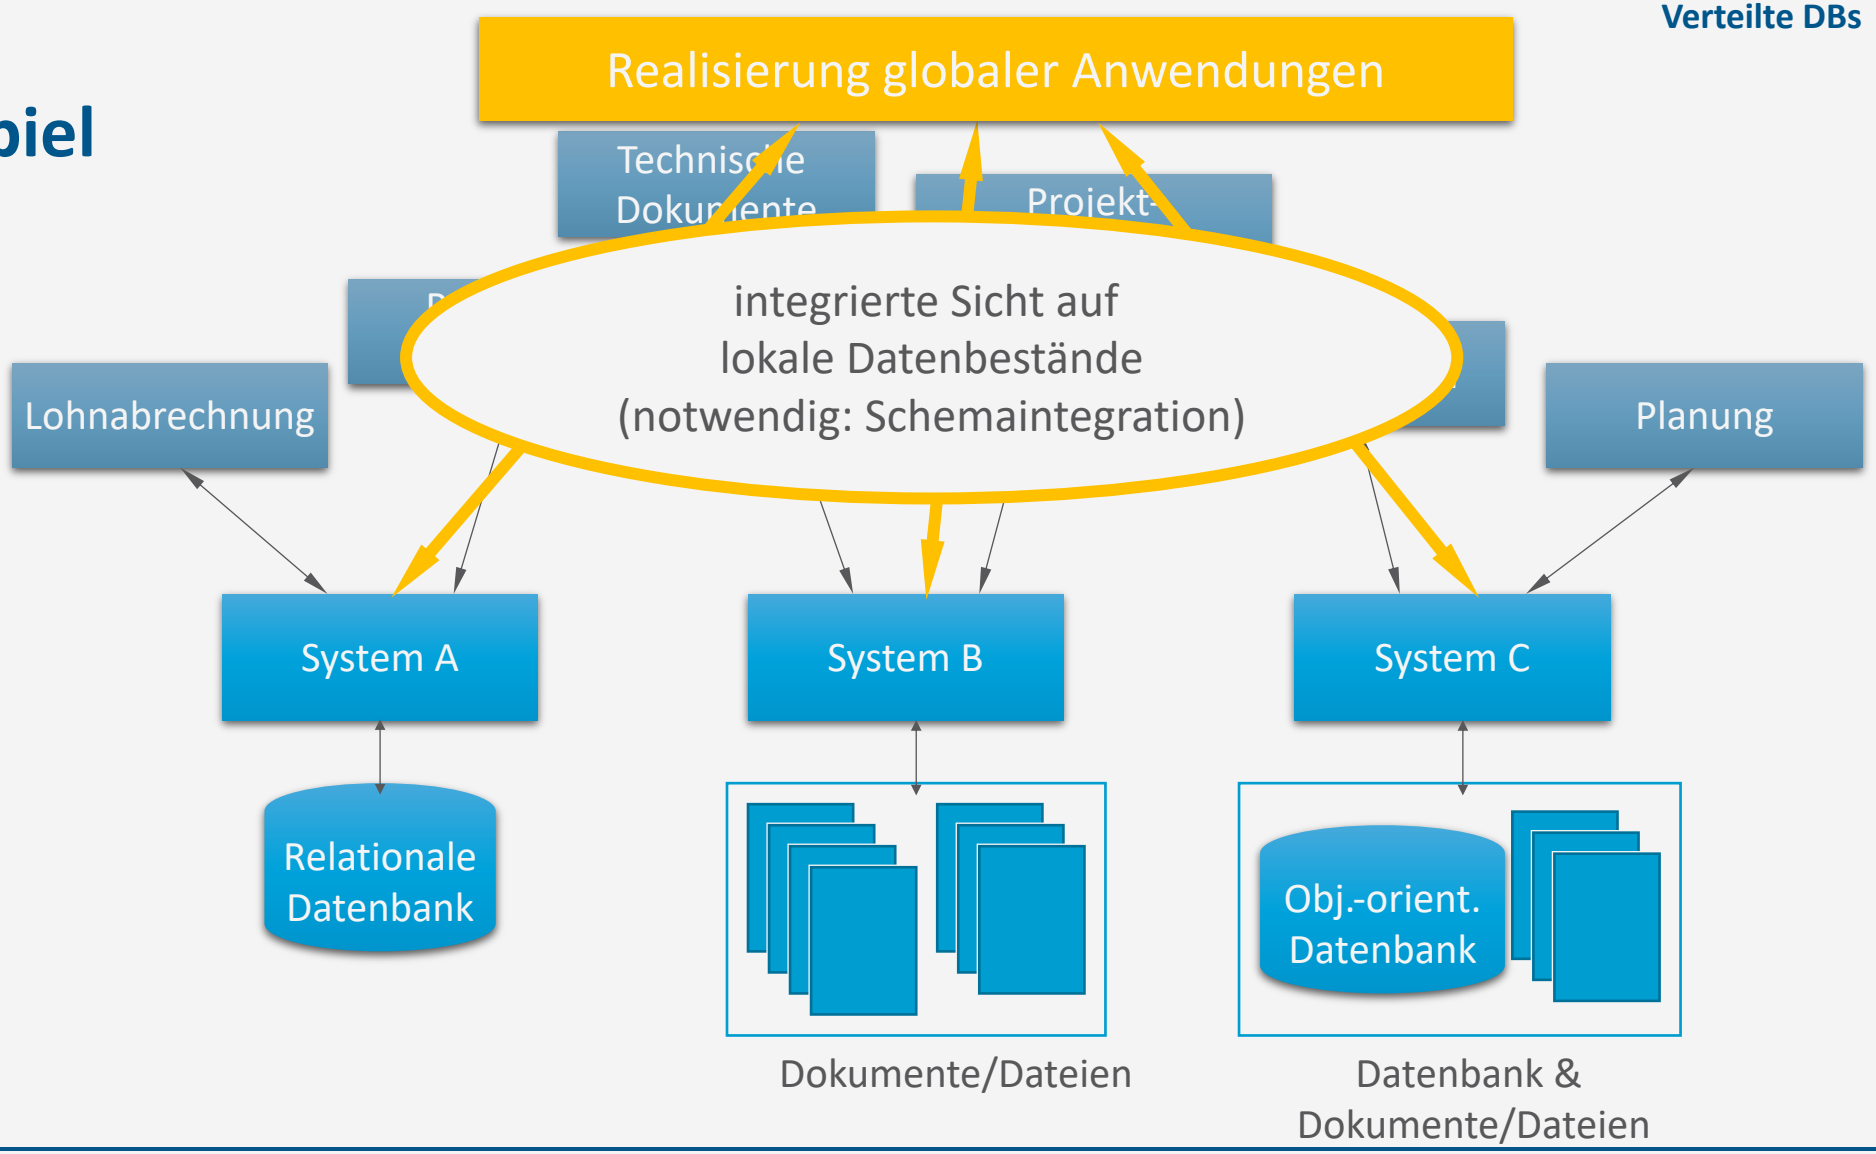

Föderierte DBS: Allgemeine Architektur

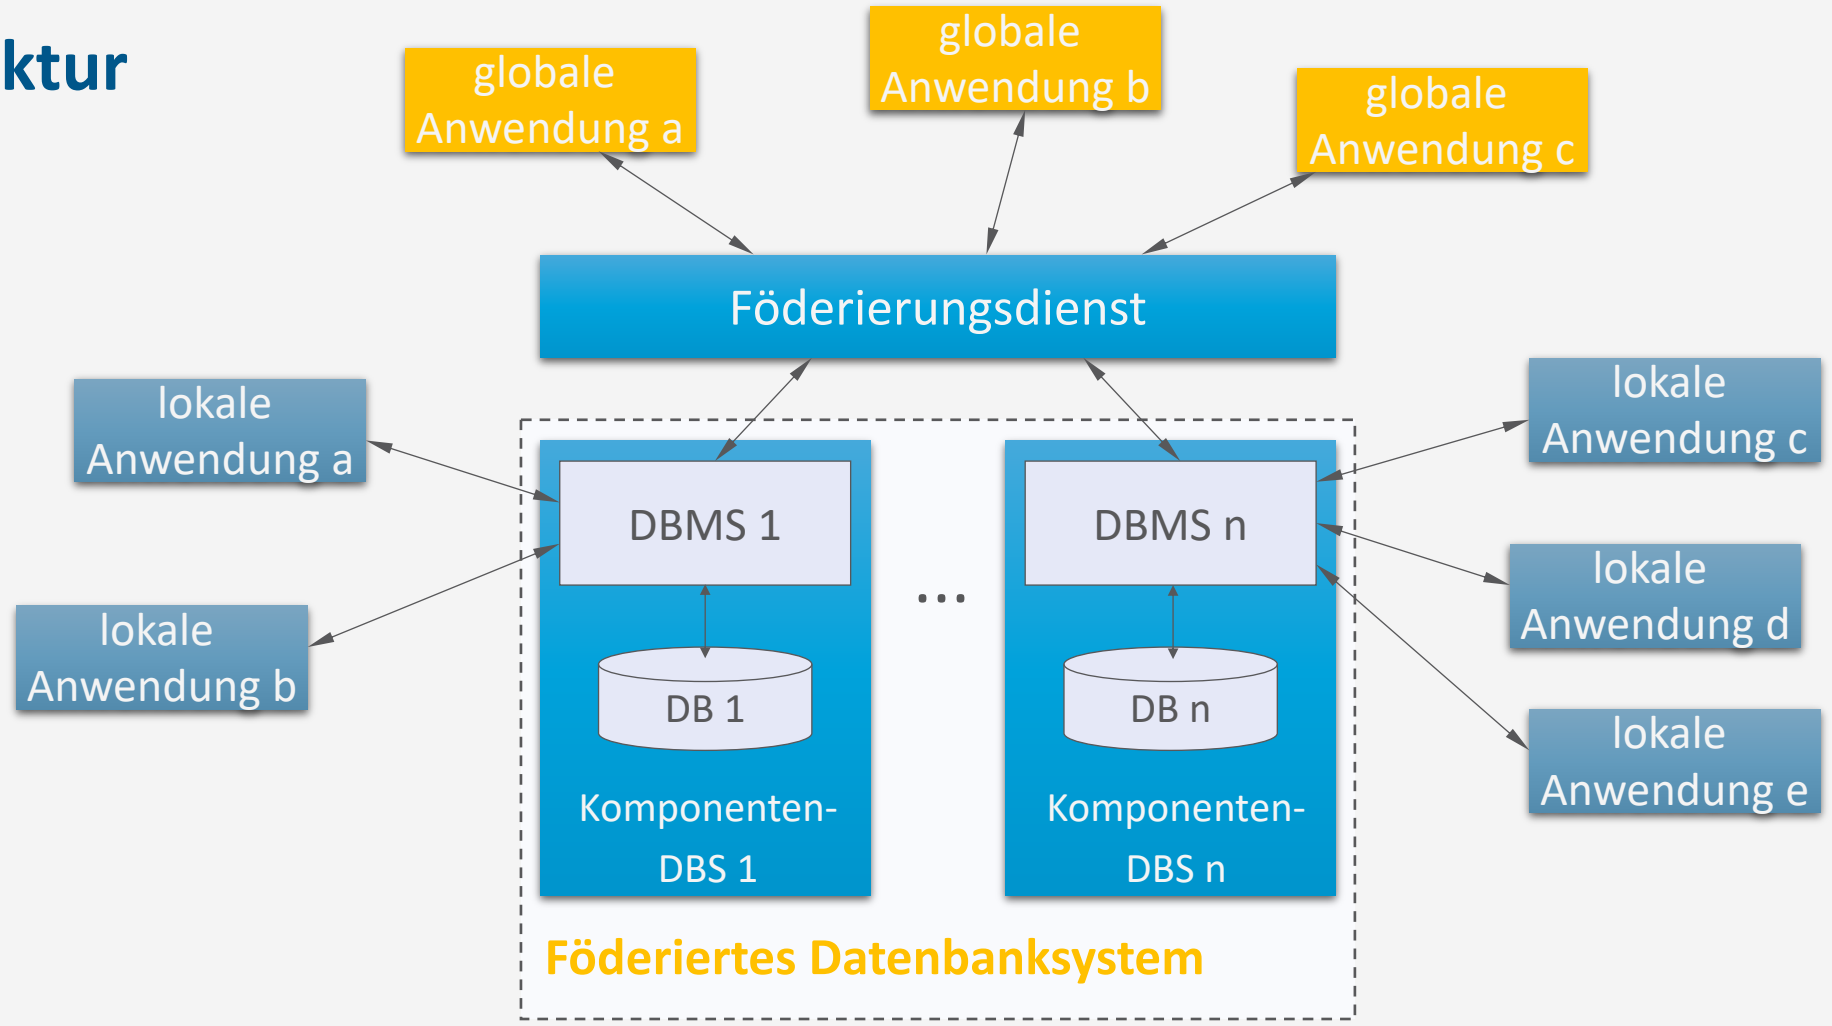

Was soll ein föderiertes DBS können?

- Im Idealfall volle Funktionalität eines DBS, dabei Verbergen der Verteilung bzgl.
  - Transaktionsverwaltung
  - Integritätskontrolle
  - Anfrageverarbeitung und -optimierung
  - Recovery

  auf globaler Ebene (im Föderierungsdienst) → Insgesamt hohen Aufwand
- Pragmatischer Ansatz:
  - Nur solche Funktionalität im föderierten System realisieren, die tatsächlich benötigt wird – eine stark anwendungsgetriebene Diskussion

5-Schichten-Architektur

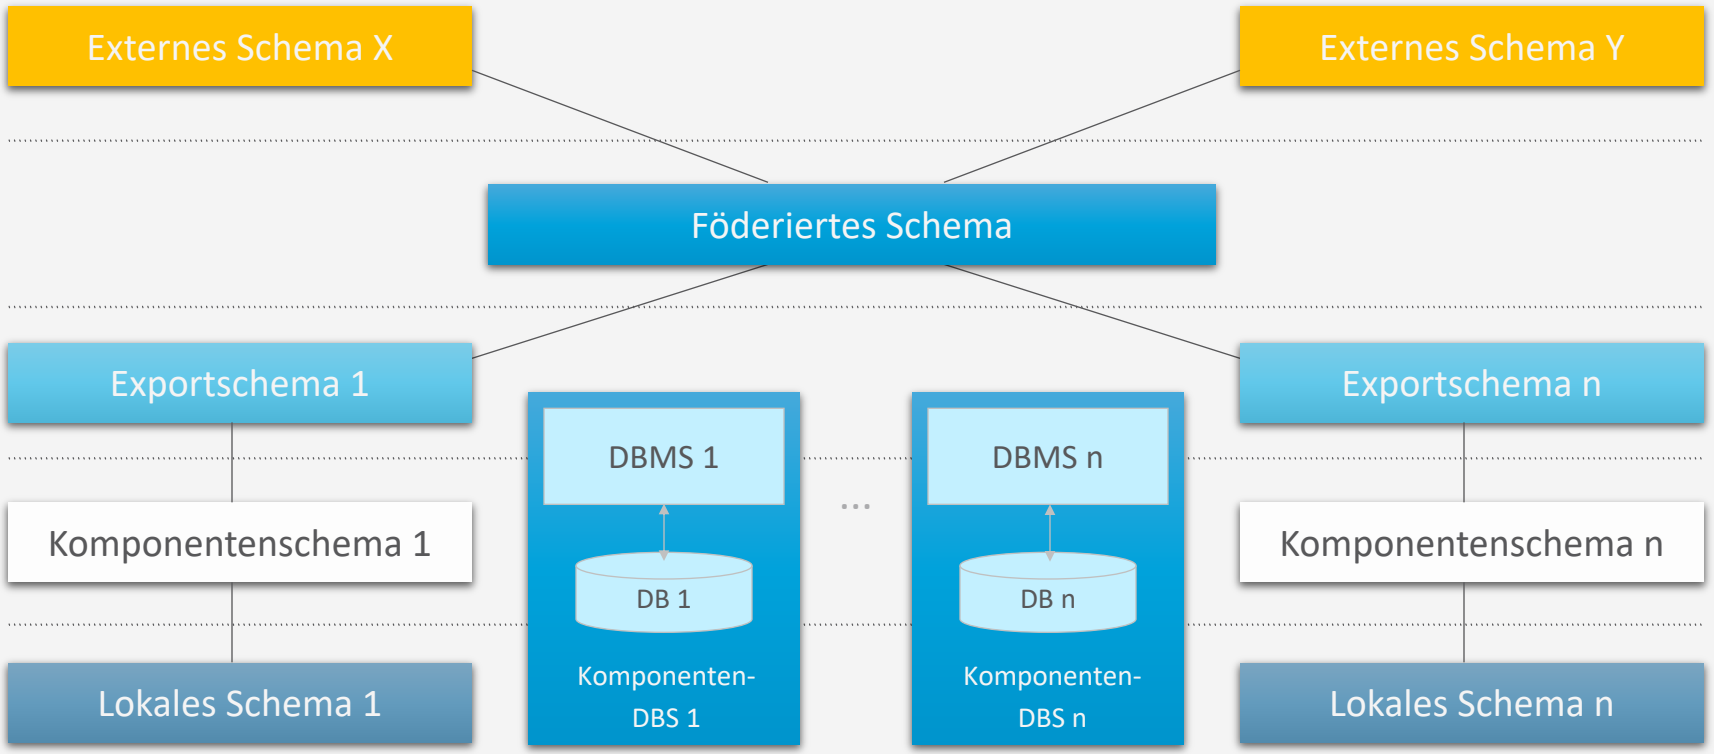

Schemaintegration

- Lokales Schema
  - Datenschema des lokalen DBS
- Komponentenschema
  - Schema des lokalen DBS im globalen Datenmodell
- Exportschema
  - Teile des lokalen Schemas, die in Föderation eingebracht werden sollen
- Föderiertes Schema
  - Globales Schema des föderierten DBS
- Externes Schema
  - Schema für einzelne Anwendungen bzw. Benutzer

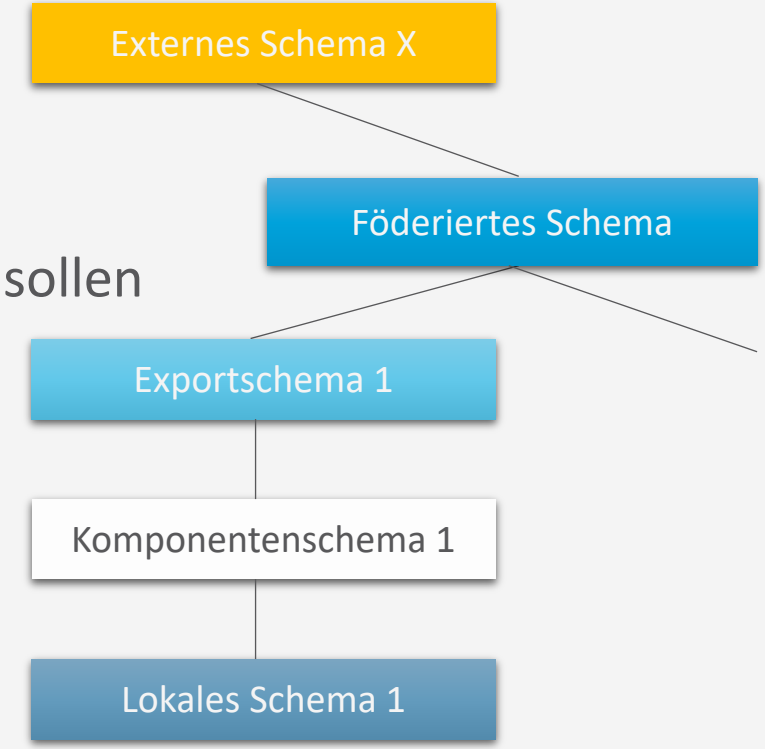

Schemaintegration

- Vorgehen
  - Schematransformation:
    - Übersetzung der lokalen Schemata in Komponentenschemata (semi-automatisch oder interaktiv anhand von Transformationsregeln)
  - Verhandlung (unter Domänenexperten und Datenbankdesignern):
    - Anwendungsorientierte Diskussion der angestrebten Exportschemata
  - Eigentliche Schemaintegration:
    - Vereinigung der Exportschemata zu föderiertem Schema
- Probleme
  - Synonyme: gleiche Bedeutung bei unterschiedlicher Benennung
  - Homonyme: gleiche Namen bei unterschiedlicher Bedeutung
  - Ähnlichkeit, Spezialisierung, Überschneidung

Forschungsgebiet u.a.: Ontology-based data access (OBDA)
Gemeinsame Ontologie definieren, für Übersetzung von globalen Anfragen in lokale Anfragen / Zusammenstellung der Einzelergebnisse in ein Gesamtergebnis
- Anwendung z.B. in der Zusammenführung von medizinischen Daten aus unterschiedlichen Krankenhausinformationssystemen

Schemaintegration → Datenintegration

	Semantische Ebene	Zu behebende Inkonsistenz	Angewandte Methoden
1	Schema	Schematische Heterogenität	Integration Mapping Matching
2	Tupel (Object)	Duplikate	Ähnlichkeitsmaße Partitionierungs-strategien
3	Wert	Datenkonflikte	Datenreinigung Transformationen Fusion

Beispiele für föderierte DBS

- Ablösung von Altsystemen (legacy systems) – z.B. wegen ...
  - Ansteigender Wartungskosten
  - Nachlassender Unterstützung durch Systemhersteller
  - Überlastung des Altsystems in vorliegender bzw. perspektivischer Anwendungssituation – keine ausreichenden Skalierungsmöglichkeiten
  - Reorganisation betrieblicher Strukturen – z.B. aufgrund einer Fusion mit anderem Unternehmen, die letztlich die Vereinheitlichung der Systemplattformen notwendig macht
- Wichtige Anforderungen dabei
  - Investitionsschutz
    - Erhalt von Daten
    - Erhalt von Anwendungsprogrammen
  - Fortlaufender Betrieb während Migration

Migration in kleinen Schritten

- Für fortlaufenden Betrieb
  - System B aufsetzen, Föderierungsdienst definieren
  - Lokale Anwendung a in globale Anwendung a übersetzen
  - Daten aus System A übertragen
  - Lokale Anwendung a an System B überführen, dann alte lokale Anwendung a und globale Anwendung a löschen

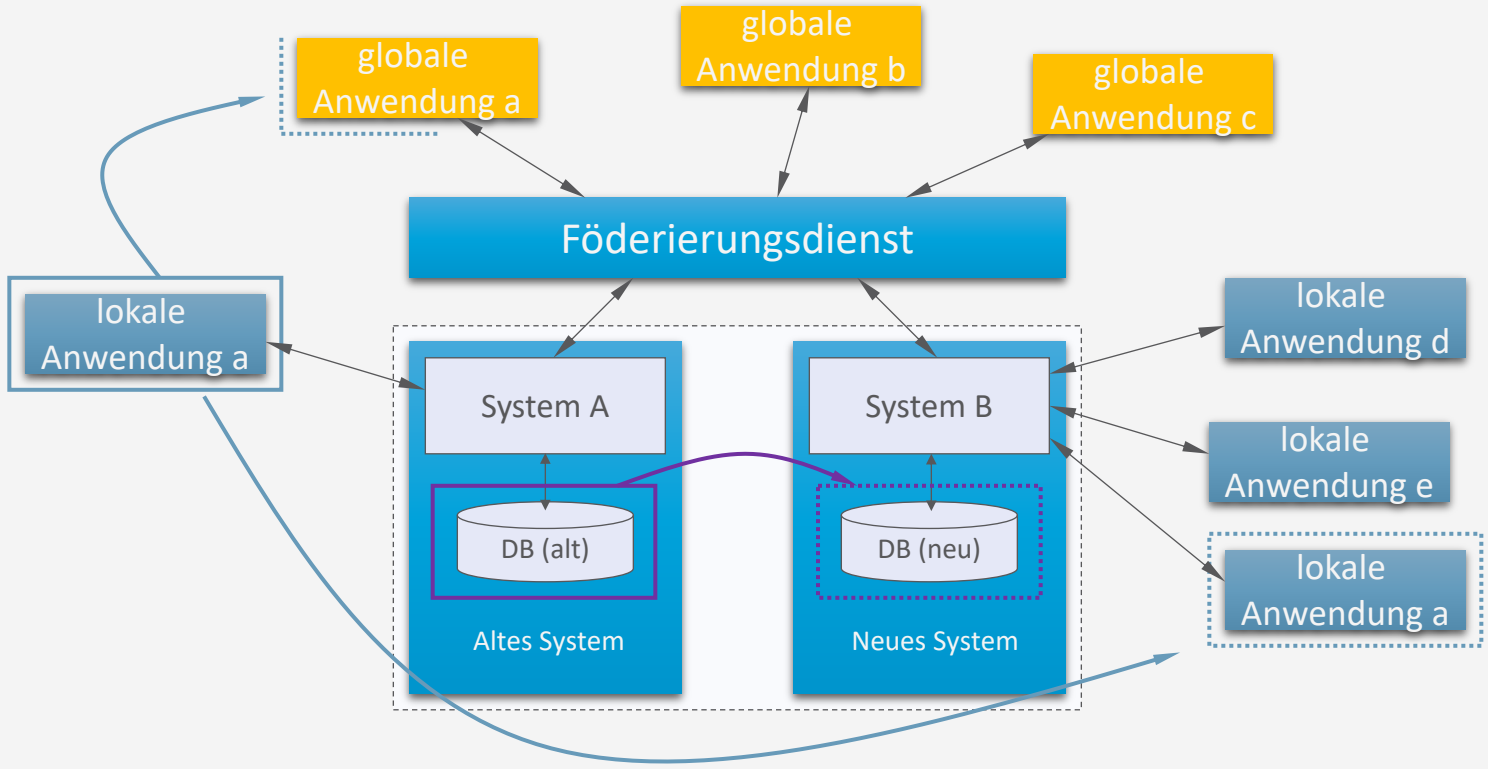

Zwischenzusammenfassung

- Föderierte Datenbanken
  - Einheitliche Sicht auf unterschiedliche DBs
  - Integration
  - Systematische Migration
  - ... von Daten und Anwendungen

Überblick: 8. Verteilte Datenbanken

A. *Verteilte DBMS*
   - Fragmentierung, Replikation, Allokation
   - Transparenz
   - CAP-Theorem

B. *Anfragenbeantwortung in verteilten Systemen*
   - Anfrageverarbeitung
   - Transaktionskontrolle, Sperrverwaltung, Deadlockvermeidung

C. *Föderierte DBS*
   - Integration
   - Migration

Ende

Anhang

Dezentrale Deadlock-Erkennung: Größeres Beispiel

Beispiel zu Path Pushing nach Kemper (Ordnung $i > j$)

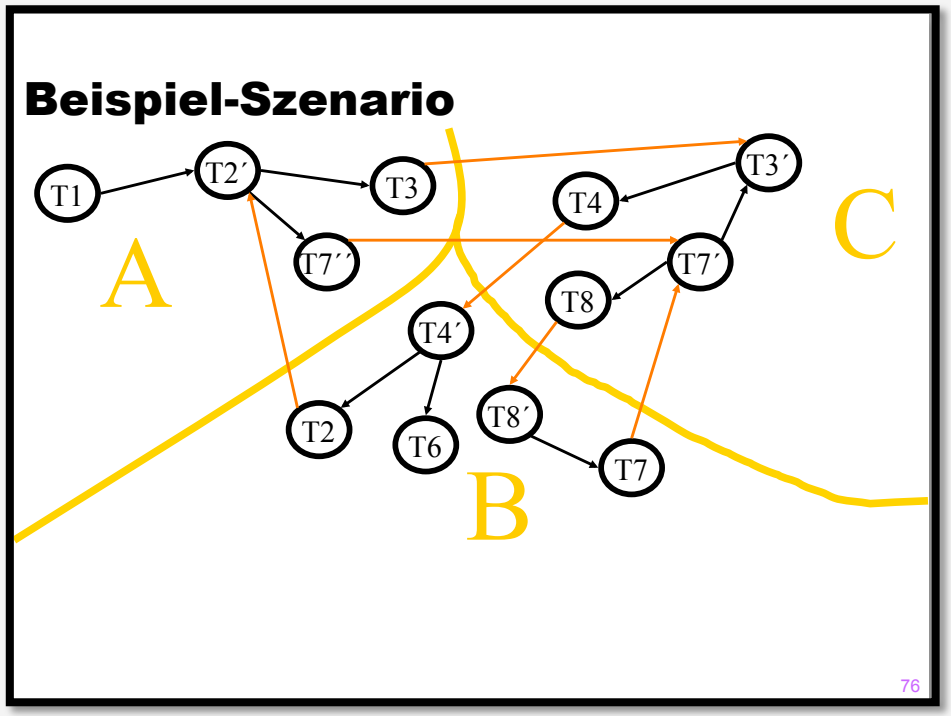

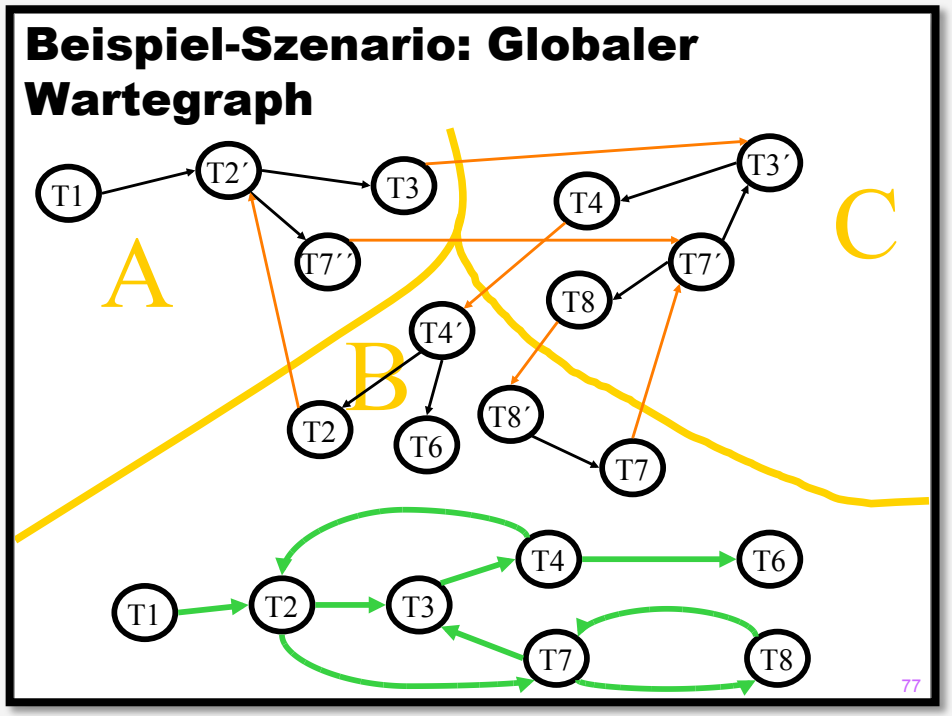

Beispiel zu Path Pushing nach Kemper (Ordnung $i > j$)

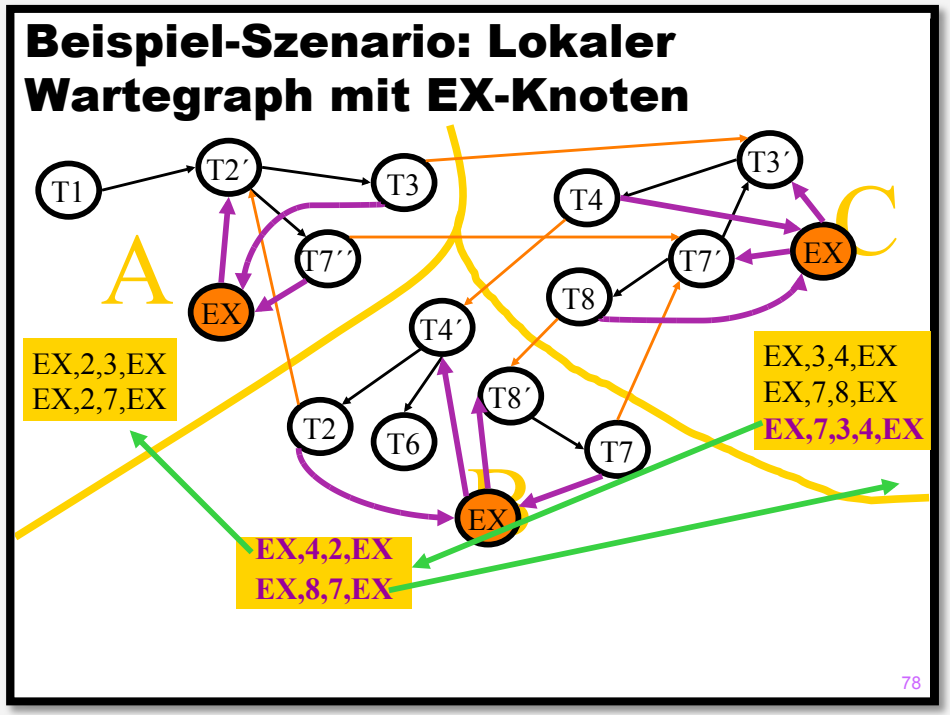

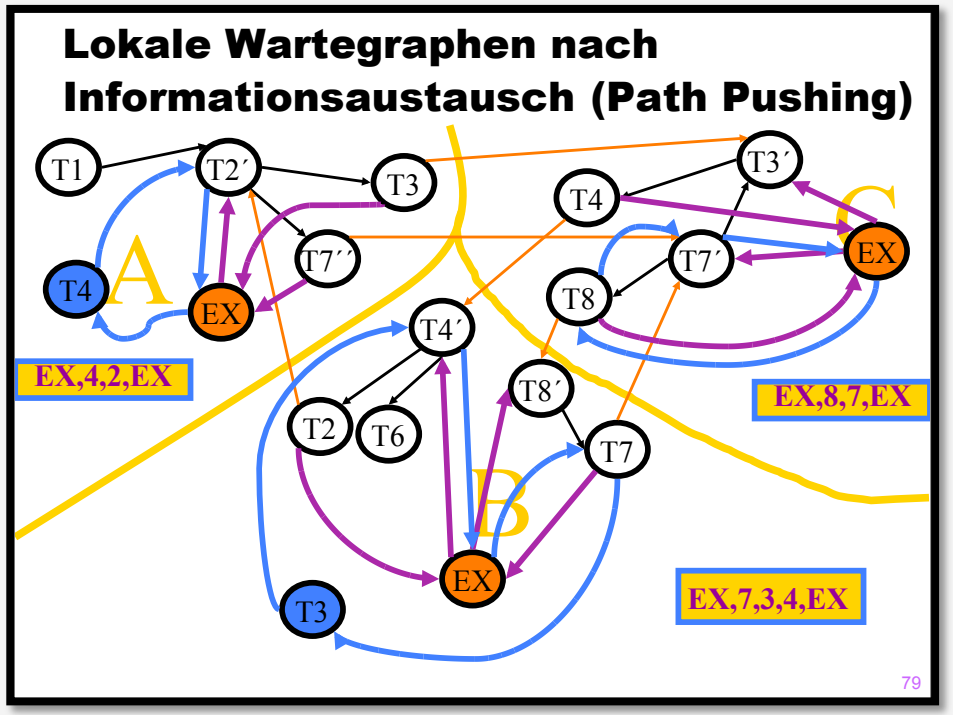

Beispiel zu Path Pushing nach Kemper (Ordnung $i > j$)

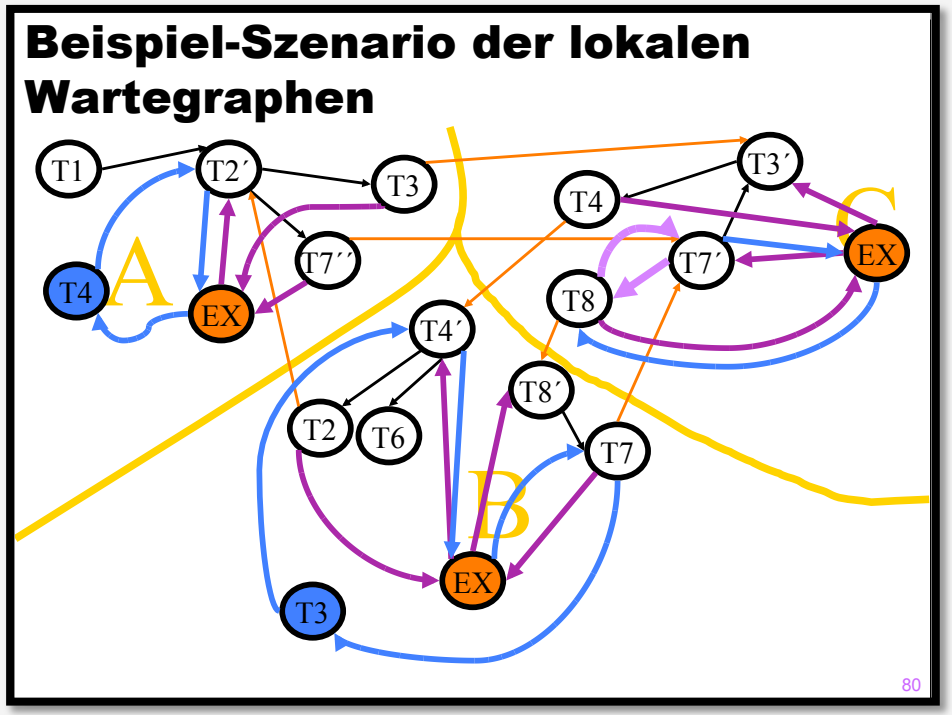

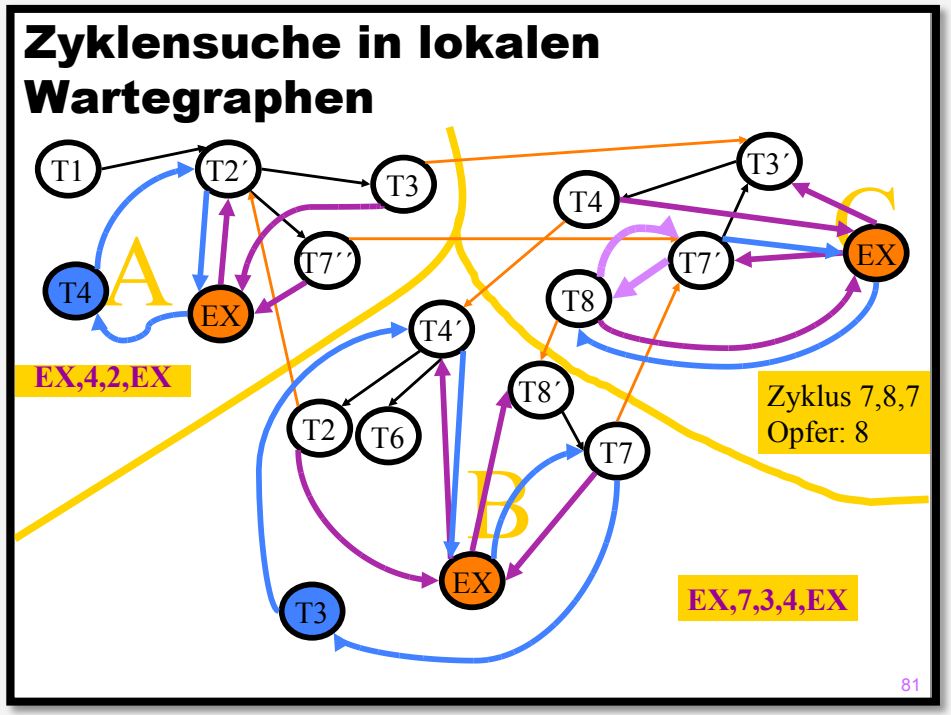

Beispiel zu Path Pushing nach Kemper (Ordnung $i > j$)

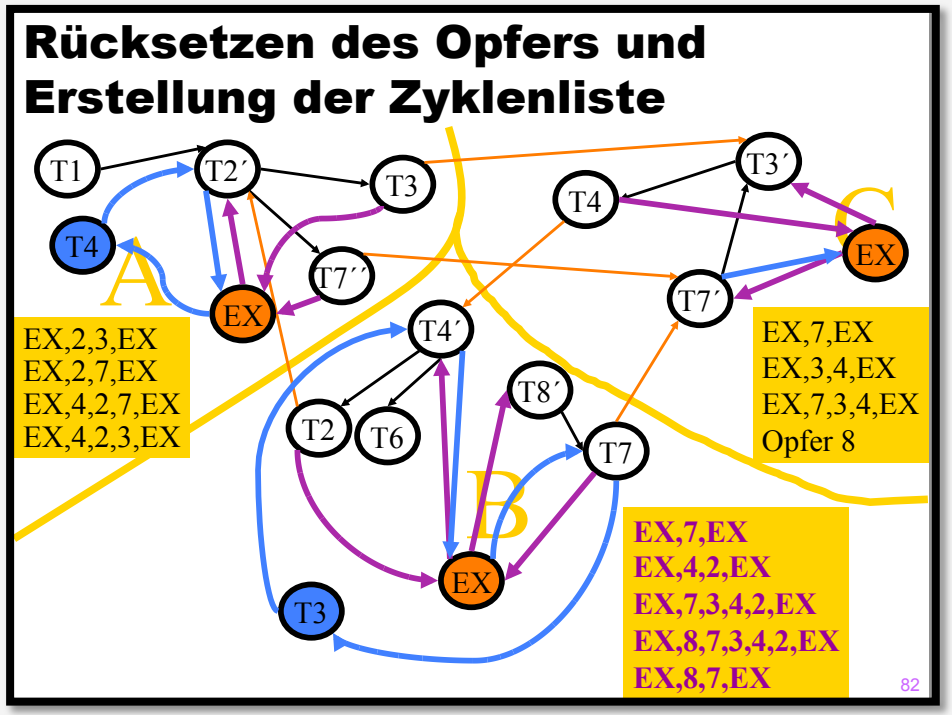

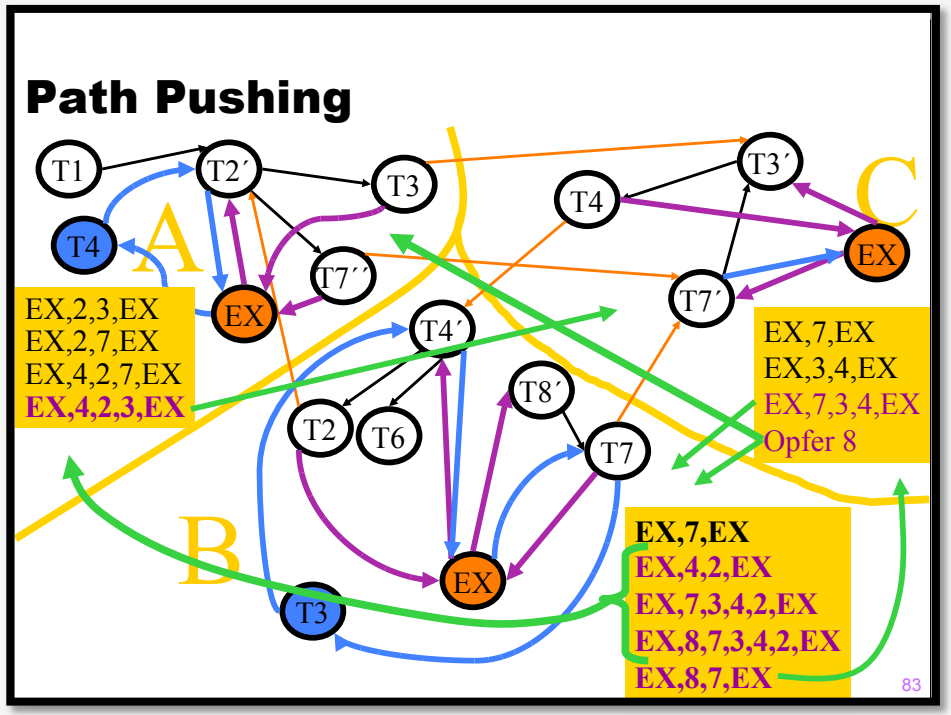

Beispiel zu Path Pushing nach Kemper (Ordnung $i > j$)

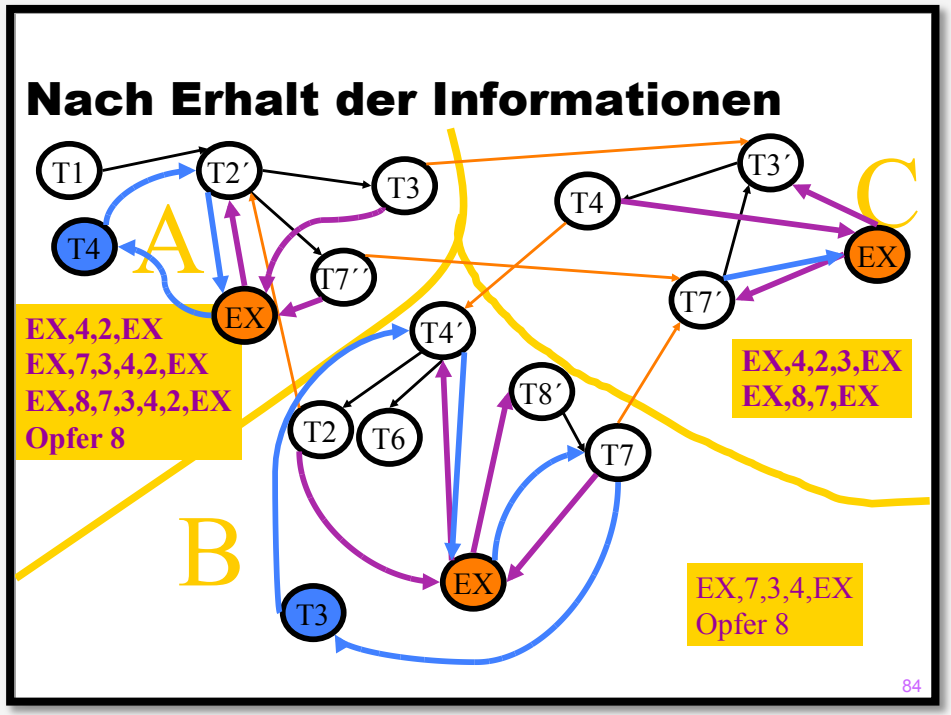

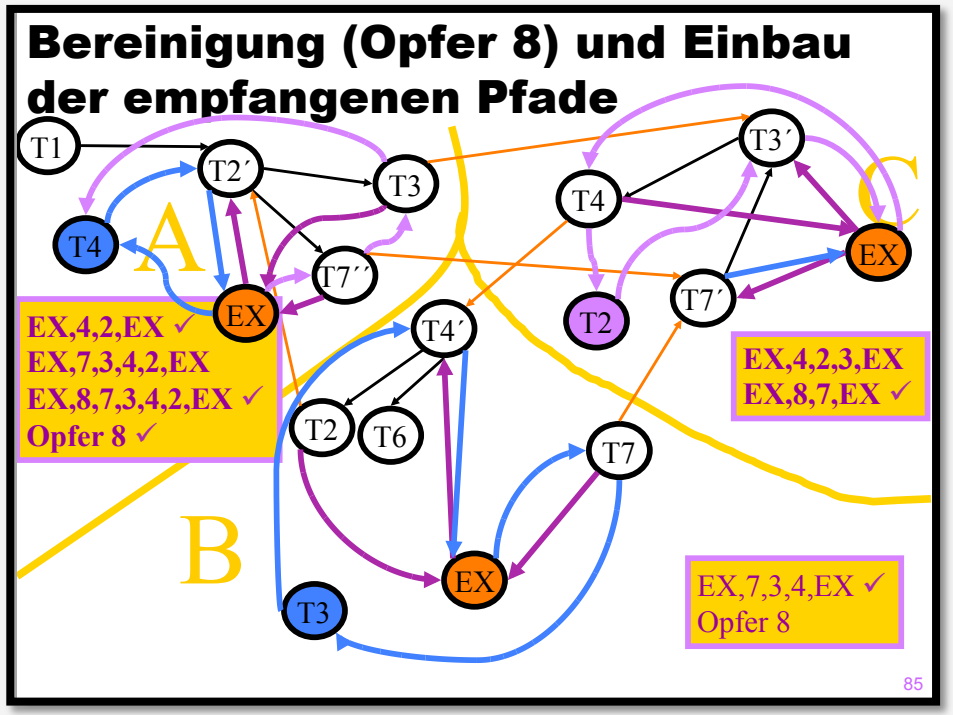

Beispiel zu Path Pushing nach Kemper (Ordnung $i > j$)

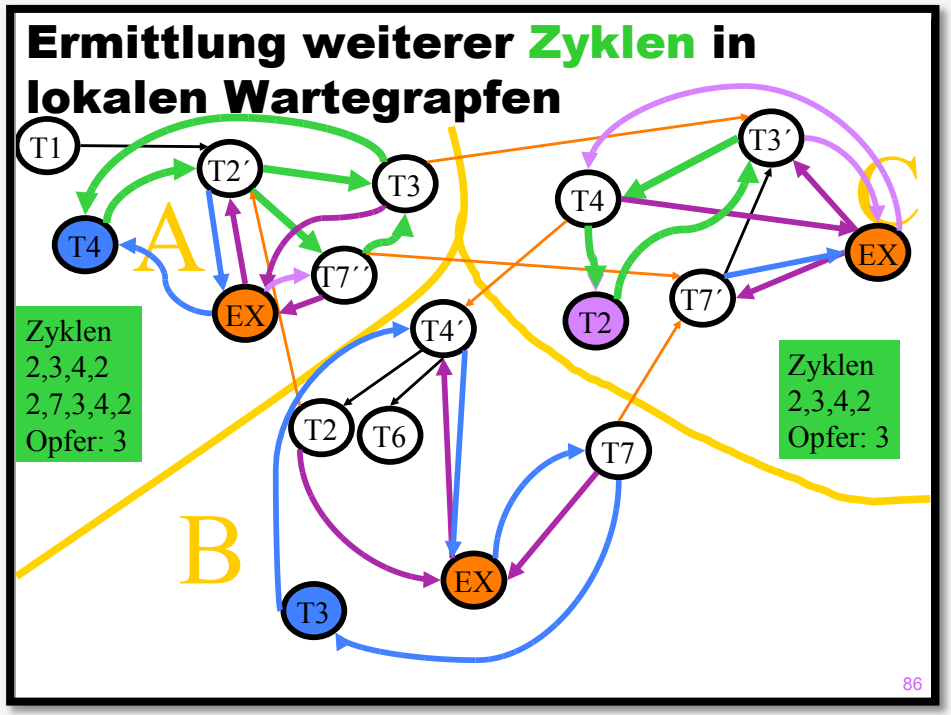

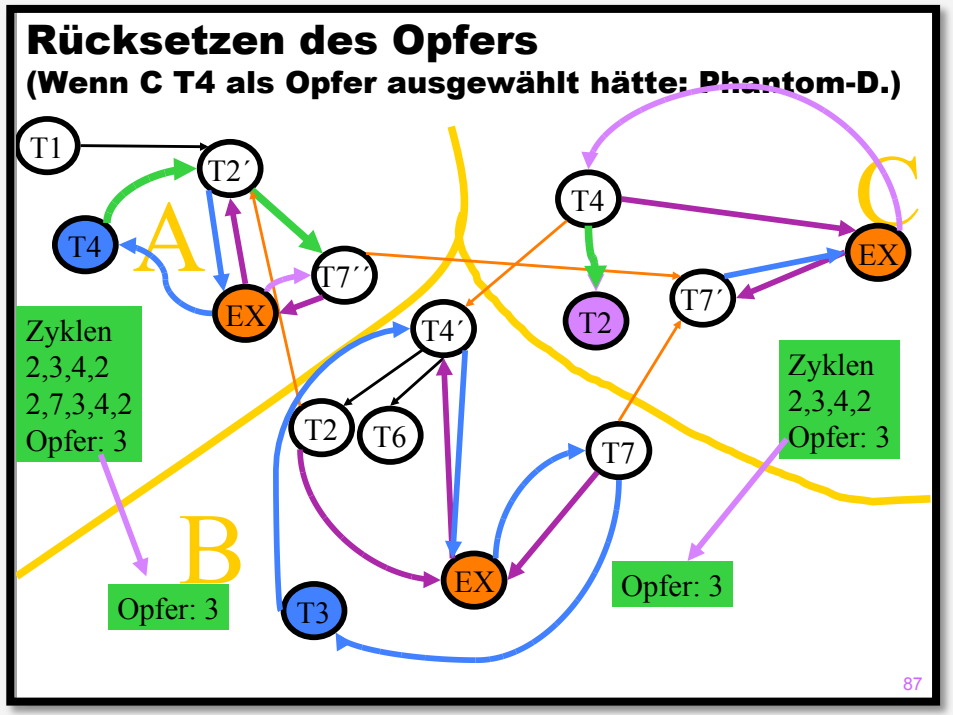

Beispiel zu Path Pushing nach Kemper (Ordnung $i > j$)

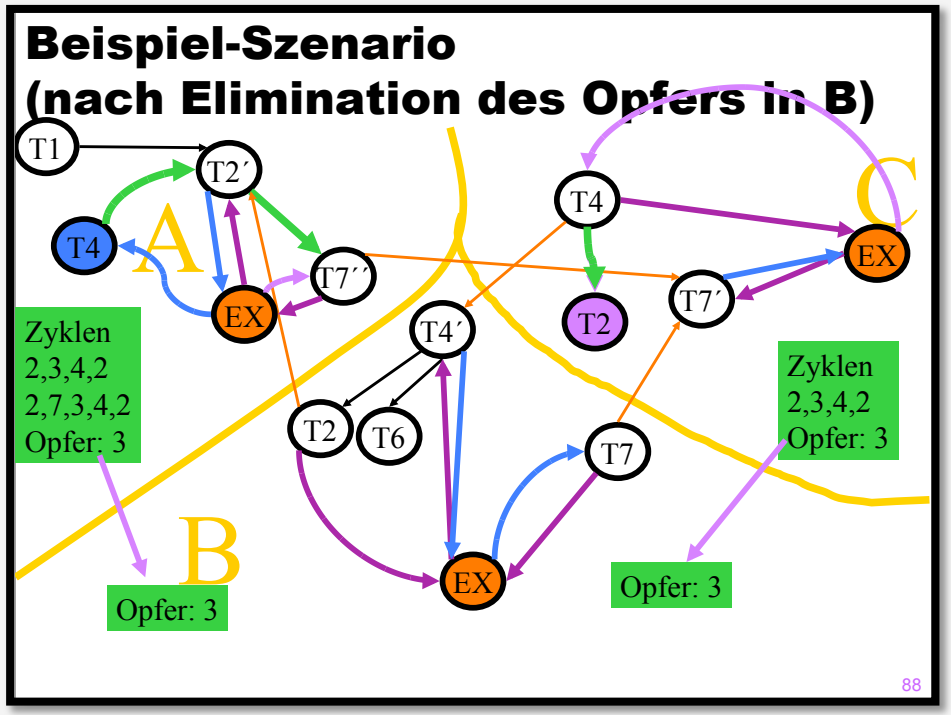

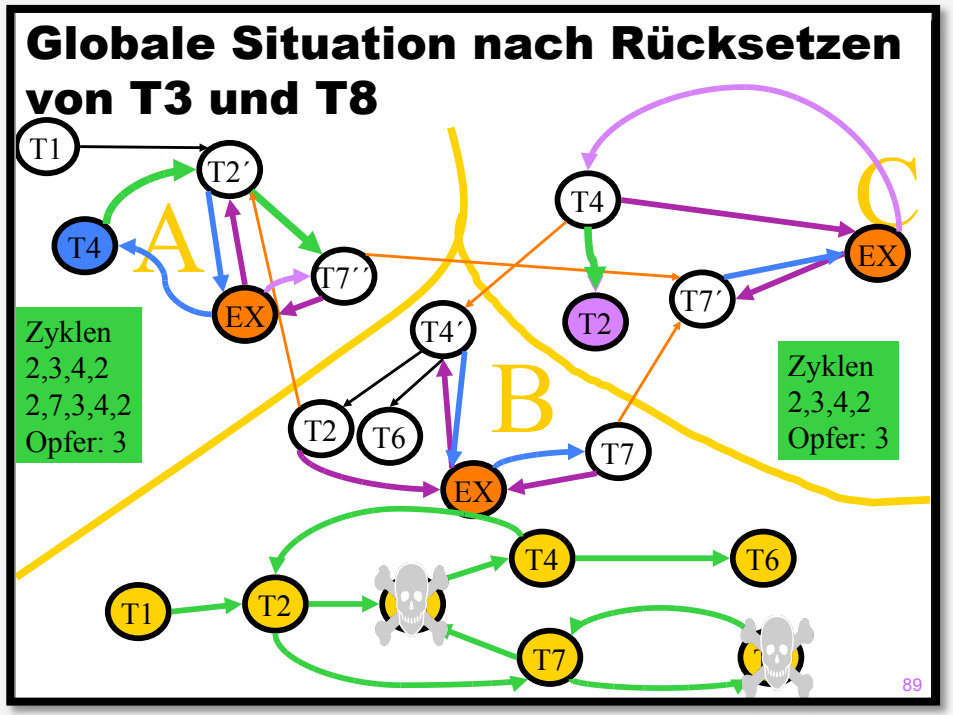

Beispiel zu Path Pushing nach Kemper (Ordnung $i > j$)