7. Replizierte Datenbanken

- Einführung (Replikationsstrategien)
- Update-Strategien bei strenger Konsistenz
  - ROWA-Verfahren / 2PC
  - Voting-Verfahren
- schwächere Formen der Datenreplikation
  - Refresh-Alternativen
  - Primary-Copy-Verfahren
  - Schnappschuß-Replikation
  - Merge-Replikation
- Katastrophen-Recovery
- Geo-Replikation für Cloud-Daten
- Datenreplikation in Parallelen DBS
  - verstreute Replikation
  - verkettete Replikation

Replikate in Verteilten DBS

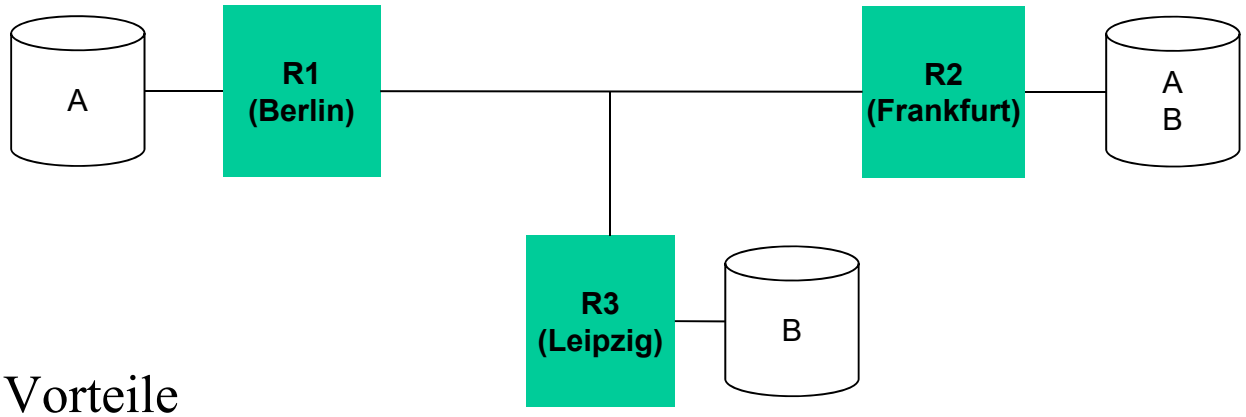

- Vorteile
  - erhöhte Verfügbarkeit der Daten
  - Beschleunigung von Lesezugriffen (bessere Antwortzeiten, Kommunikationseinsparungen)
  - erhöhte Möglichkeiten zur Lastbalancierung / Query-Optimierung
- Nachteile
  - hoher Update-Aufwand
  - erhöhter Speicherplatzbedarf
  - erhöhte Systemkomplexität

Replikation: Anwendungsmöglichkeiten

- Verteilte und Parallele DBS
  - replizierte DB-Tabellen / -Fragmente
  - replizierte Katalogdaten (Metadaten)
- Web: replizierte Daten und Metadaten für schnelles Lesen und Verfügbarkeit (Mirror Sites, Suchmaschinen, Portale)
- Katastrophen-Recovery
- Data Warehousing
  - Übernahme transformierter Daten in eigene Datenbank für Entscheidungsunterstützung
- Mobile Computing
  - Datenbank-Ausschnitte, Dateien ... auf Notebook, PDA etc.

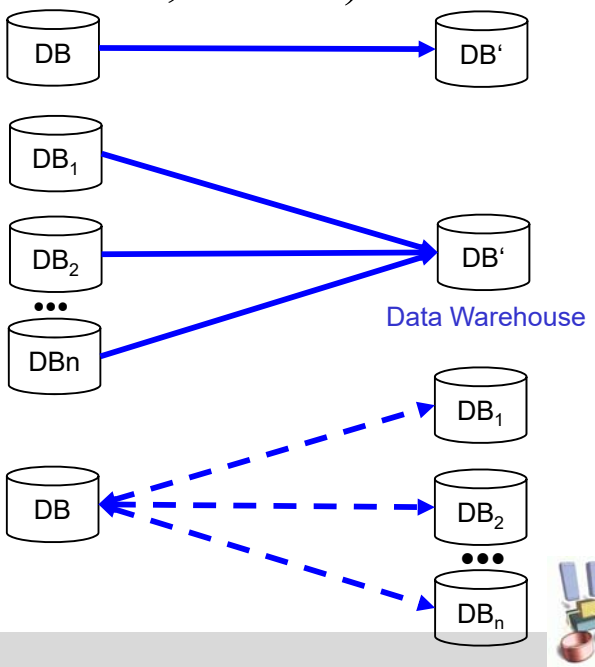

Zielkonflikte der Replikationskontrolle

Erhaltung der Datenkonsistenz
- Kopien wechselseitig konsistent zu halten: *1-Kopien-Äquivalenz*
- kleine Kopienzahl

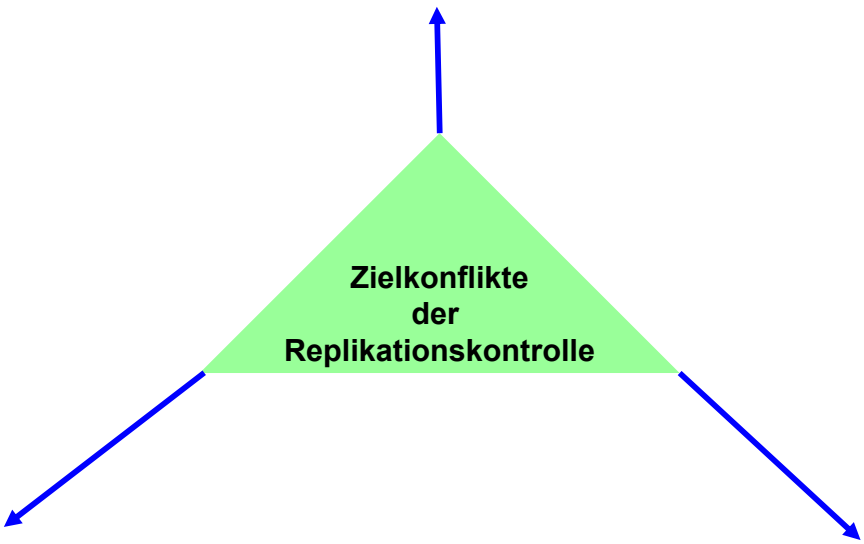

Erhöhung der Verfügbarkeit, effizienter Lesezugriff
- große Kopienzahl
- Zugriff auf beliebige und möglichst wenige Kopien

Minimierung des Änderungsaufwands
- kleine Kopienzahl
- möglichst wenige Kopien synchron aktualisieren

Replikationsstrategien (1)

- Korrektheitskriterium / Synchronisation

- 1-Kopien-Äquivalenz:
  - vollständige Replikationstransparenz: jeder Zugriff liefert jüngsten transaktionskonsistenten Objektzustand
  - alle Replikate sind wechselseitig konsistent
  - Serialisierung von Änderungen

- geringere Konsistenzanforderungen
  - Zugriff auf ältere Objektversionen
  - evtl. keine strikte Serialisierung von Änderungen, sondern parallele Änderungen mit nachträglicher Konflikt-Behebung

Replikationsstrategien (2)

- symmetrische vs. asymmetrische Konfigurationen
  - symmetrisch: jedes Replikat gleichartig bezüglich Lese- und Schreibzugriffen; n Knoten können Objekt ändern
  - asymmetrisch (Master/Slave, Publish/Subscribe-Ansätze)
    - Änderungen eines Objekts an 1 Knoten (Master, Publisher, Primärkopie)
    - Lesen an n Knoten (Slave, Subscriber, Sekundärkopien)
  - Kombinationen (z.B. Multi-Master-Ansätze)

- Zeitpunkt der Aktualisierung: synchron oder asynchron
  - synchron (eager): alle Kopien werden durch Änderungstransaktion aktualisiert
  - asynchron (lazy): verzögertes Aktualisieren (Refresh)

Grobklassifikation

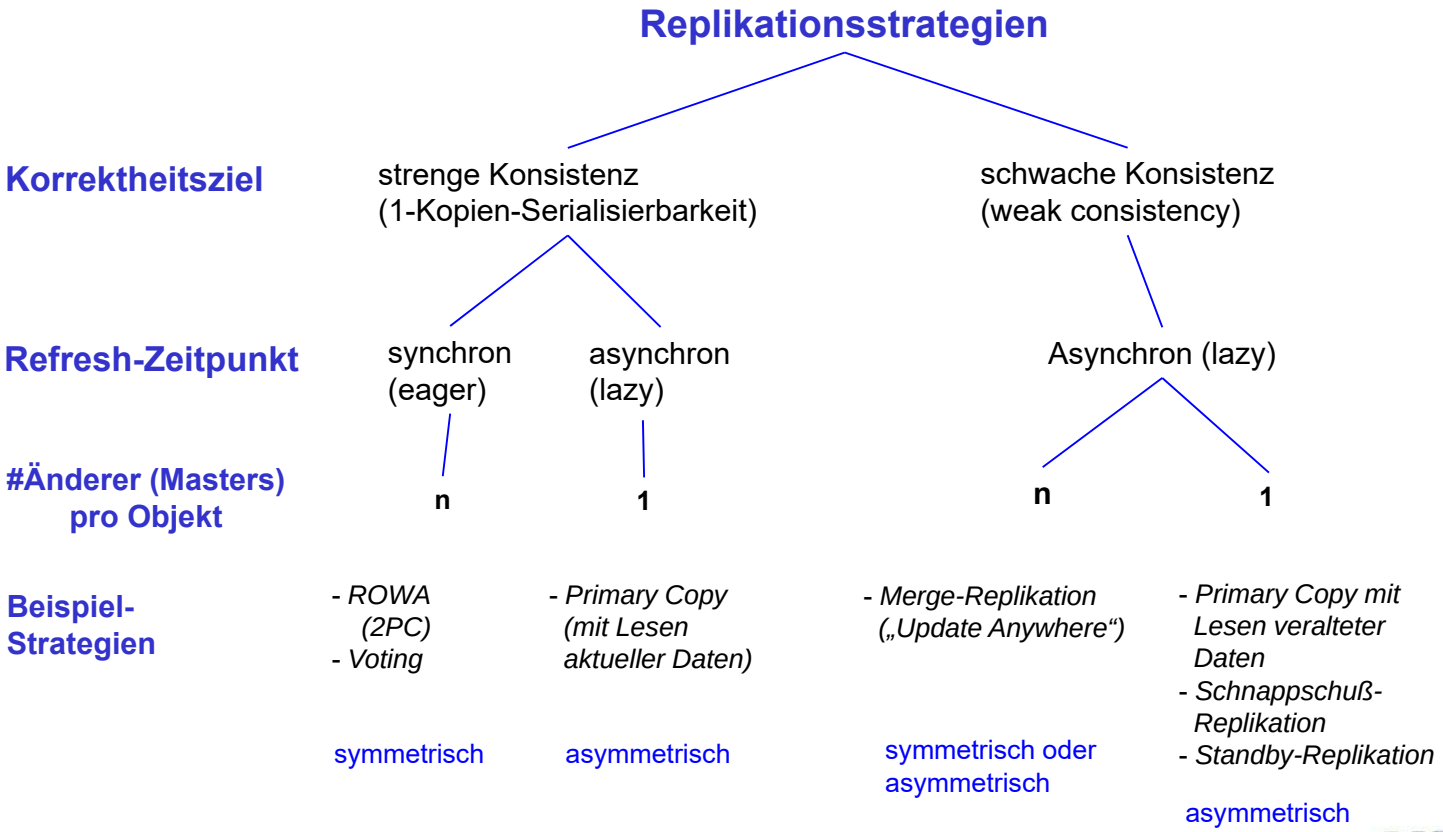

Write-All/Read-Any-Strategie (Read-One/Write-All, ROWA)

- bevorzugte Behandlung von Lesezugriffen
  - Lesen eines beliebigen (lokalen) Replikats
  - hohe Verfügbarkeit für Leser
- sehr hohe Kosten für Änderungstransaktionen
  - Schreibsperren bei allen Replikaten anfordern
  - Propagierung der Änderungen im Rahmen des Commit-Protokolls (2PC)
- Verfügbarkeitsproblem: Änderungen von Verfügbarkeit aller kopienhaltenden Knoten abhängig
  - sei p die mittlere Wahrscheinlichkeit, daß ein Knoten verfügbar ist
  - bei N Kopien beträgt die Wahrscheinlichkeit, daß *geschrieben* werden kann: p^N
  - Wahrscheinlichkeit, daß *gelesen* werden kann: $1 - (1 - p)^N$

Beispiel p=0.9, N=2: Schreibverfügbarkeit:
Leseverfügbarkeit:

Write All Available

- ROWA-Variante, bei der nur verfügbare Replikate geändert werden
  - für ausgefallene Rechner werden Änderungen bei Wiederanlauf nachgefahren
  - funktioniert nicht bei Netzwerk-Partitionierungen

Mehrheits-Votieren (Majority Voting)

- Lesen oder Schreiben eines Objektes verlangt Zugriff auf Mehrheit der Replikate
- jedes Replikat kann gleichzeitig von mehreren Transaktionen gelesen, jedoch nur von einer Transaktion geändert werden
- Bestimmung der aktuellsten Version z. B. über Änderungszähler
- Fehlerfall: Fortsetzung der Verarbeitung möglich, solange Mehrheit der Replikate noch erreichbar
- hohe Kommunikationskosten für Lese- und Schreibzugriffe
  - ungeeignet für N=2 („Read All, Write All“)

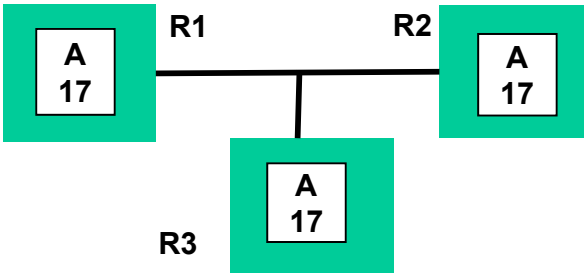

Gewichtetes Votieren (Quorum Consensus)

- jede Kopie erhält bestimmte Anzahl von Stimmen (votes)
- Protokoll:
  - Lesen erfordert R Stimmen (Read-Quorum)
  - Schreiben erfordert W Stimmen (Write-Quorum)
  - R + W > V (= Summe aller Stimmen)
  - W > V/2

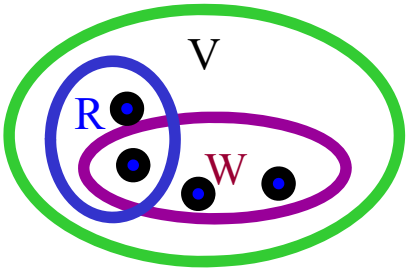

- Eigenschaften:
  - gleichzeitiges Lesen und Schreiben nicht möglich
  - jeder Zugriff auf R (W) Kopien enthält wenigstens 1 aktuelle Kopie
  - Festlegung von V, R und W erlaubt Trade-Off zwischen Lese- und Schreibkosten sowie zwischen Leistung und Verfügbarkeit

Gewichtetes Votieren (2)

- andere Verfahren ergeben sich als Spezialfälle
  - Beispiel : 3 Kopien mit jeweils 1 Stimme (V=3)
  - ROWA:
  - Majority Voting (Consensus):
  - 4 Kopien mit folgender Stimmenverteilung <2,2,2,1>

Gewichtetes Votieren (3)

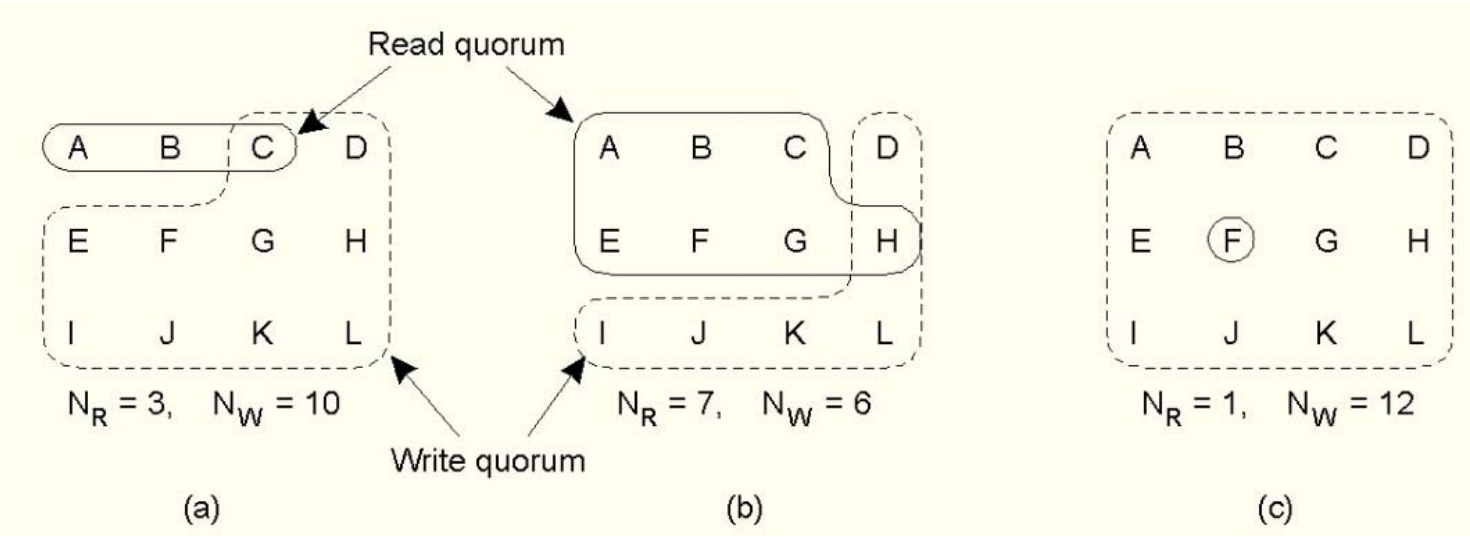

source: Tanenbaum and van Steen, Distributed Systems: Principles and Paradigms, Prentice-Hall, Inc. 2002

schwächere Replikationsformen

- gravierende Probleme bei vollständiger Replikationstransparenz
  - hohe Änderungskosten bei synchroner Propagierung von Änderungen
  - Verfügbarkeitsprobleme (besonders bei geographischer Verteilung)
  - geringe Skalierbarkeit!
  - nicht anwendbar für mobile Replikate (meist offline)
- DBS-Hersteller (Oracle, IBM, MS) unterstützen schwächere Konsistenzformen mit asynchroner Aktualisierung der Kopien
  - Schnappschuß-Replikation
  - "fast" aktuelle Kopien, z.B. für Unterstützung einer schnellen Katastrophen-Recovery
- bei n Änderungsknoten pro Objekt („Update Anywhere“):
  - asynchrones Refresh führt zu Konsistenzproblemen
  - anwendungsspezifische Konflikt-Behebung (Merge-Replikation)

Refresh-Alternativen

- baldmögliche Weiterleitung (ASAP) nach Commit der Änderungstransaktion oder verzögert (Timer, #Änderungen)
  - Verzögerungsdauer: Aktualität vs. Overhead
- Push- vs. Pull-Replikation
  - Push: Notifikation von Änderungen durch Master / Publisher
  - Pull: Probing durch Slave/Subsriber (z. B. mobiles Endgerät)
- einfache Replikate (Kopien) vs. abgeleitete Replikation (Ergebnisse einer SQL-Operation)
- vollständige vs. inkrementelle Aktualisierung von Replikaten
  - Übertragung der Objektkopien / Werte
  - Verwendung von Triggern
  - Übertragung der Log-Daten

Primärkopien-Verfahren

- asymmetrisches Verfahren
  - 1 Primärkopie (primary copy): *publisher*
  - n Sekundärkopien pro Objekt: *subscriber*
- Bearbeitung von Schreib- und Lesesperren beim Primärkopien-Rechner
- synchrone Änderungen nur für Primärkopie
- verzögerte/asynchrone Aktualisierungen der Sekundärkopien
  - in der selben Commit-Reihenfolge wie bei Primärkopien-Rechner
  - Verwendung von Sequenz-Nummern

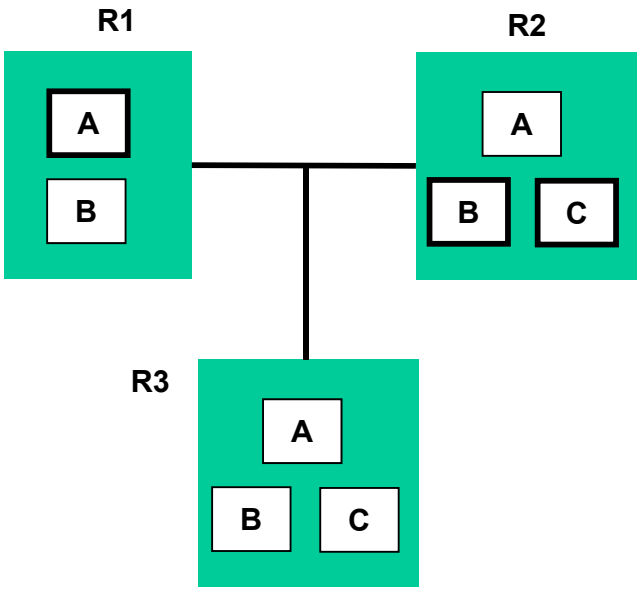

Die Primärkopien verschiedener Objekte können auf verschiedenen Rechnern liegen

Primärkopien-Verfahren: Lesezugriffe

mehrere Alternativen

- Sperren und Lesen der Primärkopie
  - aktuelle Daten
  - Replikation wird nicht genutzt!
- lokale Kopie lesen ohne Sperre
  - effizient
  - lokale Kopie kann leicht veraltet sein (keine 1-Kopien-Serialisierbarkeit)
- Lesesperre beim Primärkopien-Rechner + Lesen einer aktuellen (lokalen) Kopie
  - z.B. Test über Versionsnummer bei Primärkopien-Rechner
  - strenge Konsistenz, jedoch geringe Kommunikationseinsparung

Primärkopien-Verfahren: Fehlerbehandlung

- Netzwerk-Partitionierung: nur in Partition mit Primärkopie können weiterhin Änderungen erfolgen
- Ausfall des Primary-Copy-Rechners verhindert weitere Schreibzugriffe bis zu dessen Recovery
- Alternative: Bestimmung eines neuen Primary-Copy-Rechners, z.B. mit Paxos-Protokoll
  - jede Änderung erfordert, dass Mehrheit der Kopien nicht nur Primärkopie geändert wird
  - auch nach Ausfall der Primärkopie entsteht kein Datenverlust und Verarbeitung kann mit aktuellen Daten fortgesetzt werden

Schnappschuß-Replikation

- Erzeugung einer materialisierten Sicht zur Nutzung an anderen Rechnern

  Beispiel:

```
CREATE SNAPSHOT  CS-BOOKS AS
                 SELECT  *
                 FROM BOOKS
                 WHERE TOPIC=7
REFRESHED  EVERY  MONTH;
```

- Merkmale
  - Schnappschuß meist nicht auf dem neuesten Stand (-> reduzierter Änderungsaufwand)
  - i.a. nur lesender Zugriff (-> keine Synchronisationskonflikte auf Kopien)
  - Replikation für Benutzer i.a. nicht transparent

Schnappschuß-Replikation (2)

- Aktualisierung der Kopie (Refresh)
  - periodisch (täglich, monatlich, etc.)
  - explizit auf Anforderung: **REFRESH SNAPSHOT** CS_BOOKS
- Refresh-Optionen in Oracle (für Materialized Views)
  - Refresh Type: Complete, Fast (incremental), Force (system-determined)
  - Refresh Interval: on demand, on commit, automatically on, never
- zahlreiche Anwendungsmöglichkeiten
  - besonders geeignet für Datennutzung auf mobilen Geräten

Merge-Replikation

- unsynchronisierte Änderung eines replizierten Objekts an mehreren Knoten (Multi-Master) mit asynchroner Propagierung der Änderungen
- Performance- und Verfügbarkeitsvorteile gegenüber synchroner Aktualisierung
- unabdingbar für mobile DB-Nutzung mit Änderungsbedarf (z.B. Außendienst-Mitarbeiter)
  - Eintragung neuer Kunden / Aufträge (geringe Konfliktgefahr)
- Probleme:
  - nachträgliche Konflikt-Behandlung
  - Mischen paralleler Änderungen (Merge-Replikation)

Beispiel für Änderungskonflikt bei unabhängiger Änderung

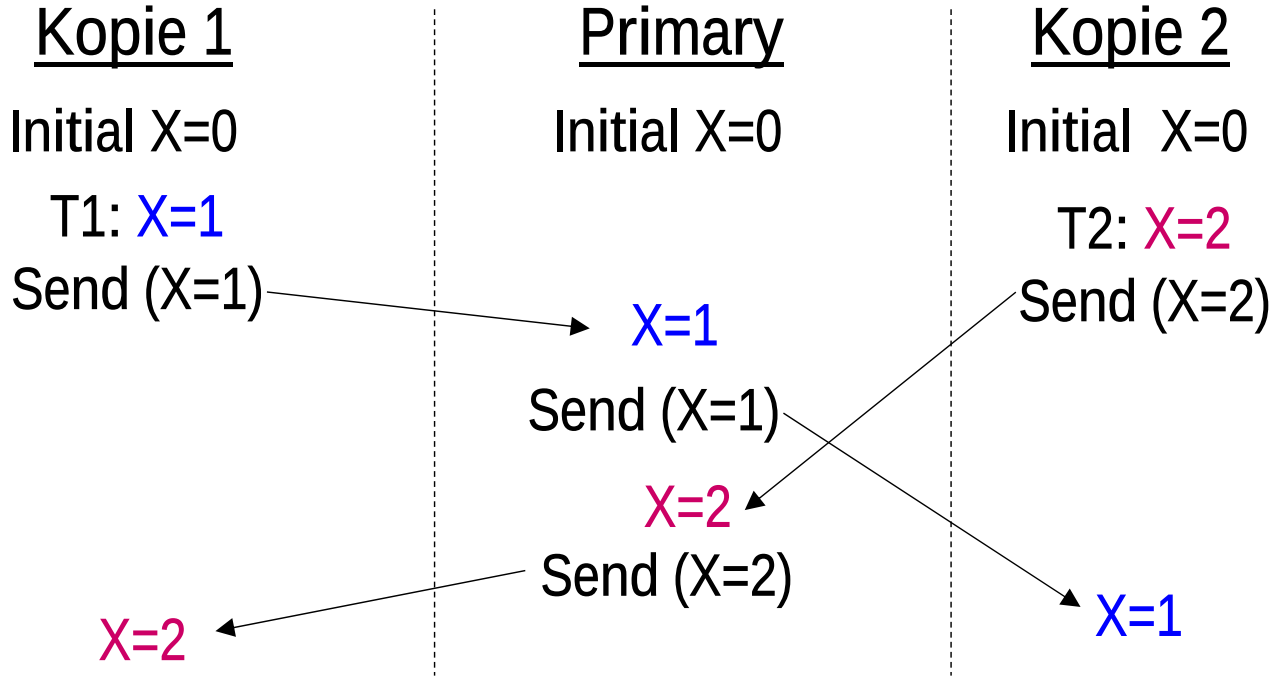

- Kopien enden in unterschiedlichen Zuständen

Merge-Replikation (2)

- Konfliktmöglichkeiten für
  - Update
  - Insert (z. B. Eindeutigkeit)
  - Delete
- Konflikterkennung
  - Objektänderungen enthalten Zeitstempel v der Vorgängerversion und neuen Wert
  - Konflikt: falls lokaler Zeitstempel einer zu aktualisierenden Objektversion abweicht von v
  - Konfliktwahrscheinlichkeit wächst mit Anzahl der änderbaren Replikate und Aktualisierungsverzögerung
- anwendungsspezifische Konflikt-Behandlung (reconciliation)
  - vordefinierte Strategien in ex. DBS: „last timestamp wins“, „site priority“, „average“ ...
  - benutzerdefinierte Konfliktauflösungsroutinen oder manuelle Konfliktbehebung
  - Gefahr von „lost updates“ und anderen Anomalien (keine Serialisierbarkeit)

Ablauf für “last timestamp wins”

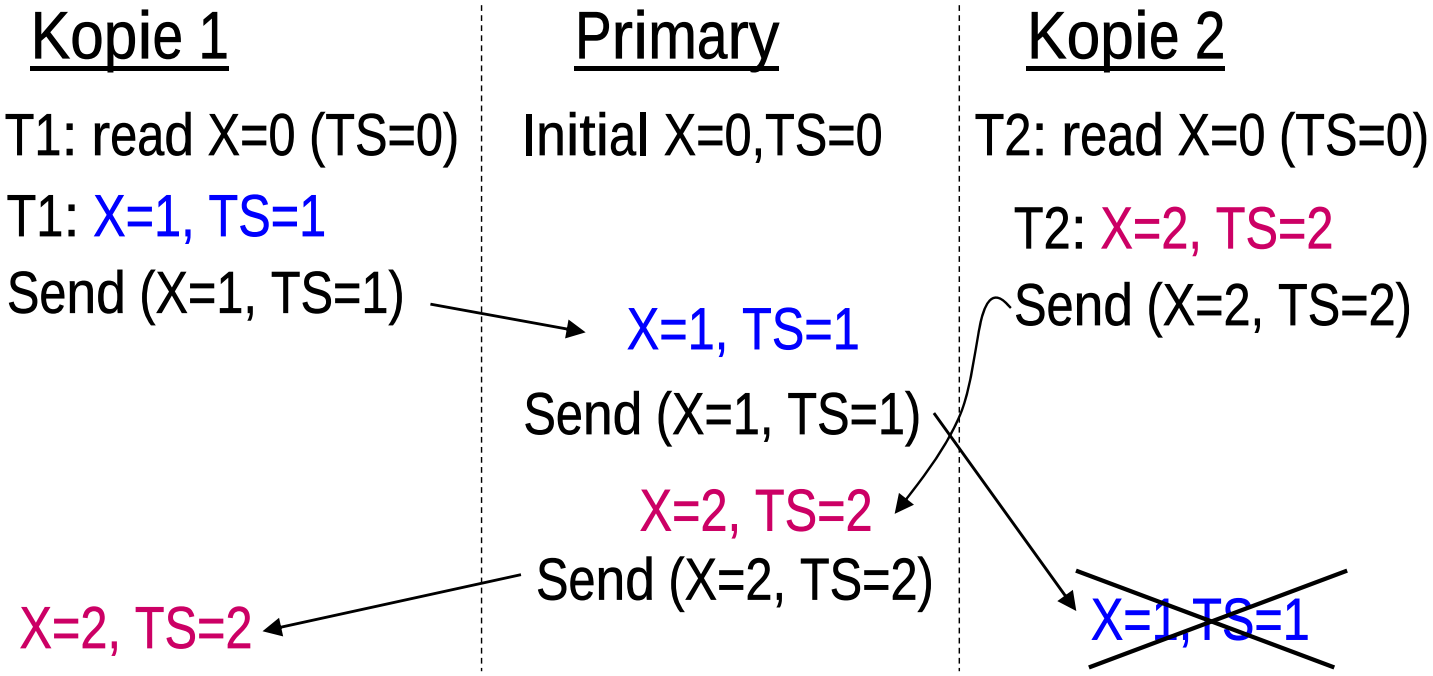

Kopien enden in gleichem Zustand, jedoch hat weder T1 noch T2 das Ergebnis der anderen Transaktion gesehen (nicht serialisierbar)

Katastrophen-Recovery

- traditionell: Zurückgehen auf Archivkopie
  - Verlust vieler Transaktionen falls aktuelle Log-Daten seit Erstellung der Archivkopie verloren gehen
  - zeitaufwendiges Einspielen der Archivkopie
- Remote Logging: Übertragung der Log-Daten an entferntes Rechenzentrum
- Alternative für hohe Verfügbarkeit: räumlich entfernte Rechenzentren mit replizierter Datenbank
  - Replikationswartung gemäß Primary-Copy-Verfahren (Primär- und Sekundärkopien)
  - kommerzielle DBS: meist zwei Rechenzentren, davon nur in einem Änderungsbetrieb
  - Web Data (Google, Yahoo, Ebay, Amazon): mehrere (<10) aktive Data Center mit replizierten Daten

Katastrophen-Recovery (2)

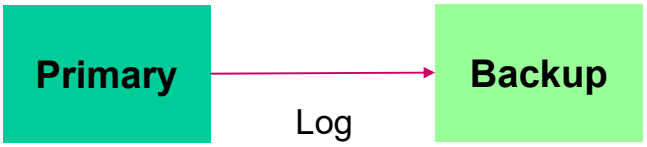

- passives Stand-By-System (Hot Stand-By)
  - Änderungen erfolgen nur im Primärsystem
  - Kopie dient als Stand-By bzw. wird nur für Queries genutzt (Entlastung des Primärsystems)
  - Redo-Log-Daten werden ständig zum Backup-System übertragen und DB-Kopie wird nachgefahren
  - bei asynchroner Übertragung gehen höchstens einige wenige Transaktionen im Kastastrophenfall verloren
  - für "wichtige" Transaktionen: synchrone Übertragung der Log-Daten (Commit-Verzögerung bis entfernte DB aktualisiert ist)

Katastrophen-Recovery: Sicherheitsstufen

- 1-sicher (1-safe)
  - lokales Commit am Primary (P)
  - asynchrone Übertragung der Änderungen an Backups (B)

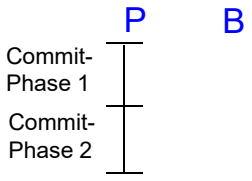

- 2-sicher (2-safe)
  - synchrone Aktualisierung der Backups
  - Kommunikation in Commit-Phase 1

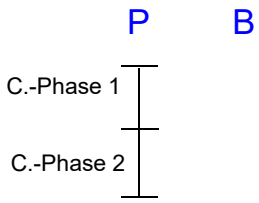

- "sehr sicher"
  - 2PC bzw. Paxos-Verfahren zwischen Primary u. Backups
  - alle Knoten (bzw. Mehrheit) müssen Commit zustimmen
  - nur sinnvoll bei gleichberechtigten Data Centers

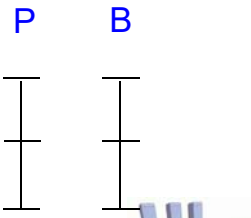

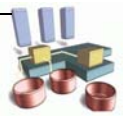

Geo-Replikation für Cloud-Daten

- mehrere geographisch verteilte Data Center mit replizierter Datenhaltung (meist 3-5 Replikate pro Objekt)
  - schnelle Zugriffe auf räumlich nahe Replikate
  - Gewährleistug einer sehr hohen Verfügbarkeit gegenüber Ausfällen innerhalb Data Center sowie Katastrophen
- Beisipielansätze: Cassandra, Yahoo Pnuts, Google MegaStore / Spanner
- meist synchrone Replikation („sehr sicher“) für Änderungen, um Datenverlust zu vermeiden
  - Google nutzt dazu Paxos-Verfahren zur konsistenten Aktualisierung der Replikate, eingebettet in 2PC
  - Beispiel für Client-initiiertes 2PC für Änderung von dreifach replizierten Objekten X,Y,Z

(dunkel: Paxos Leader pro Replikatgruppe)

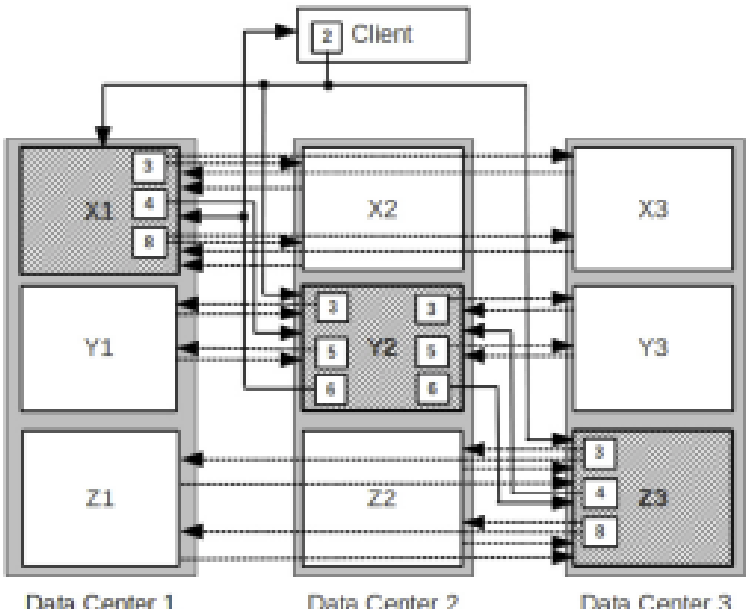

Quelle: D. Agrawal et al.: Managing Geo-replicated Data in Multi-Datacenters. LNCS 7813, 2013

Replikation in Parallelen DBS

- replizierte Zuordnung von Fragmenten im Rahmen der Datenallokation
- Ziele einer Replikation
  - Fehlertoleranz gegenüber Externspeicherfehlern
  - Fehlertoleranz gegenüber Rechnerausfällen
  - günstige Lastbalancierung im Normalbetrieb und Fehlerfall
- Lokalität und Knotenautonomie weniger/nicht relevant
- i.a. synchrone (parallele) Aktualisierung der Replikate
- drei Replikationsansätze mit doppelter Speicherung der Daten
  - Spiegelplatten
  - Verstreute Replikation (NCR Teradata)
  - Verkettete Replikation (Gamma-Prototyp)

Spiegelplatten

- weitverbreitet zur Maskierung von Plattenfehlern
- verbesserte Lese-Performanz
- Shared Nothing: Replikation auf einen Knoten beschränkt

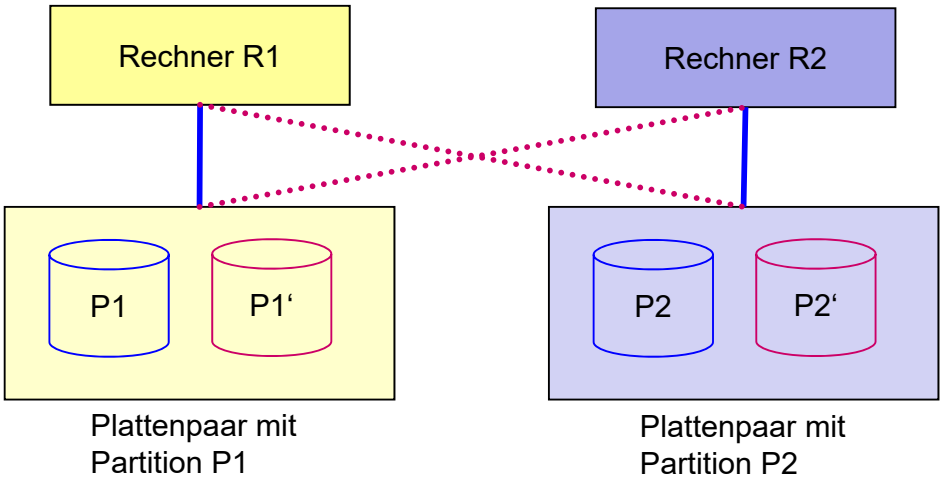

- Rechnerausfall erfordert Übernahme der kompletten Partition durch zweiten Rechner
  => sehr ungünstige Lastbalancierung im Fehlerfall

Verstreute Replikation (Interleaved Declustering)

- Ziel: bessere Lastbalancierung im Fehlerfall
- Datenknoten einer Relation werden in Gruppen von je G Rechnern unterteilt (node groups)
  - Replikate zu Daten eines Rechners werden gleichmäßig unter den G-1 anderen Rechnern der Gruppe verteilt
  - nach Crash erhöht sich Last jedes überlebenden Rechners der Gruppe gleichmäßig um Faktor G/G-1

Beispiel (D=G=4)

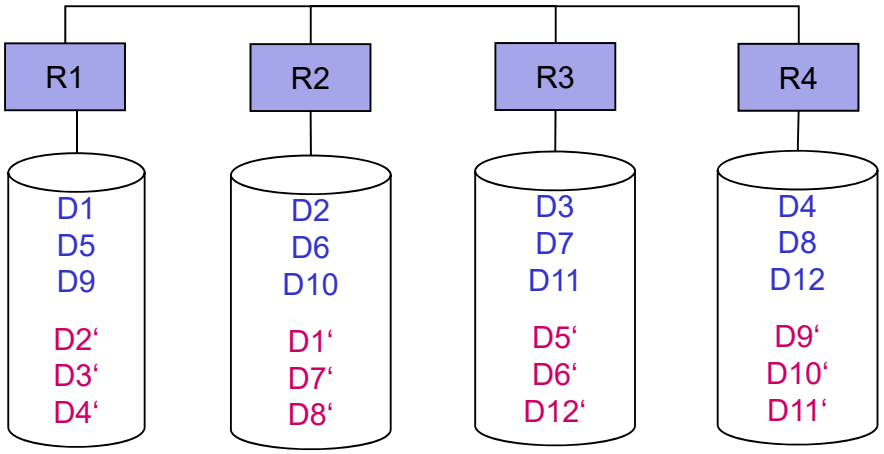

Verstreute Replikation (2)

- Ausfall mehrerer Rechner beeinträchtigt Datenverfügbarkeit nicht, sofern verschiedene Gruppen betroffen sind
- Wahl von G erlaubt Kompromiß zwischen Verfügbarkeit und Lastbalancierung
  - Extremfälle: G=D (= Verteilgrad der Relation) und G=2 (Spiegelplatten)
- Nutzung der Replikate zur Lastbalancierung im Normalbetrieb aufwendig

Verkettete Replikation (Chained Declustering)

- Ziele: hohe Verfügbarkeit von Spiegelplatten + günstige Lastbalancierung (im Fehlerfall) der verstreuten Replikation
- Kopie der Partition von Rechner R_i wird vollständig am "nächsten" Rechner $R_{(i \text{ MOD } G) + 1}$ der Gruppe gehalten
- selbst Mehrfachausfälle in einer Gruppe erhalten die Verfügbarkeit aller Daten, so lange nicht zwei benachbarte Rechner ausfallen

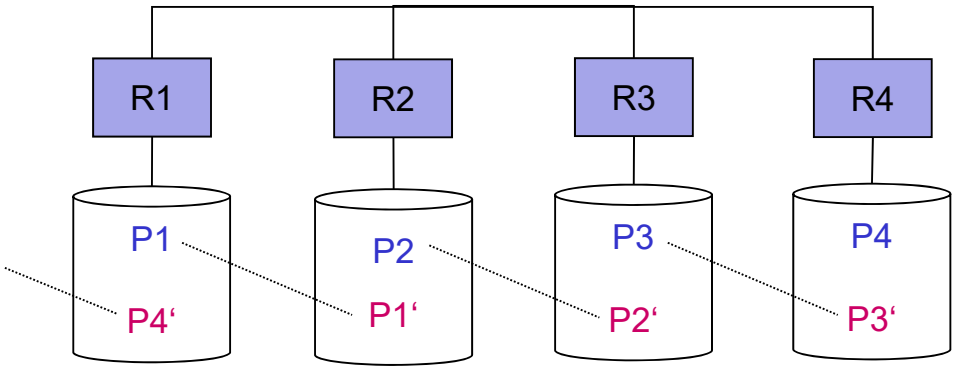

Verkettete Replikation (2)

- Knotenausfall: Zugriffe auf betroffener Partition sind vollständig vom "nächsten" Rechner der Gruppe auszuführen
- Zugriffe auf den anderen Partitionen sind unter den beiden Kopien umzuverteilen, so daß Lastbalancierung erreicht wird
- keine Umverteilung von Daten, sondern nur Anpassung der Verteilungsinformationen

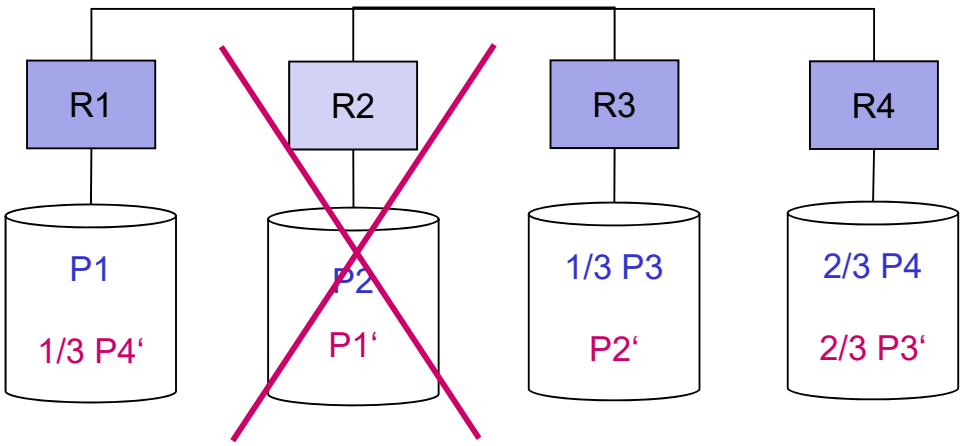

Zusammenfassung

- Zielkonflikte: Leistung vs. Verfügbarkeit für Leser vs. Schreiber / Konsistenzanforderungen
- Synchronisationsansätze: ROWA, Voting, Primary Copy
- Probleme bei 1-Kopien-Serialisierbarkeit
  - synchrone Aktualisierung ist aufwändig (Commit-Protokoll)
  - geringe Skalierbarkeit
- kommerzielle DBS unterstützen unterschiedl.Replikationsmodelle
  - Publish/Subscribe-Ansätze , Primärkopien vs. „Update Anywhere“
  - synchrone oder verzögerte Übertragung von Änderungen
  - einfache Kopien und abgeleitete (transformierte) Replikate
  - parallele Änderungen mit Nutzerkontrolle (Merge-Replikation)
  - Parallele DBS: Duplizierung mit synchroner (paralleler) Aktualisierung
- Cloud Data: Geo-Replikation über mehrere Data Center
  - „billige“ Rechner mit hoher Ausfallwahrscheinlichkeit erfordern sichere Protokolle gegen Datenverlust, z.B. mit 2PC und Paxos