DATENBANKANWENDUNG

Wintersemester 2013/2014

Holger Schwarz
Universität Stuttgart, IPVS
holger.schwarz@ipvs.uni-stuttgart.de

Beginn:	**23.10.2013**
Mittwochs:	**11.45 – 15.15 Uhr, Raum 46-268 (Pause 13.00 – 13.30)**
Donnerstags:	**10.00 – 11.30 Uhr, Raum 46-268**
	11.45 – 13.15 Uhr, Raum 46-260

http://wwwlgis.informatik.uni-kl.de/cms/courses/datenbankanwendung/

5. Transaktionsverwaltung

- **Transaktionsparadigma**
  - ACID-Eigenschaften
  - Programmierschnittstelle
  - Mögliche Ausgänge einer TA
- **Gefährdung der DB-Konsistenz**
- **Transaktionsverwaltung und Transaktionsablauf**
  - Architektur
  - SQL-Operationen: COMMIT WORK, ROLLBACK WORK
  - Zustände und Zustandsübergänge
  - Verarbeitung in verteilten Systemen
- **Commit-Protokolle**
  - Einsatz von Commit-Protokollen (zentralisierter TA-Ablauf)
  - **2PC (Zweiphasen-Commit-Protokoll)**
    - verteilter TA-Ablauf
    - Fehleraspekte
    - Kostenbetrachtungen
  - 2PC-Protokoll in Bäumen
    - Bestimmen eines Koordinators
    - Hierarchisches 2PC
  - TA-Verarbeitung in offenen Systemen
- **BASE (basically available, soft state, eventually consistent)**
  - eine ACID-Alternative
  - CAP-Theorem

Transaktionsparadigma

- **Ablaufkontrollstruktur: Transaktion**

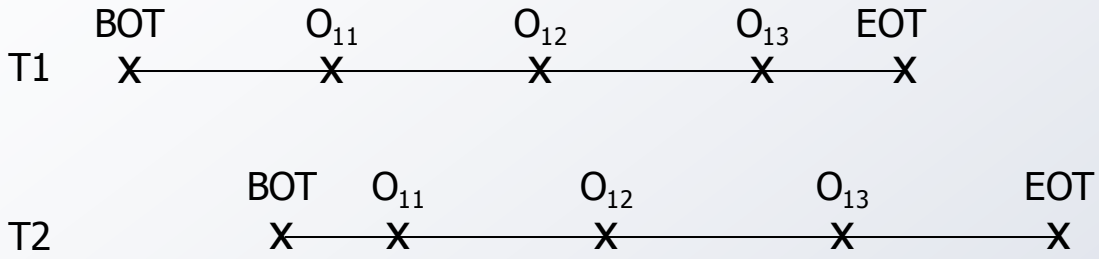

- **Transaktionsparadigma**
  - führt ein neues Verarbeitungsparadigma ein
  - ist Voraussetzung für die Abwicklung betrieblicher Anwendungen (mission-critical applications)
  - erlaubt „Vertragsrecht" in rechnergestützten IS zu implementieren

Transaktionsparadigma (2)

- **Welche Eigenschaften von Transaktionen sind zu garantieren?**
  - **Atomicity (Atomarität)**
    - TA ist kleinste, nicht mehr weiter zerlegbare Einheit
    - Entweder werden alle Änderungen der TA festgeschrieben oder gar keine („alles-oder-nichts"-Prinzip)
  - **Consistency**
    - TA hinterlässt einen konsistenten DB-Zustand, sonst wird sie komplett zurückgesetzt (siehe Atomarität)
    - Zwischenzustände während der TA-Bearbeitung dürfen inkonsistent sein
    - Endzustand muß die Integritätsbedingungen des DB-Schemas erfüllen
  - **Isolation**
    - Nebenläufig (parallel, gleichzeitig) ausgeführte TA dürfen sich nicht gegenseitig beeinflussen
    - Parallele TA bzw. deren Effekte sind nicht sichtbar
  - **Durability (Dauerhaftigkeit)**
    - Wirkung erfolgreich abgeschlossener TA bleibt dauerhaft in der DB
    - TA-Verwaltung muß sicherstellen, dass dies auch nach einem Systemfehler (HW- oder System-SW) gewährleistet ist
    - Wirkung einer erfolgreich abgeschlossenen TA kann nur durch eine sog. kompensierende TA aufgehoben werden

Transaktionsparadigma (3)

- **DB-bezogene Definition der Transaktion**

  Eine TA ist eine ununterbrechbare Folge von DML-Befehlen, welche die Datenbank von einem logisch konsistenten Zustand in einen neuen logisch konsistenten Zustand überführt.

⇨ Diese Definition eignet sich insbesondere für relativ kurze TA, die auch als **ACID-Transaktionen** bezeichnet werden.

- **Transaktionsprogramm – Beispiel:**

```
BOT
  UPDATE  Konto
  . . .
  UPDATE  Schalter
  . . .
  UPDATE  Zweigstelle
  . . .
  INSERT  INTO Ablage (...)
COMMIT;
```

Transaktionsparadigma (4)

- **Programmierschnittstelle für Transaktionen:**
  - begin of transaction (BOT)
  - commit transaction ("commit work" in SQL)
  - rollback transaction ("rollback work" in SQL)

- **Mögliche Ausgänge einer Transaktion**

BOT	**BOT**	**BOT**
DML_1	**DML_1**	**DML_1**
DML_2	**DML_2**	**DML_2**
DML_3	**DML_3**	**DML_3**
⋮	⋮	⋮
DML_n	**DML_n**	**Systemausfall, Programmfehler, usw.**
COMMIT	**ROLLBACK**	**erzwungenes ROLLBACK**
normales Ende	**abnormales Ende**	**erzwungenes abnormales Ende**

Gefährdung der DB-Konsistenz

	Korrektheit der Abbildungshierarchie	Übereinstimmung zwischen DB und Miniwelt
durch das Anwendungs-programm	Mehrbenutzer-Anomalien Synchronisation	unzulässige Änderungen Integritätsüberwachung des DBVS TA-orientierte Verarbeitung
durch das DBVS und die Betriebsumgebung	Fehler auf den Externspeichern, Inkonsistenzen in den Zugriffs-pfaden Fehlertolerante Implementierung, Archivkopien (Backup)	undefinierter DB-Zustand nach einem Systemausfall Transaktionsorientierte Fehler-behandlung (Recovery)

Transaktionsverwaltung

- **Wesentliche Abstraktionen aus Sicht der DB-Anwendung**
  - Alle Auswirkungen auftretender Fehler bleiben der Anwendung verborgen (*failure transparency*)
  - Es sind keine anwendungsseitigen Vorkehrungen zu treffen, um Effekte der Nebenläufigkeit beim DB-Zugriff auszuschließen (*concurrency transparency*)

  ⇨ Gewährleistung einer fehlerfreien Sicht auf die Datenbank im logischen Einbenutzerbetrieb

- **Transaktionsverwaltung**
  - koordiniert alle DBS-seitigen Maßnahmen, um ACID zu garantieren
  - besitzt drei wesentliche Komponenten zur/zum
    - Synchronisation
    - Logging und Recovery
    - Konsistenzsicherung/Regelverarbeitung
  - kann zentralisiert oder verteilt (z.B. bei VDBS) realisiert sein
  - soll Transaktionsschutz für heterogene Komponenten bieten

Transaktionsverwaltung (2)

- **Einsatz kooperierender Ressourcen-Manager (RM)**
  - RM sind Systemkomponenten, die **Transaktionsschutz für ihre gemeinsam nutzbaren Betriebsmittel** (BM) bieten
  - RM gestatten die externe Koordination von BM-Aktualisierungen durch spezielle Commit-Protokolle
  - ⇨ Gewährleistung von ACID für DB-Daten und auch für andere BM (persistente Warteschlangen, Nachrichten, Objekte von persistenten Programmiersprachen)
- **Ziel:** TA-orientierte Verarbeitung in heterogenen Systemen

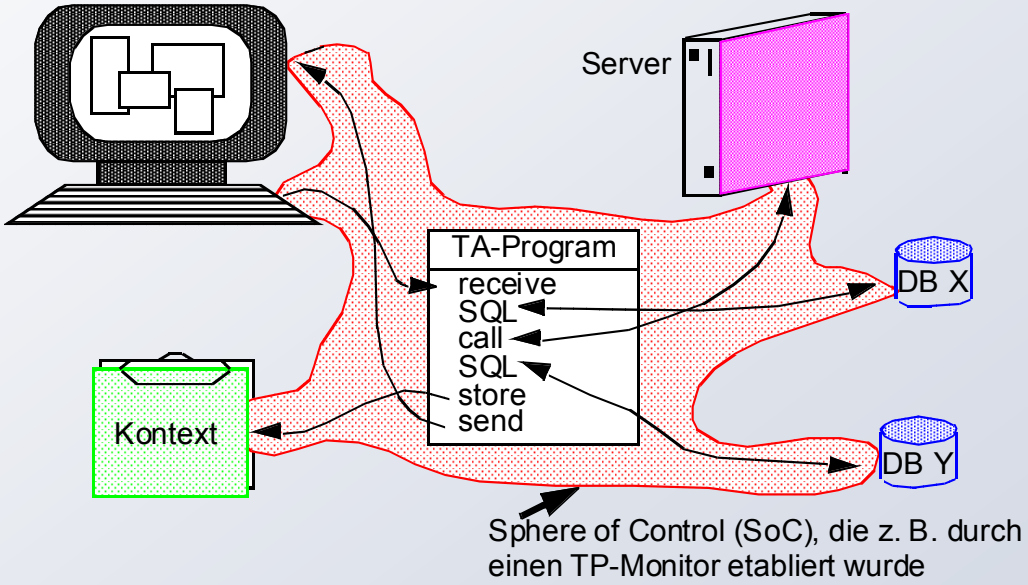

⇨ Die gesamte verteilte Verarbeitung in einer SoC ist eine ACID-TA

- alle Komponenten werden durch die TA-Dienste integriert
- für die Kooperation ist eine Grundmenge von Protokollen erforderlich

Transaktionsverwaltung (3)

- **Abstraktes Architekturmodell für die Transaktionsverwaltung**
  (für das Read/Write-Modell auf Seitenbasis)

- **Transaktionsverwalter**
  - Verteilung der DB-Operationen in VDBS und Weiterreichen an den Scheduler
  - zeitweise Deaktivierung von TA (bei Überlast)
  - Koordination der Abort- und Commit-Behandlung

- **Scheduler** (Synchronisation)
  - kontrolliert die Abwicklung der um DB-Daten konkurrierenden TA

- **Recovery-Komponente**
  - sorgt für die Rücksetzbarkeit/Wiederholbarkeit der Effekte von TA

- **DB-Pufferverwalter**
  - stellt DB-Seiten bereit und gewährleistet persistente Seitenänderungen

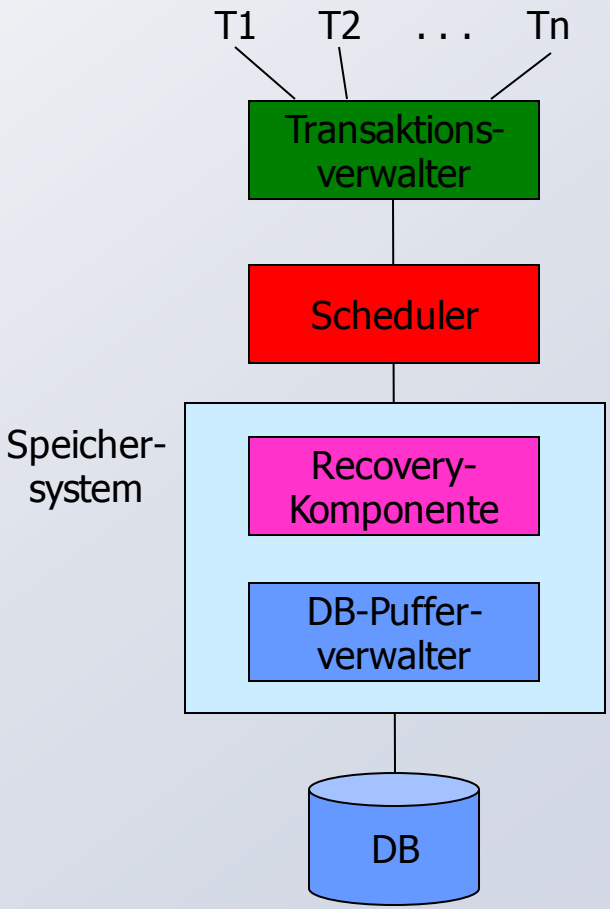

Zustände einer Transaktion

- **Zustandsübergangs-Diagramm**

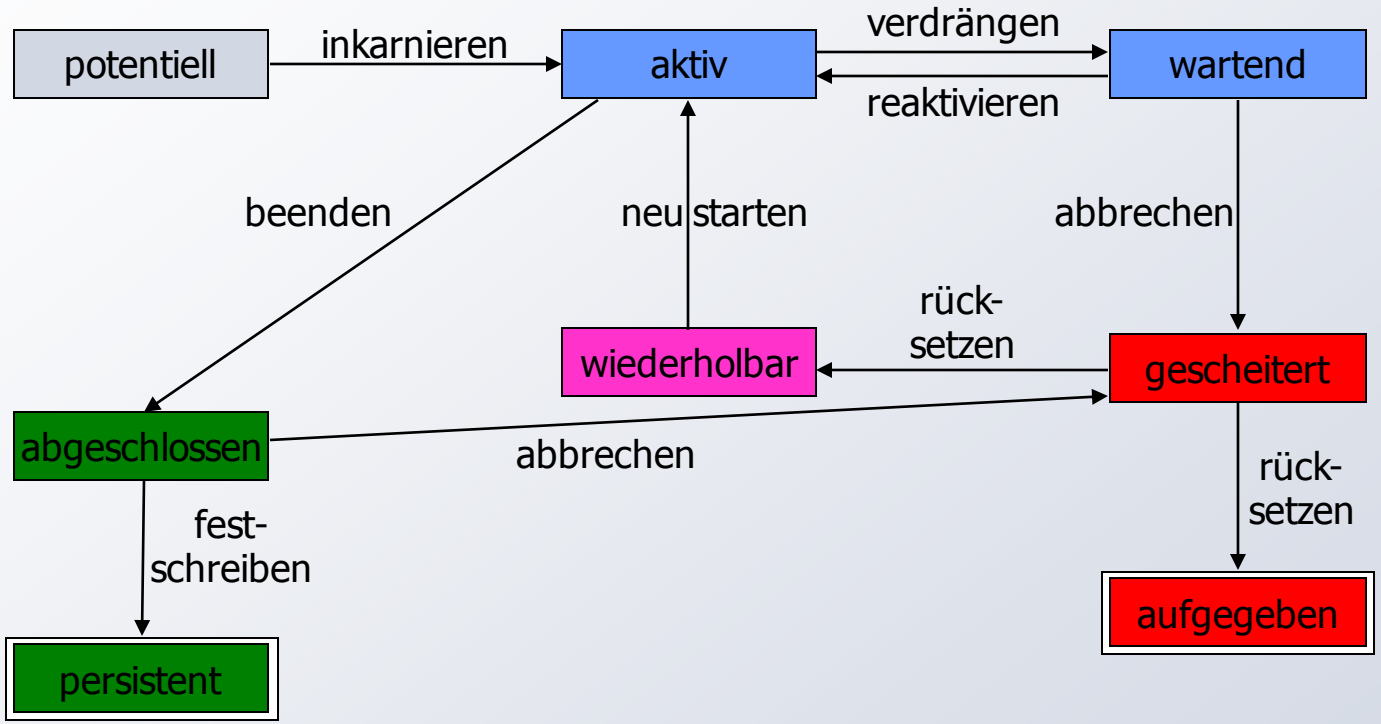

- **Transaktionsverwaltung**
  - muß die möglichen Zustände einer TA kennen und
  - ihre Zustandsübergänge kontrollieren/auslösen

Zustände einer Transaktion (2)

- **TA-Zustände**
  - **potentiell**
    - TAP wartet auf Ausführung
    - Beim Start werden, falls erforderlich, aktuelle Parameter übergeben
  - **aktiv**
    - TA konkurriert um Betriebsmittel und führt Operationen aus
  - **wartend**
    - Deaktivierung bei Überlast
    - Blockierung z.B. durch Sperren
  - **abgeschlossen**
    - TA kann sich (einseitig) nicht mehr zurücksetzen
    - TA kann jedoch noch scheitern (z.B. bei Konsistenzverletzung)
  - **persistent** (Endzustand)
    - Wirkung aller DB-Änderungen werden dauerhaft garantiert
  - **gescheitert**
    - Vielfältige Ereignisse können zum Scheitern ein TA führen (siehe Fehlermodell, Verklemmung usw.)
  - **wiederholbar**
    - Gescheiterte TA kann ggf. (mit demselben Eingabewerten) erneut ausgeführt werden
  - **aufgegeben** (Endzustand)

Schnittstelle zwischen AP und DBS – transaktionsbezogene Aspekte

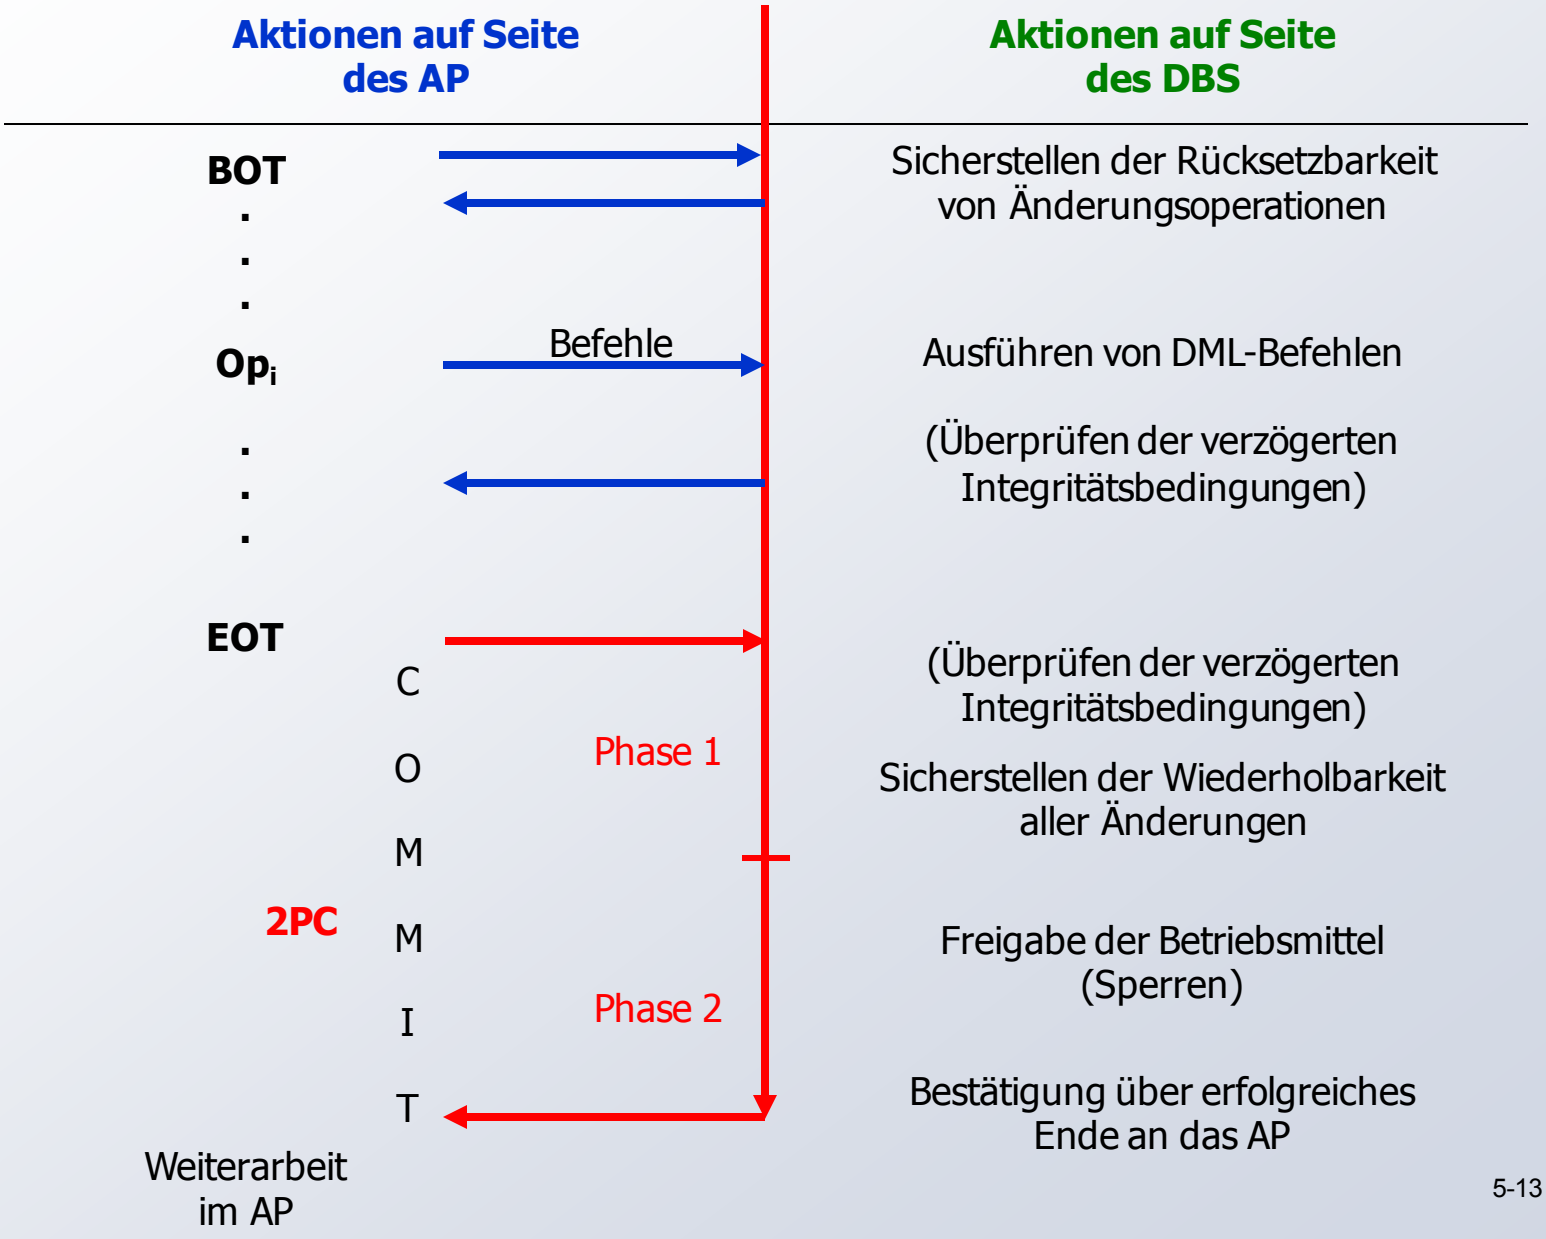

Verarbeitung in Verteilten Systemen

- Ein ***verteiltes System*** besteht aus autonomen Subsystemen, die koordiniert zusammenarbeiten, um eine gemeinsame Aufgabe zu erfüllen
  - Client/Server-Systeme (C/S), Doppelrolle von Servern:
    Sie können wiederum als Clients anderer Server auftreten!
  - Mehrrechner-DBS, . . .
- **Beispiel:** The „Coordinated Attack" Problem

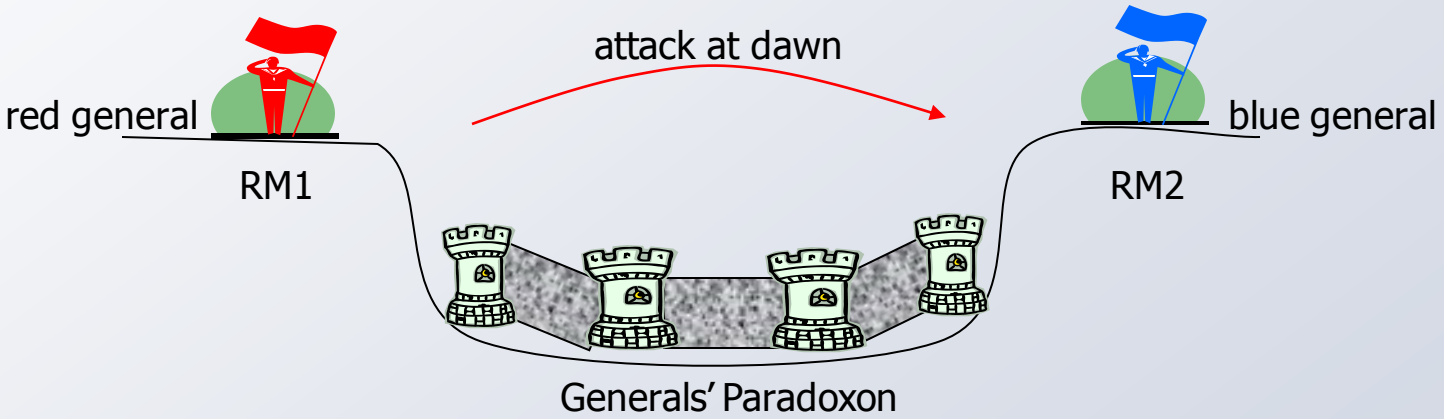

Wie wird die Eindeutigkeit einer Entscheidung bei Unsicherheit in einer verteilten Situation erreicht?

Verarbeitung in Verteilten Systemen (2)

- **Grundproblem verteilter Systeme**

  Das für verteilte Systeme charakteristische Kernproblem ist der Mangel an globalem (zentralisiertem) Wissen

  ⇨ **symmetrische Kontrollalgorithmen sind oft zu teuer oder zu ineffektiv**
  ⇨ **fallweise Zuordnung der Kontrolle**

- **Annahmen im allgemeinen Fall**
  - nicht nur Verlust (omission) von Nachrichten (Bote/Kurier wird gefangen)
  - sondern auch ihre bösartige Verfälschung (commission failures)

  ⇨ **dann komplexere Protokolle erforderlich:**
  Distributed consensus (bekannt als Byzantine agreement)

Verarbeitung in Verteilten Systemen (3)

- **Fehlermodell**
  - **allgemein:**
    - Transaktionsfehler
    - Crash (i. Allg. einiger Rechner)
    - Gerätefehler
  - **speziell** (nur omission failures)**:**
    - Nachrichtenverluste
    - Nachrichten-Duplikate: dieselbe Nachricht erreicht ihr Ziel mehrmals, möglicherweise verschachtelt mit anderen Nachrichten
    - transiente Prozessfehler (soft crashs):
      Restart erforderlich, aber kein Datenverlust auf Externspeicher
    - Achtung: Wir schließen hier bösartige Verfälschungen von Nachrichten aus!

    ⇨ **keine speziellen Annahmen:**

    Kommunikationssystem arbeitet mit Datagrammen als einfachstem Typ von unbestätigten, sitzungsfreien Nachrichten

    ⇨ schwierige Fehlererkennung, z. B. oft über Timeout

Verarbeitung in Verteilten Systemen (4)

- **Erweitertes Transaktionsmodell**

  verteilte Transaktionsbearbeitung (Primär-, Teiltransaktionen) –
  zentralisierte Steuerung des Commit-Protokolls (vergleiche „Heirat")

1 Koordinator

N Teiltransaktionen (Agenten)

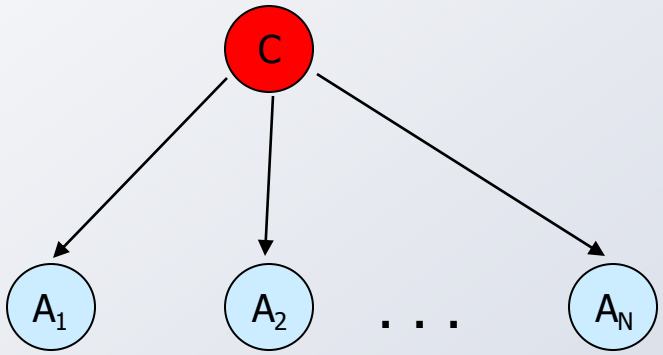

⇨ *rechnerübergreifendes Mehrphasen-Commit-Protokoll notwendig, um Atomarität einer globalen Transaktion sicherzustellen*

Commit-Protokolle

- **Allgemeine Anforderungen an geeignetes Commit-Protokoll:**
  - Geringer Aufwand (#Nachrichten, #Log-Ausgaben)
  - Minimale Antwortzeitverlängerung (Nutzung von Parallelität)
  - Robustheit gegenüber Rechnerausfällen und Kommunikationsfehlern

⇨ Zentralisiertes Zweiphasen-Commit-Protokoll stellt geeignete Lösung dar

Zentralisiertes Zweiphasen-Commit

* synchrone Log-Ausgabe (log record is force-written)
"End" ist wichtig für Garbage Collection im Log von C

Zentralisiertes Zweiphasen-Commit (2)

- **Protokoll (Basic 2PC)**
  - Folge von Zustandsänderungen für Koordinator und für Agenten
    - Protokollzustand auch nach Crash eindeutig: synchrones Logging
    - Sobald C ein NO VOTE (FAILED) erhält, entscheidet er ABORT
    - Sobald C die ACK-Nachricht von allen Agenten bekommen hat, weiß er, dass alle Agenten den Ausgang der TA kennen

    ⇨ C kann diese TA vergessen, d. h. ihre Log-Einträge im Log löschen!

  - Warum ist das 2PC-Protokoll blockierend?
- **Aufwand im Erfolgsfall:**
  - Nachrichten:
  - Log-Ausgaben (forced log writes):

2PC: Zustandsübergänge

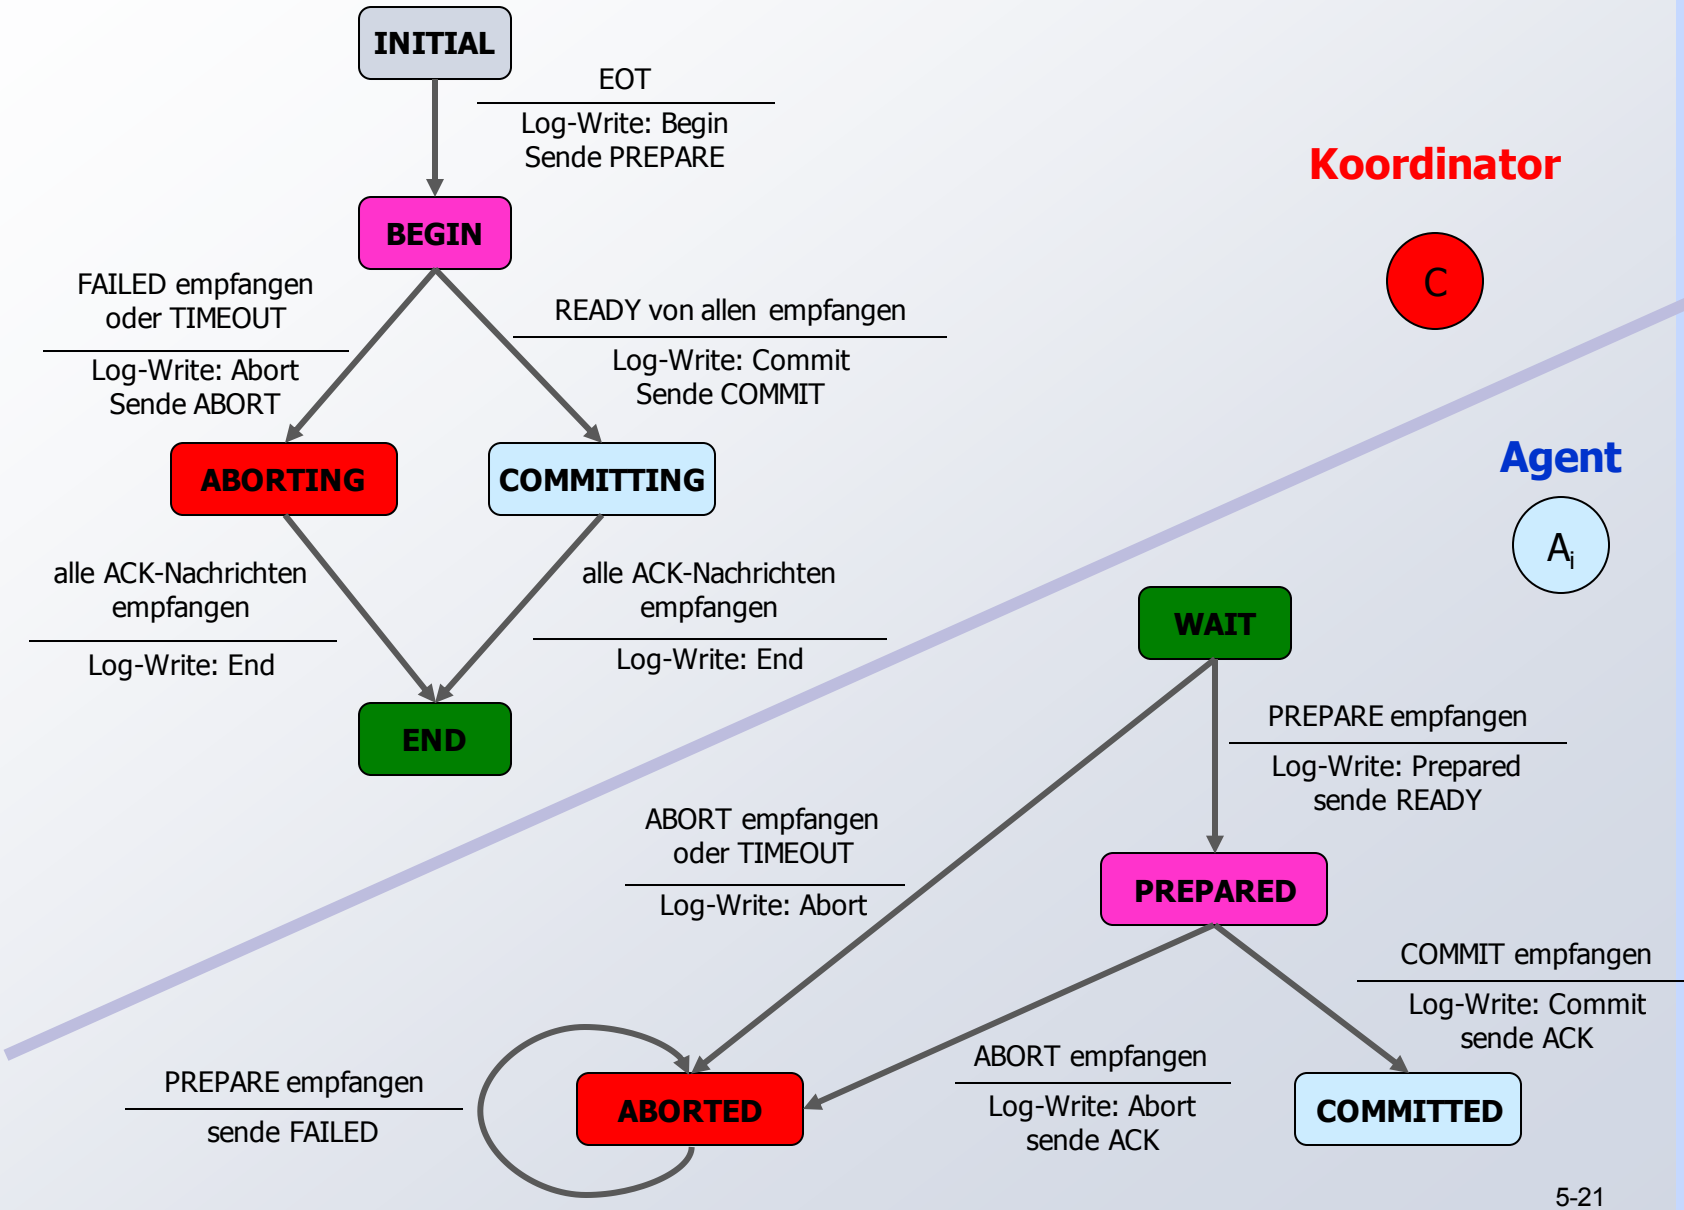

2PC: Fehlerbehandlung

- **Timeout-Bedingungen für Koordinator:**
  - **BEGIN** ⇨ setze Transaktion zurück; verschicke ABORT-Nachricht
  - **ABORTING** **COMMITTING** ⇨ vermerke Agenten, für die ACK noch aussteht

- **Timeout-Bedingungen für Agenten:**
  - **WAIT** ⇨ setze Teiltransaktion zurück (unilateral ABORT)
  - **PREPARED** ⇨ erfrage Transaktionsausgang bei Koordinator (bzw. bei anderen Rechnern)

- **Ausfall des Koordinatorknotens:** Vermerkter Zustand auf Log
  - **END** ⇨ UNDO bzw. REDO-Recovery, je nach Transaktionsausgang keine "offene" Teiltransaktionen möglich
  - **ABORTING** ⇨ UNDO-Recovery ABORT-Nachricht an Rechner, von denen ACK noch aussteht
  - **COMMITTING** ⇨ REDO-Recovery COMMIT-Nachricht an Rechner, von denen ACK aussteht
  - Sonst ⇨ UNDO-Recovery

- **Rechnerausfall für Agenten:** Vermerkter Zustand auf Log
  - **COMMITTED** ⇨ REDO-Recovery
  - **ABORTED** bzw. kein 2PC-Log-Satz vorhanden ⇨ UNDO-Recovery
  - **PREPARED** ⇨ Anfrage an Koordinator-Knoten, wie TA beendet wurde (Koordinator hält Information, da noch kein ACK erfolgte)

2PC-Protokoll in TA-Bäumen

- **Typischer AW-Kontext: C/S-Umgebung**
  - Beteiligte: Clients (C), Applikations-Server (AS), DB-Server (DB)
  - unterschiedliche *Quality of Service* bei Zuverlässigkeit, Erreichbarkeit, Leistung, ..

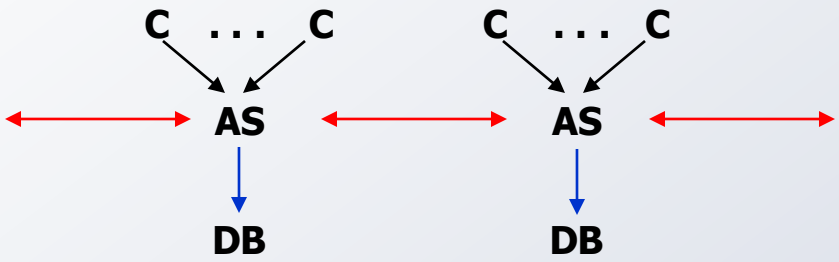

2PC-Protokoll in TA-Bäumen (2)

- **Wer übernimmt die Koordinatorrolle? – wichtige Aspekte**
  - TA-Initiator
  - Zuverlässigkeit und Geschwindigkeit der Teilnehmer
    - Anzahl der Teilnehmer
    - momentane Last
    - Geschwindigkeit der Netzwerkverbindung
  - Kommunikationstopologie und -protokoll
    - sichere/schnelle Erreichbarkeit
    - im LAN: Netzwerkadressen aller Server sind bekannt; jeder kann jeden mit Datagrammen oder neu eingerichteten Sitzungen erreichen
    - im WAN: „transitive" Erreichbarkeit; mehrere Hops erforderlich; Initiator kennt nicht unbedingt alle (dynamisch hinzukommenden) Teilnehmer (z. B. im Internet)

- **Im einfachsten Fall: TA-Initiator übernimmt Koordinatorrolle**

  ⇨ sinnvoll, wenn Initiator ein zuverlässiger, schneller und gut angebundener Applikations-Server ist!

2PC-Protokoll in TA-Bäumen (3)

- **Drei wichtige Beobachtungen**
  - Während der TA-Verarbeitung formen die involvierten Prozesse einen (unbalancierten) Baum mit dem Initiator als Wurzel. Jede Kante entspricht einer dynamisch eingerichteten Kommunikationsverbindung
  - Für die Commit-Verarbeitung kann der Baum „flachgemacht" werden
    - Der Initiator kennt die Netzwerkadressen aller Teilnehmerprozesse bei Commit (durch „piggybacking" bei vorherigen Aufrufen)
    - Nicht möglich, wenn die Server die Information, welche Server sie aufgerufen haben, kapseln
  - „Flachmachen" kann als spezieller Fall der Restrukturierung der C/S-Aufrufhierarchie gesehen werden
    - Es könnte auch ein zuverlässiger innerer Knoten als Koordinator ausgewählt werden
    - „Rotation" der Aufrufhierarchie um den neu gewählten Koordinatorknoten

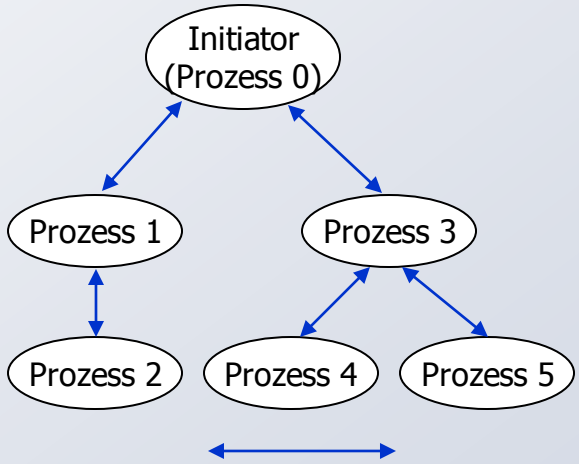

2PC-Protokoll in TA-Bäumen (4)

Initiator = Koordinator

Flaches 2PC

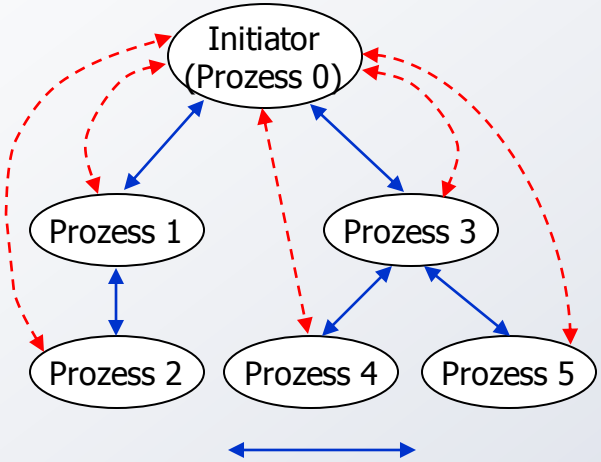

Kommunikation während Transaktionsausf.

Hierarchisches 2PC

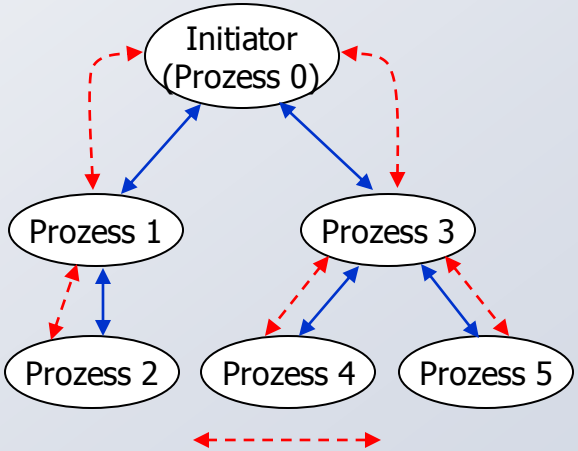

Kommunikation während Commitprotokoll

Hierarchisches 2PC

- **Allgemeineres Ausführungsmodell**
  - beliebige Schachtelungstiefe, angepasst an C/S-Modell
  - Modifikation des Protokolls für "Zwischenknoten"

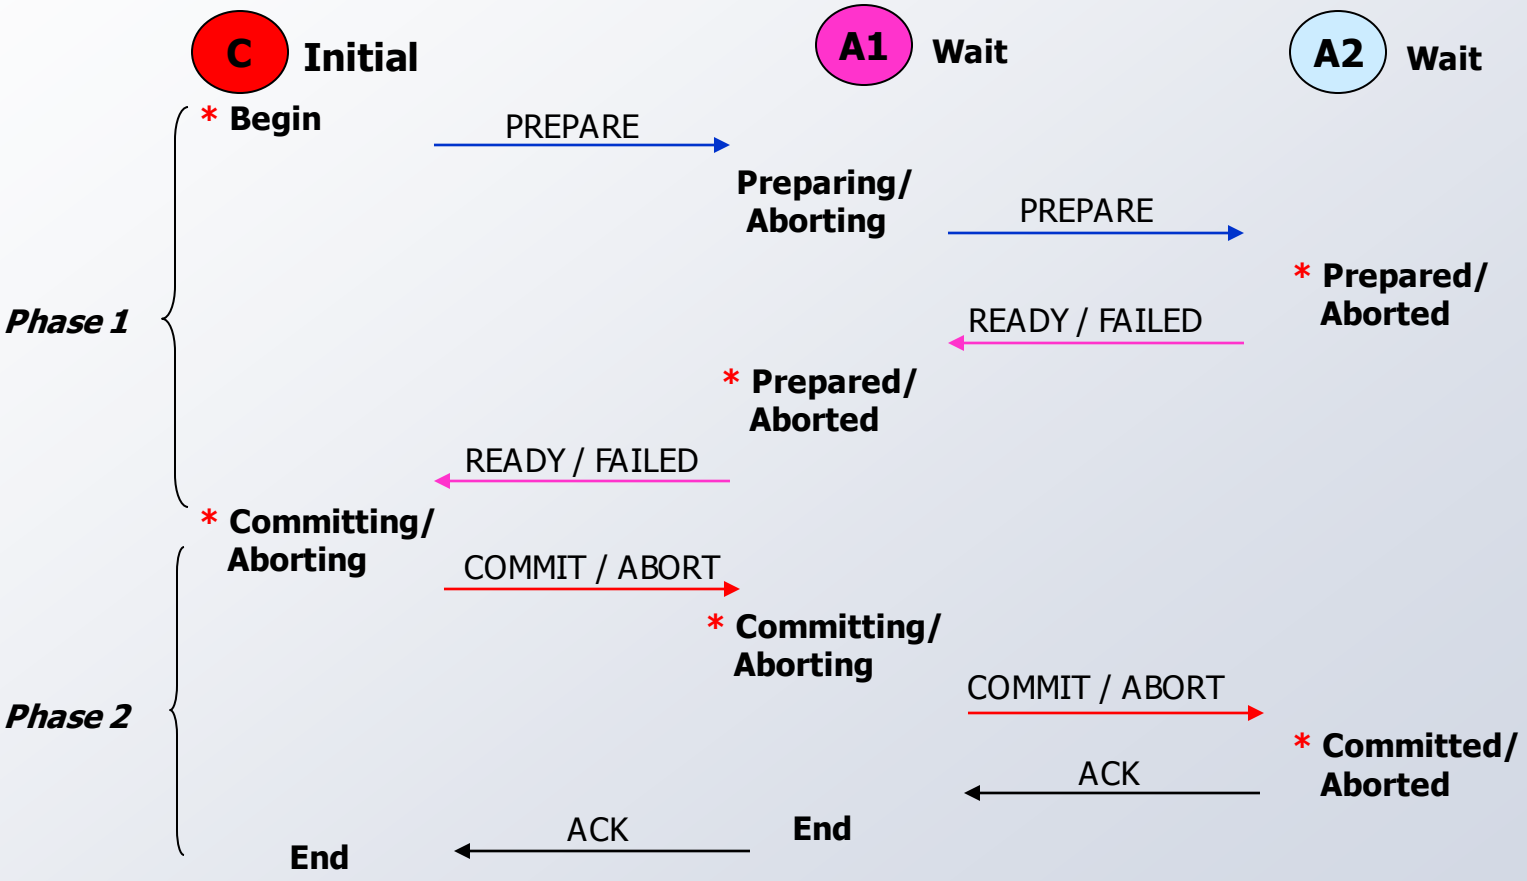

* synchrone Log-Ausgabe (log record is force-written)
"End" ist wichtig für Garbage Collection im Log

Hierarchisches 2PC (2)

- **Aufwand im Erfolgsfall:**
  - Nachrichten:
  - Log-Ausgaben (forced log writes):
  - Antwortzeit steigt mit Schachtelungstiefe
- **Problem Koordinator-/Zwischenknotenausfall**
  ⇨ Blockierung möglich!

Commit: Optimierungen

- **Beobachtung:**

  Commit-Protokoll
  - hat erheblichen Einfluss auf den TA-Durchsatz
    - substanzieller Anteil an der gesamten TA-Zeit bei kurzen TAs (Reservierungen, Buchungen, Kreditkartenvalidierung usw.)
    - Commit-Anteil bei TAs, die einen Satz ändern, etwa 1/3 der TA-Zeit
  - Schnelleres Commit-Protokoll kann Durchsatz verbessern
    - Reduktion der Commit-Dauer jeder TA
    - frühere Freigabe von Sperren, was die Wartezeit anderer TA verkürzt
    - Verkleinerung des Zeitfensters für die Blockierungsgefahr (Crash oder Nicht-Erreichbarkeit von C)

Commit: Optimierungen (2)

- **Wünschenswerte Charakteristika eines Commit-Protokolls**
  1. **A von ACID**: stets garantierte TA-Atomarität[1]
  2. Fähigkeit, den Ausgang der Commit-Verarbeitung einer TA „nach einer Weile" vergessen zu können
     - begrenzte Log-Kapazität von C
     - C muss sicher sein, dass alle Agenten den Commit-Ausgang für T_i kennen oder
     - C nimmt einen bestimmten Ausgang an, wenn er keine Information über T_i mehr besitzt
  3. Minimaler Aufwand für Nachrichten und synchrones Logging
  4. Optimierte Leistungsfähigkeit im fehlerfreien Fall (no-failure case)
     - ist wesentlich häufiger zu erwarten: optimistisches Verhalten
     - vor allem Minimierung von synchronen Log-Ausgaben (forced log write)
     - dafür zusätzlicher Recovery-Aufwand, um verlorengegangene Information im Fehlerfall wieder zu beschaffen
  5. Spezielle Optimierung für Leser
     (ihre Commit-Behandlung ist unabhängig vom Ausgang der TA)

1. May all your transactions commit and never leave you in doubt! (Jim Gray)

Commit: Kostenbetrachtungen

- **Vollständiges 2PC-Protokoll** (N = #Teil-TA, davon M = #Leser)
  - Nachrichten:
  - Log-Ausgaben:
  - Antwortzeit:
    längste Runde in Phase 1 (kritisch, weil Betriebsmittel blockiert)
    + längste Runde in Phase 2
- **Spezielle Optimierung für Leser**
  - Teil-TA, die nur Leseoperationen ausgeführt haben, benötigen keine Recovery!
    - C und D von ACID sind nicht betroffen
    - für A und I genügt das Halten der Sperren bis Phase 1
  - Lesende Teil-TA brauchen deshalb **nur an Phase 1** teilzunehmen
    - Mitteilung an (Zwischen-)Koordinator: „read-only vote"
    - dann Freigabe der Sperren
    - (Zwischen-)Koordinator darf (Teil-)Baum nur freigeben, wenn er ausschließlich *read-only votes* erhält
  - Nachrichten:
  - Log-Ausgaben:
    für N > M

1. Leseroptimierung läßt sich mit allen 2PC-Varianten kombinieren, wird jedoch nachfolgend nicht berücksichtigt

Commit: Kostenbetrachtungen (2)

- **1PC-Protokolle**
  - Bei Aufruf der Commit-Operation durch die TA sind bereits alle Agenten im PREPARED-Zustand
    - „implicit yes-vote" (IYV)
    - Modifikation der API erforderlich
- **Variante 1: A_i geht nach jedem Auftrag in den PREPARED-Zustand**
  - Jeder Aufruf von A_i: Work & Prepare
  - Einschränkungen bei verzögerten Integritätsprüfungen erforderlich (deferred)

  - Nachrichten:
  - durchschnittlich K Aufträge pro Agent;
    Log-Ausgaben:

Commit: Kostenbetrachtungen (3)

- **Variante 2: A_i geht beim letzten Auftrag in den PREPARED-Zustand**
  - Normaler Aufruf von A_i: Work
  - Letzter Aufruf von A_i: Work&Prepare;
    Lässt sich diese Art der Optimierung **immer** erreichen?
  - Nachrichten:
  - Log-Ausgaben:
- **Weglassen der expliziten ACK-Nachricht**
  - A_i fragt ggf. nach, falls ihn die Koordinatorentscheidung nicht erreicht
  - C weiß nicht, ob alle A_i die Commit/Abort-Nachricht erhalten haben

  ⇨ impliziert "unendlich langes Gedächtnis" von C

  - Nachrichten:
  - Log-Ausgaben:

Commit: Kostenbetrachtungen (4)

- **Spartanisches Protokoll**
  - A_i geht nach jedem Auftrag in den PREPARED-Zustand; Weglassen der expliziten ACK-Nachricht
  - Nachrichten:
  - Log-Ausgaben:
  - Nur letzter Aufruf: Work&Prepare;
    Log-Ausgaben:

⇨ **Log-Aufwand bleibt gleich (oder erhöht sich drastisch) !**

TA-Verarbeitung in offenen Systemen

Standards zur TA-Verwaltung

TA-Mgrs benötigen Standards, weil sie letztendlich den „Klebstoff" verkörpern, der die unterschiedlichen und heterogenen SW-Komponenten zusammenfügt.

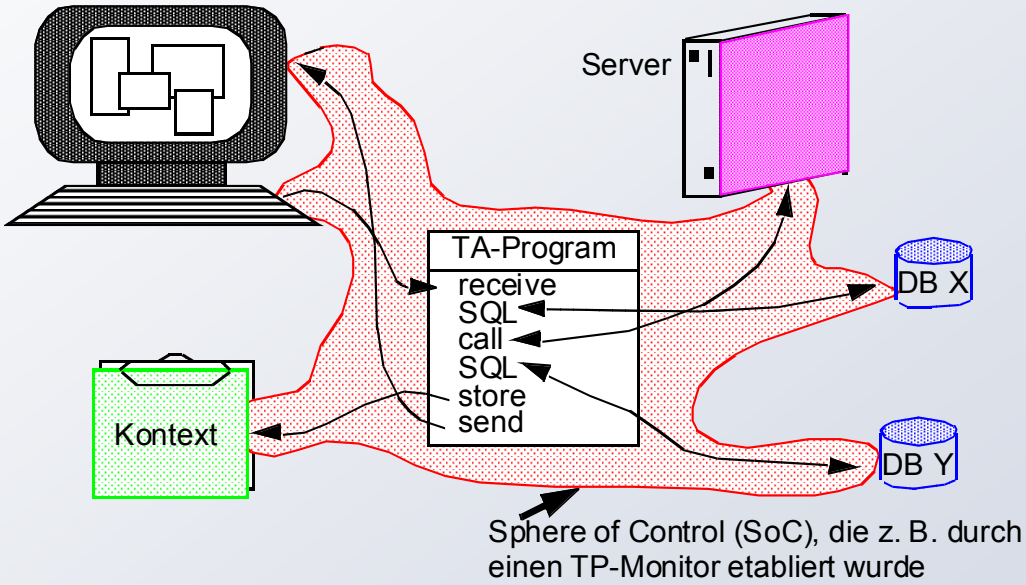

- Ihre AW laufen auf verschiedenartigen Plattformen und
- haben Zugriff zu verschiedenen DBs und RMs
- Die AW haben absolut kein Wissen voneinander

⇨ Einziger Weg zur Verknüpfung: **„Offene Standards"**

Bereitstellung von Schnittstellen zwischen TA-Mgr und RM, TA-Mgrs untereinander und TA-Mgr und AW

TA-Verarbeitung in offenen Systemen (2)

- **Standards kommen aus zwei Quellen**
  - ISO:
    OSI-TP spezifiziert die Nachrichtenprotokolle zur Kooperation von TA-Mgrs
  - X/OPEN definiert den allgemeinen Rahmen für TA-Verarbeitung:
    X/Open DTP (distributed transaction processing) stellt eine SW-Architektur dar, die mehreren AWP erlaubt, gemeinsam Betriebsmittel mehrerer RMs zu nutzen und die Arbeit der beteiligten RMs durch globale Transaktionen zusammenzufassen.

TA-Verarbeitung in offenen Systemen (3)

- **X/Open DTP (1991)** für die lokale Zusammenarbeit von Anwendung (AW), TA-Mgr (TM) und Resource-Mgrs (RMs)

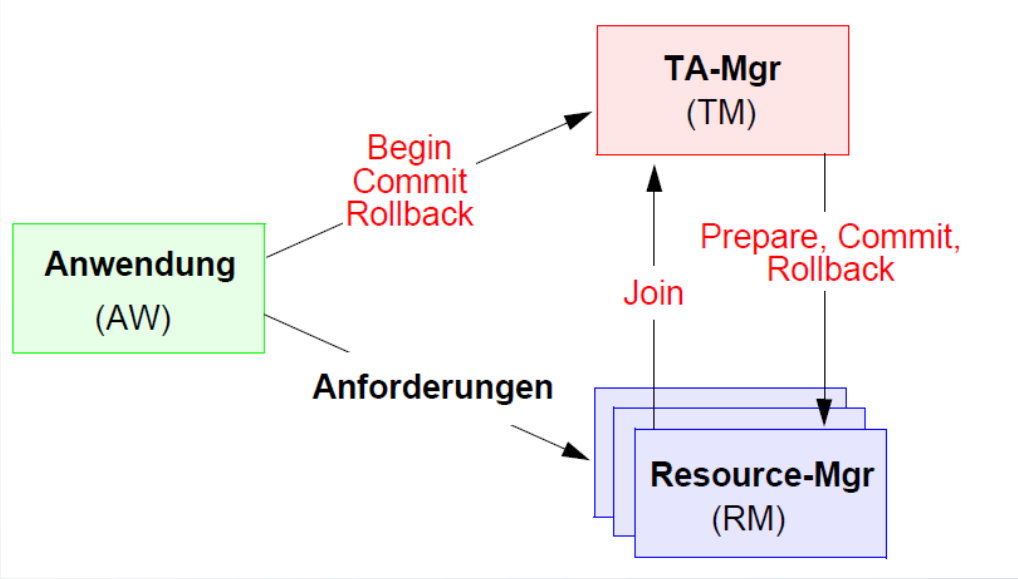

- **Standardisierung**
  - Schnittstelle zur Transaktionsverwaltung (TX: AW — TM)
  - Schnittstelle zwischen TM und RMs (XA: zur TA-Verwaltung und ACID-Kontrolle)
  - zusätzlich: Anforderungsschnittstellen (API, z. B. SQL)

TA-Verarbeitung in offenen Systemen (4)

- **TA-Ablauf**
  - Die AW startet eine TA, die vom lokalen TA-Mgr verwaltet wird
  - RMs melden sich bei erster Dienst-Anforderung beim lokalen TA-Mgr an (Join)
  - Wenn AW Commit oder Rollback ausführt (oder zwangsweise zurückgesetzt wird), schickt TA-Mgr Ergebnis zu den RMs (über Broadcast)

➥ **hier sorgen die RMs für Synchronisation und Logging**
in ihrem Bereich (private Lock-Mgr und Log-Mgr) — Warum?

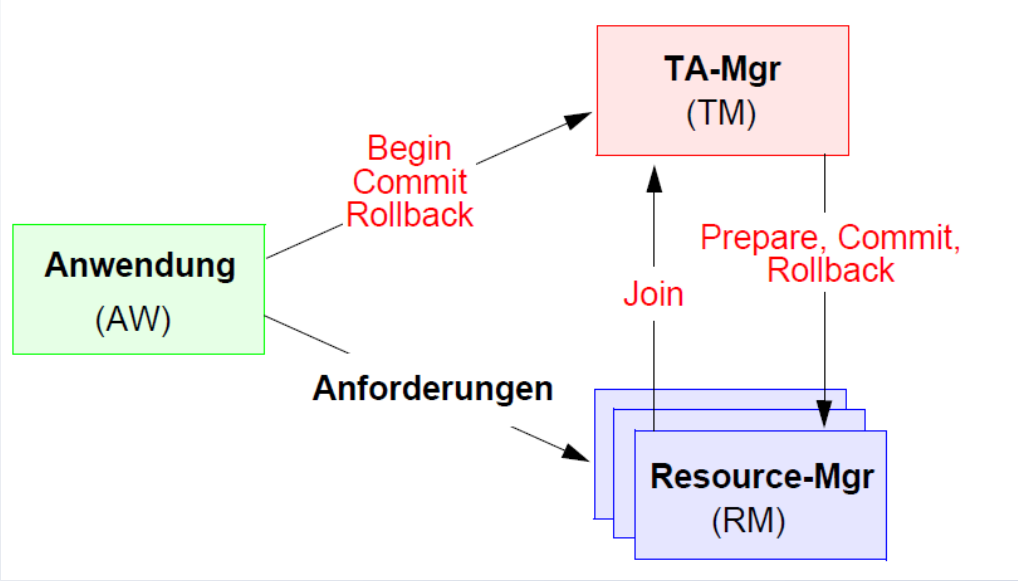

TA-Verarbeitung in offenen Systemen (5)

- **X/Open DTP (1993) standardisiert die verteilte TA-Verarbeitung.**
  - Es kommt der „Communication Resource Manager" (CRM) hinzu
  - XA+ erweitert Schnittstelle XA für den verteilten Fall

- **Definition von Schnittstellen auf der AW-Ebene**
  - TxRPC definiert transaktionalen RPC. Seine TA-Eigenschaften können ausgeschaltet werden (optional)
  - CPI-C V2 ist Konversations-schnittstelle (peer-to-peer), welche die OSI-TP-Semantik unterstützen soll
  - XATMI ist Konversations-schnittstelle für Client/Server-Beziehungen

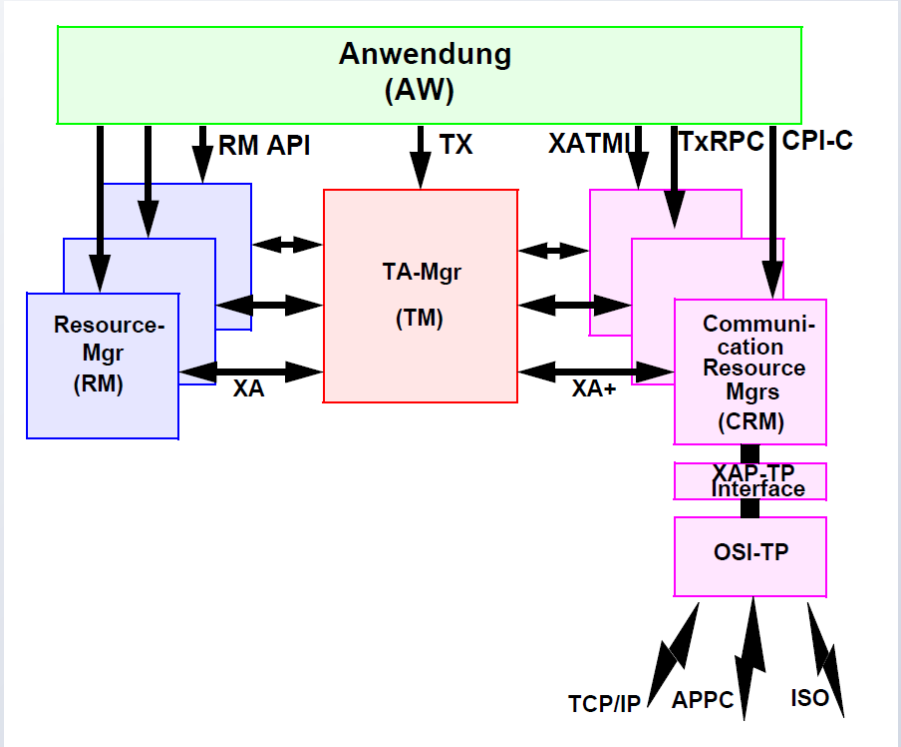

➥ Sind drei Schnittstellen-Standards erforderlich?
Kompromisslösung für drei existierende Protokolle (DCE, CiCS, Tuxedo)

TA-Verarbeitung in offenen Systemen (6)

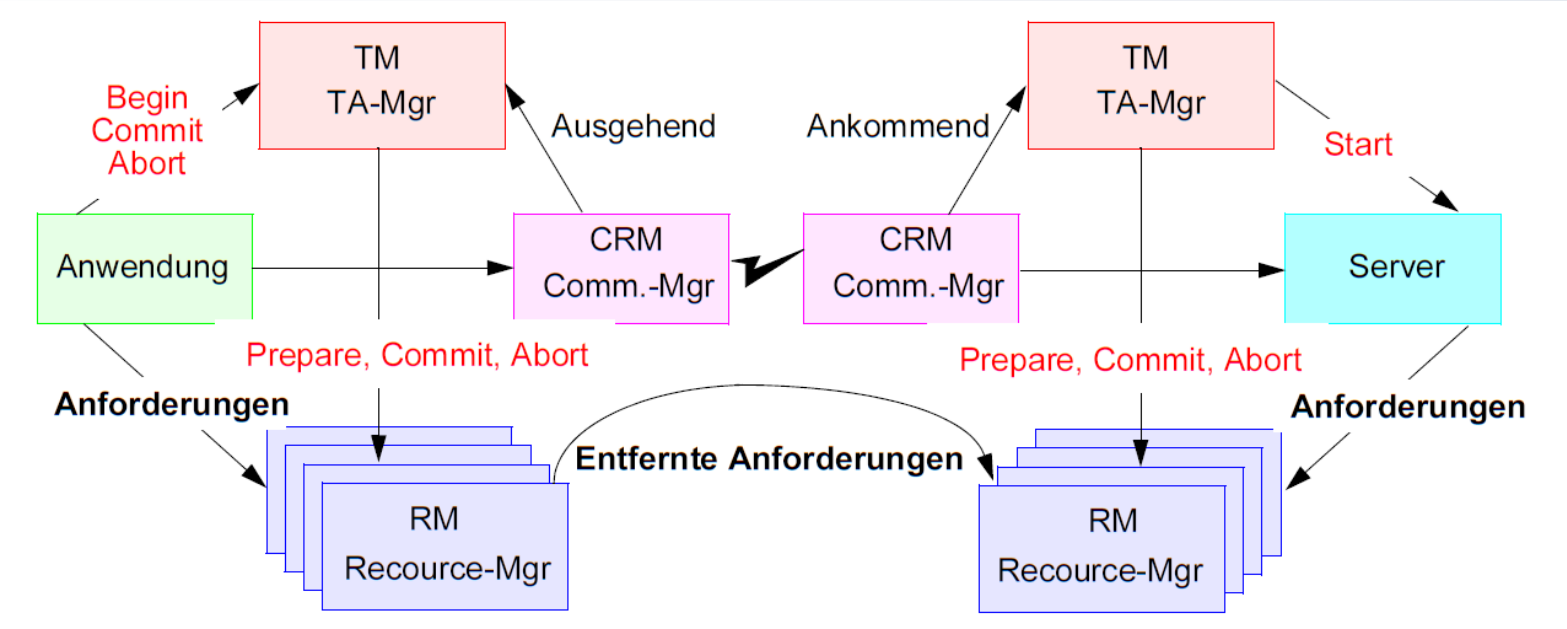

- **TA-Ablauf**
  - AW startet TA, die vom lokalen TA-Mgr verwaltet wird
  - Wenn die AW oder der RM, der für die AW eine Anforderung bearbeitet, eine entfernte Anforderung durchführen, informieren die CRMs an jedem Knoten ihre lokalen TA-Mgr über die ankommende oder ausgehende TA
  - TA-Mgr verwalten an jedem Knoten jeweils die TA-Arbeit am betreffenden Knoten
  - Wenn die AW COMMIT oder ROLLBACK durchführt oder scheitert, kooperieren alle beteiligten TA-Mgr, um ein atomares und dauerhaftes Commit zu erzielen.

BASE – Eine ACID-Alternative?

- **2PC ist teuer: Wie erreicht man Skalierbarkeit?**
  - Vertikales Skalieren:
    Verschiebe die Anwendung auf das nächst größere Rechensystem
    ➥ aufwändig, teuer, verstärkte Herstellerbindung, ...
  - Horizontales Skalieren:
    Partitioniere (gruppiere) die Daten nach AW-Funktionen und verteile die funktionalen Gruppen auf verschiedene DBs
  - **Sharding*:**
    Weitere Dimension beim horizontalen Skalieren, d.h. horizontale Zerlegung der Daten (Tabellen) innerhalb von funktionalen Gruppen und Zuordnung auf verschiedene DBs

    ➥ Horizontales Skalieren bietet mehr Flexibilität, ist aber auch wesentlich komplexer!

* Nach Wikipedia: Horizontal partitioning is a database design principle whereby rows of a database table are held separately, rather than splitting by columns (as for normalization). Each partition forms part of a shard, which may in turn be located on a separate database server or physical location.

BASE – Eine ACID-Alternative? (2)

- **Funktionale Partitionierung – wesentlich für hohe Skalierbarkeit**
  - Beispiel-Schema

    transaction(xid, seller_id, buyer_id, amount)

    user(id, name, amt_sold, amt_bought)

  - Um Constraints (automatisch) einhalten zu können, müssen alle betroffenen Daten (Tabellen) von einem einzigen DBMS verwaltet werden
    ➥ horizontales Skalieren wäre hier ausgeschlossen !
  - Verwaltung durch verschiedene DBMSs verlangt die Verschiebung von partitionsübergreifenden Constraints in die AW

CAP-Theorem oder Brewer's Theorem

- **CAP-Theorem**
  - Für ein System zum **verteilten Rechnen** ist es unmöglich, gleichzeitig die folgenden drei Eigenschaften zu garantieren:
    - **Consistency** (Konsistenz):
      Aus Benutzersicht findet eine Menge von Operationen auf einmal statt
    - **Availability** (Verfügbarkeit):
      Jede Operation muss mit einer bestimmungsgemäßen Antwort beendet werden
    - **Partition tolerance** (Partitionstoleranz):
      Operationen kommen zum Ende, selbst wenn individuelle Komponenten nicht verfügbar sind

  ➥ Eine Web-AW kann höchstens zwei von diesen Eigenschaften für jeden beliebigen DB-Entwurf unterstützen!

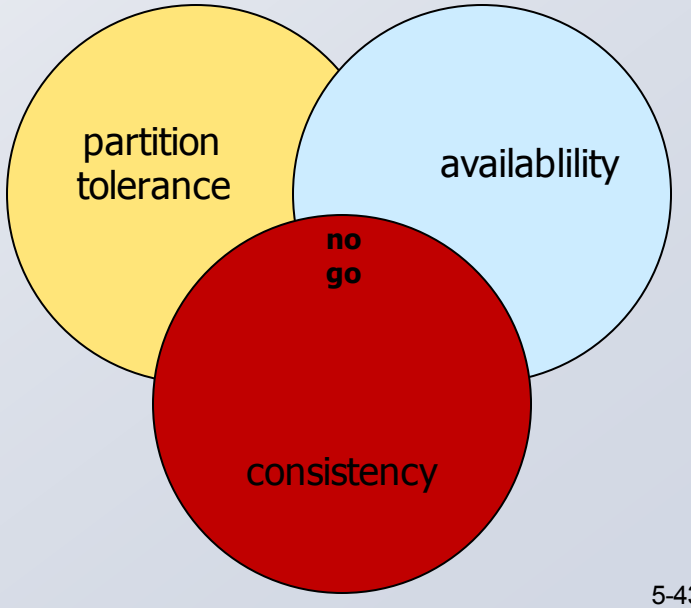

CAP-Theorem oder Brewer's Theorem (2)

- **Wie lassen sich ACID-Lösungen annähern?**
  - Eine horizontale Skalierungsstrategie basiert auf Datenpatitionierung

  ➥ Wir müssen uns zwischen Konsistenz und Verfügbarkeit entscheiden!

- **Aber Konsistenz ist zu garantieren!**

  ➥ Wenn Brewer recht hat, muss an der Verfügbarkeit „gedreht" werden!

- **Auswirkungen reduzierter Verfügbarkeit bei ACID-Lösungen**
  - angenommene Komponentenverfügbarkeit von 99,9%
  - Gesamtverfügbarkeit als Produkt der Einzelverfügbarkeiten:
    2PC-Protokoll bei zwei DBs ➥ 99,8%
    (zusätzliche Ausfallzeit von 43 Min./Monat)

  ➥ Reicht das für erhöhte Skalierbarkeit aus?

BASE (basically available, soft state, eventually consistent)*

- **Eine ACID-Alternative**
  - ACID ist pessimistisch und erzwingt Konsistenz bei Commit
  - BASE ist dazu diametral entgegengesetzt
    - Es ist optimistisch und akzeptiert, dass sich die DB-Konsistenz in einem fließenden Zustand befindet
    - Verfügbarkeit wird dadurch erreicht, dass bestimmte Fehlerzustände akzeptiert werden, ohne dass es zu einem Ausfall des Gesamtsystems kommt
      Bsp.: Wenn nur einer von fünf Servern ausfällt, wird im Vergleich zu einem System-Crash eine deutlich höhere Verfügbarkeit wahrgenommen
    - Beim DB-Entwurf sind die **Daten in funktionale Gruppen** zu zerlegen; nach Verkehrsaufkommen werden sie dann auf verschiedene DBMS verteilt

↪ **BASE verlangt eine weitaus detailliertere Analyse der TA-Ops als ACID!**

* In partitioned databases, trading some consistency for availability can lead to dramatic improvements in scalability (Dan Britchett, eBay)

BASE (2)

Schema

transaction(<u>xid</u>, seller_id, buyer_id, amount)

user(<u>id</u>, name, amt_sold, amt_bought)

Konsistenzmuster

- Nach Brewer müssen Wege zur Lockerung der Konsistenzforderung gefunden werden, wenn die Verfügbarkeit in einer partitionierten DB erhalten bleiben soll
- Ein Benutzer kann in mehreren TAs kaufen oder verkaufen
- Müssen die laufenden Gesamtsummen in Tabelle *user* immer aktuell sein?
- Die Tabellen *user* und *transaction* werden hier als verschiedene funktionale Gruppen klassifiziert
- Im Allgemeinen ist die Konsistenz **zwischen** funktionalen Gruppen leichter zu lockern als innerhalb einer funktionalen Gruppe

BASE (3)

- **Schema**

  transaction(xid, seller_id, buyer_id, amount)

  user(id, name, amt_sold, amt_bought)

- **DB-Ausprägung verteilt**

transaction — **node 2**

xid	seller_id	buyer_id	amount
123	4711	0815	20,000
124	0007	4711	10,000

user — **node 1**

id	name	amt_sold	amt_bought
4711	Coy	200,000	50,000
0815	May	520,000	100,000
0007	Bond	30,000	600,000

BASE (4)

- **Eine ACID-Lösung mit SQL**

```
Begin transaction
    Insert into transaction(xid, seller_id, buyer_id, amount);
    Update user set amt_sold = amt_sold+$amount where id=$seller_id;
    Update user set amt_bought = amount_bought+$amount
        where id=$buyer_id;
End transaction
```

- **2PC** erforderlich
  - ➥ **The Unavailability Problem!** (W. Vogels, Amazon)
- Die Zähler amount, amt_bought und amt_sold, die zu verschiedenen funktionalen Gruppen gehören, werden gemeinsam aktualisiert
  - ➥ **Konsistenz garantiert!**

BASE (5)

- **Zerlegung in zwei ACID-Transaktionen**

```
Begin transaction
    Insert into transaction(id, seller_id, buyer_id, amount);
End transaction
Begin transaction
    Update user set amt_sold=amt_sold+$amount
        where id=$seller_id;
    Update user set amt_bought=amount_bought+$amount
        where id=$buyer_id;
End transaction
```

- Lockerung der Konsistenzanforderung: Die Zähler brauchen nicht sofort das Ergebnis einer Transaktion reflektieren; sie enthalten „Schätzungen"!
- **Konsistenz** zwischen beiden Tabellen wird nicht garantiert!

BASE (6)

- **Ein möglicher Ablauf von xid = 125**

transaction — **node 2**

xid	seller_id	buyer_id	amount
123	4711	0815	20,000
124	0007	4711	10,000
125	0815	0007	100,000

user — **node 1**

id	name	amt_sold	amt_bought
4711	Coy	200,000	50,000
0815	May	520,000	100,000
0007	Bond	30,000	600,000

BASE (7)

- **Eine einfache BASE-Lösung**
  - Falls Zähler-Werte als Schätzungen nicht akzeptabel sind und die Konsistenz zumindest zeitverzögert garantiert werden muss?
  - Persistente Nachrichtenwarteschlange (PMQ: persistent message queue) löst das Problem

```
Begin transaction
    Insert into transaction(id, seller_id, buyer_id, amount);
    Queue message "update user(seller_id, "seller", amount)";
    Queue message "update user(buyer_id, "buyer", amount)";
End transaction

For each message in queue
    Begin transaction
        Dequeue message
        If message.balance == "seller"
            Update user set amt_sold = amt_sold + message.amount
            where id=message.id;
        Else
            Update user set amt_bought = amt_bought + message.amount
            where id=message.id;
        End if
    End transaction
End for
```

BASE (8)

- **Transaktionsablauf**

transaction **node 2**

xid	seller_id	buyer_id	amount
123	4711	0815	20,000
124	0007	4711	10,000
125	0815	0007	100,000

- Erste Transaktion aktualisiert **transaction** und fügt atomar in PMQ ein:
  - update user("seller", 0815, 100,000)
  - update user("buyer", 0007, 100,000**)**
- PMQ garantiert, dass die Nachrichten in endlicher Zeit atomar verarbeitet werden und die Zähler aktualisieren
  - ↪ **eventually consistent!**
- 2PC bei der PMQ-Verarbeitung erforderlich!

BASE (9)

- **2PC soll vermieden werden!**
  - Gewährleistung von **Idempotenz** (bei partiellem Ausfall) !
    Welche Zähleraktualisierungen waren erfolgreich und welche nicht?
  - Hilfstabelle: **updates_applied**(trans_id, balance, user_id)
  - Algorithmus unterstützt partielle Fehler und bietet TA-Garantien (eventually consistent), ohne 2PC auf user und PMQ zu erfordern!

```
Begin transaction
    Insert into transaction(id, seller_id, buyer_id, amount);
    Queue message "update user(seller_id, "seller", amount)";
    Queue message "update user(buyer_id, "buyer", amount)";
End transaction

...
```


BASE (10)


```
For each message in queue
    Peek message
    Begin transaction
        Select count(*) as processed from updates_applied
        where trans_id = message.trans_id
        and balance = message.balance and user_id = message.user_id
        If processed == 0
            If message.balance == "seller"
                Update user set amt_sold=amt_sold + message.amount
                where id=message.user_id;
            Else
                Update user set amt_bought=amt_bought + message.amount
                where id=message.user_id;
                End if
        Insert into updates_applied (message.trans_id, message.balance, message.user_id);
        End if
    End transaction
    If transaction successful
        Remove message from queue
    End if
End for
```

- Lösung hängt hier davon ab, dass Nachricht in PMQ aufgesucht (peek) und nach erfolgreicher Verarbeitung aus PMQ entfernt werden kann!
- Queue-Operationen sind vor dem Commit der DB-Transaktion nicht erfolgreich

BASE (11)

- **Ein möglicher Ablauf von xid = 125**

transaction **node 2**

xid	seller_id	buyer_id	amount
123	4711	0815	20,000
124	0007	4711	10,000
125	0815	0007	100,000

- **PMQ mit (user_id, balance, amount)**
  - message.trans_id: update user(0815, "seller", **100,000)**
  - message.trans_id: update user(0007, "buyer", **100,000)**
  - …

BASE (12)

- **Stand von Tabelle user**

user — **node 1**

id	name	amt_sold	amt_bought
4711	Coy	200,000	50,000
0815	May	520,000	100,000
0007	Bond	30,000	600,000

- **Kontrolle erfolgreicher Aktualisierungen von user durch**

updates_applied — **node 1**

trans_id	balance	user_id

Zusammenfassung

- **Transaktionsparadigma**
  - Verarbeitungsklammer für die Einhaltung von semantischen Integritätsbedingungen
  - Verdeckung der Nebenläufigkeit (*concurrency isolation*)
    ⇨ Synchronisation
  - Verdeckung von (erwarteten) Fehlerfällen (*failure isolation*)
    ⇨ Logging und Recovery
  - im SQL-Standard: COMMIT WORK, ROLLBACK WORK
    ⇨ Beginn einer Transaktion implizit
- **Zweiphasen-Commit-Protokolle**
  - Hoher Aufwand an Kommunikation und E/A
  - Optimierungsmöglichkeiten sind zu nutzen
  - Maßnahmen erforderlich, um Blockierungen zu vermeiden!
    ⇨ **Kritische Stelle:** Ausfall von C

Zusammenfassung (2)

- **Einsatz in allen Systemen!**
- **Varianten des Commit-Protokolls:**
  - Hierarchisches 2PC:
    Verallgemeinerung auf beliebige Schachtelungstiefe
  - Reduzierte Blockierungsgefahr durch 3PC:
    Nach Voting-Phase wird in einer zusätzlichen Runde (Dissemination-Phase) allen Agenten der TA-Ausgang mitgeteilt. Erst nachdem C sicher ist, dass alle Agenten das Ergebnis kennen, wird die Decision-Phase initiiert: unabhängige Recovery, aber komplexes Fehlermodell
- **BASE (basically available, soft state, eventually consistent)**
  - CAP-Theorem: Eine Web-AW kann höchstens zwei der drei Eigenschaften (Konsistenz, Verfügbarkeit, Partitionierungstoleranz) für jeden beliebigen DB-Entwurf unterstützen!
  - Lockerung der Konsistenz (zwischen funktionalen Gruppen), wenn die Verfügbarkeit in einer partitionierten DB erhalten bleiben soll