5. Transaktionsverwaltung

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

- **Gefährdung der DB-Konsistenz**

- **Transaktionsverwaltung**
  - ACID-Eigenschaften
  - Architektur

- **Transaktionsablauf**
  - SQL-Operationen: COMMIT WORK, ROLLBACK WORK (Beginn einer Transaktion implizit)
  - Zustände und Zustandsübergänge

- **Wie erreicht man Atomarität?**
  - Einsatz von Commit-Protokollen (zentralisierter TA-Ablauf)
  - **2PC (Zweiphasen-Commit-Protokoll)**
    - verteilter TA-Ablauf
    - Fehleraspekte
    - Kostenbetrachtungen
  - Hierarchisches 2PC

Gefährdung der DB-Konsistenz

	Korrektheit der Abbildungshierarchie	Übereinstimmung zwischen DB und Miniwelt
durch das Anwendungspro-gramm	Mehrbenutzer-Anomalien **Synchronisation**	unzulässige Änderungen **Integritätsüberwachung des DBVS** **TA-orientierte Verarbeitung**
durch das DBVS und die Betriebsumge-bung	Fehler auf den Externspeichern, Inkonsistenzen in den Zugriffspfaden **Fehlertolerante Implementierung, Archivkopien (Backup)**	undefinierter DB-Zustand nach einem Systemausfall **Transaktionsorientierte Fehlerbe-handlung (Recovery)**

Transaktionsverwaltung

- **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.

- **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
      (wird später behandelt)
  - kann zentralisiert oder verteilt (z.B. bei VDBS) realisiert sein
  - soll Transaktionsschutz für heterogene Komponenten bieten

Transaktionsverwaltung (2)

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

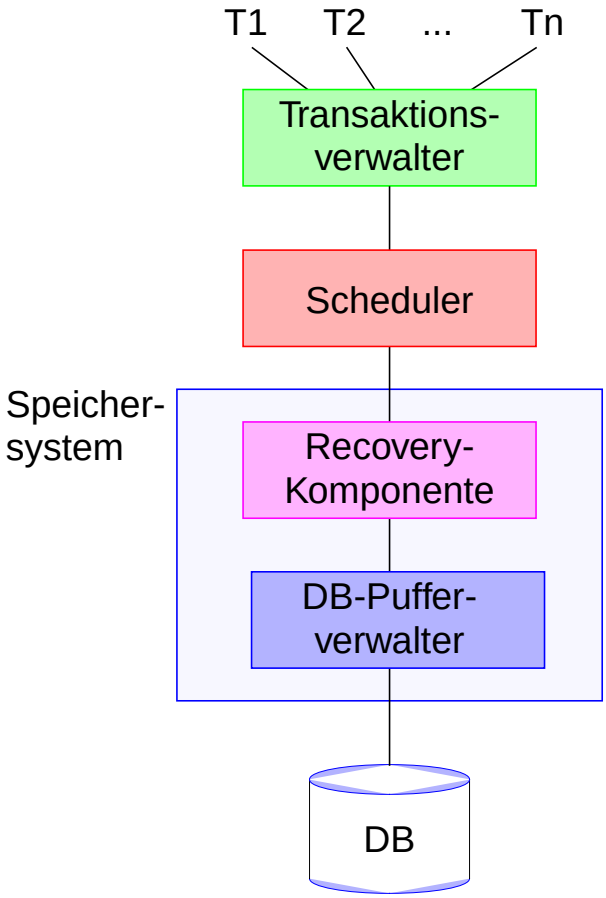

- **Transaktionsverwalter**
  - Verteilung der DB-Operationen in VDBS und Weiterreichen an den Scheduler
  - zeitweise Deaktivierung von TA (bei Überlast)
  - Koordination der Abort- und Commit-Behandlung
- **Scheduler** (Synchronisation)
  kontrolliert die Abwicklung der um DB-Daten konkurrierenden 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

- **Transaktionsprogramm – Beispiel:**

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

- **Zustandsübergangs-Diagramm**

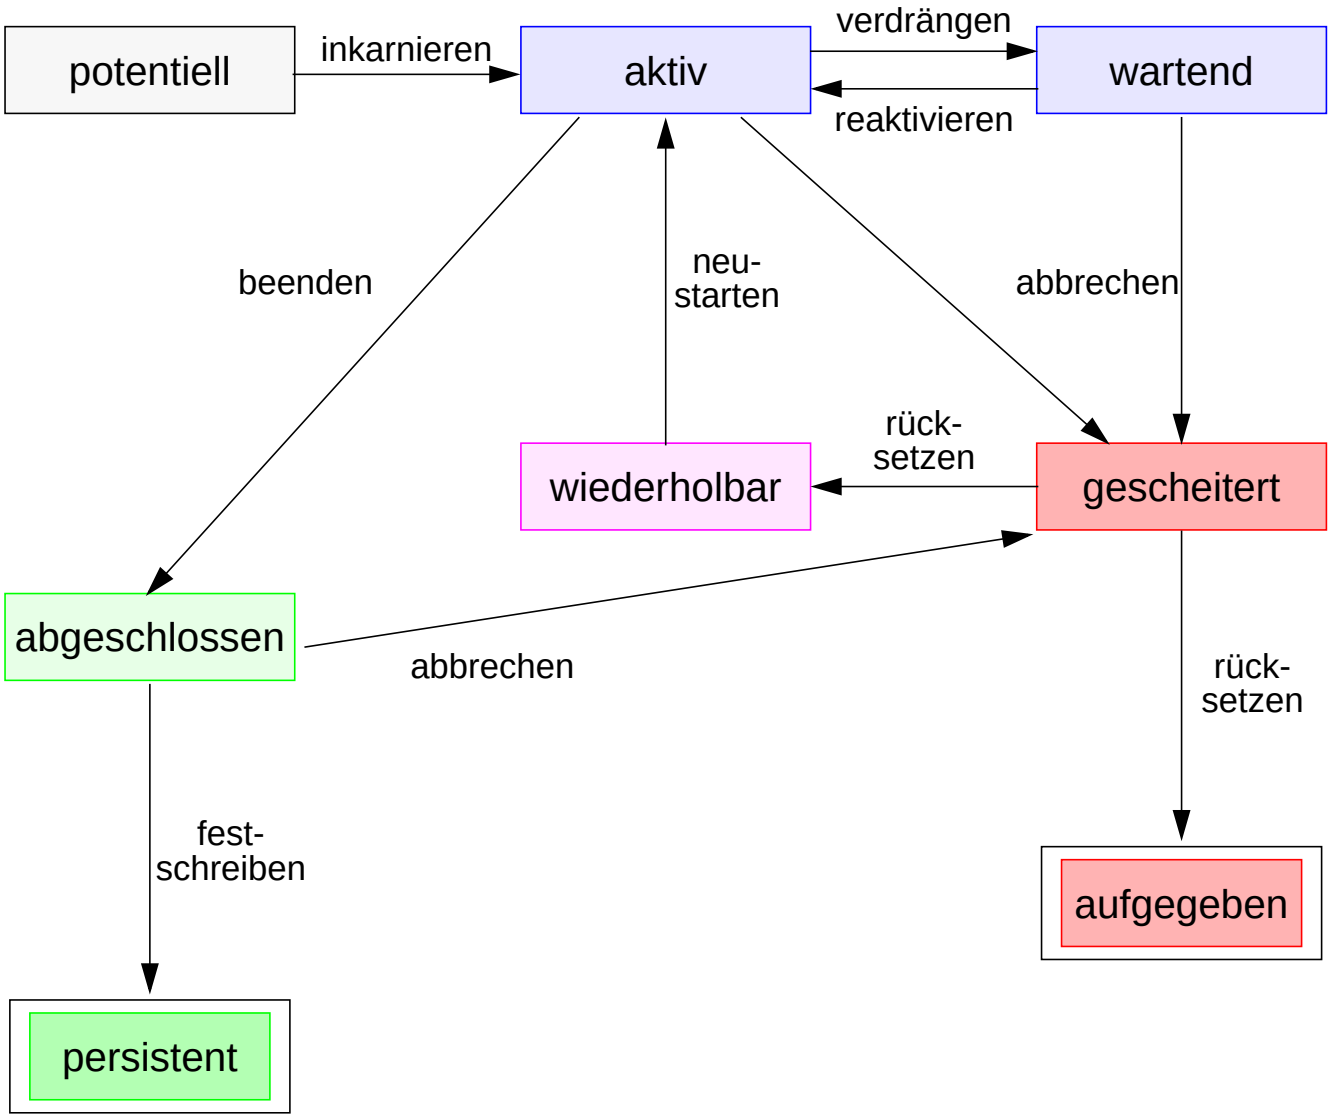

Zustände einer Transaktion (2)

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

- **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

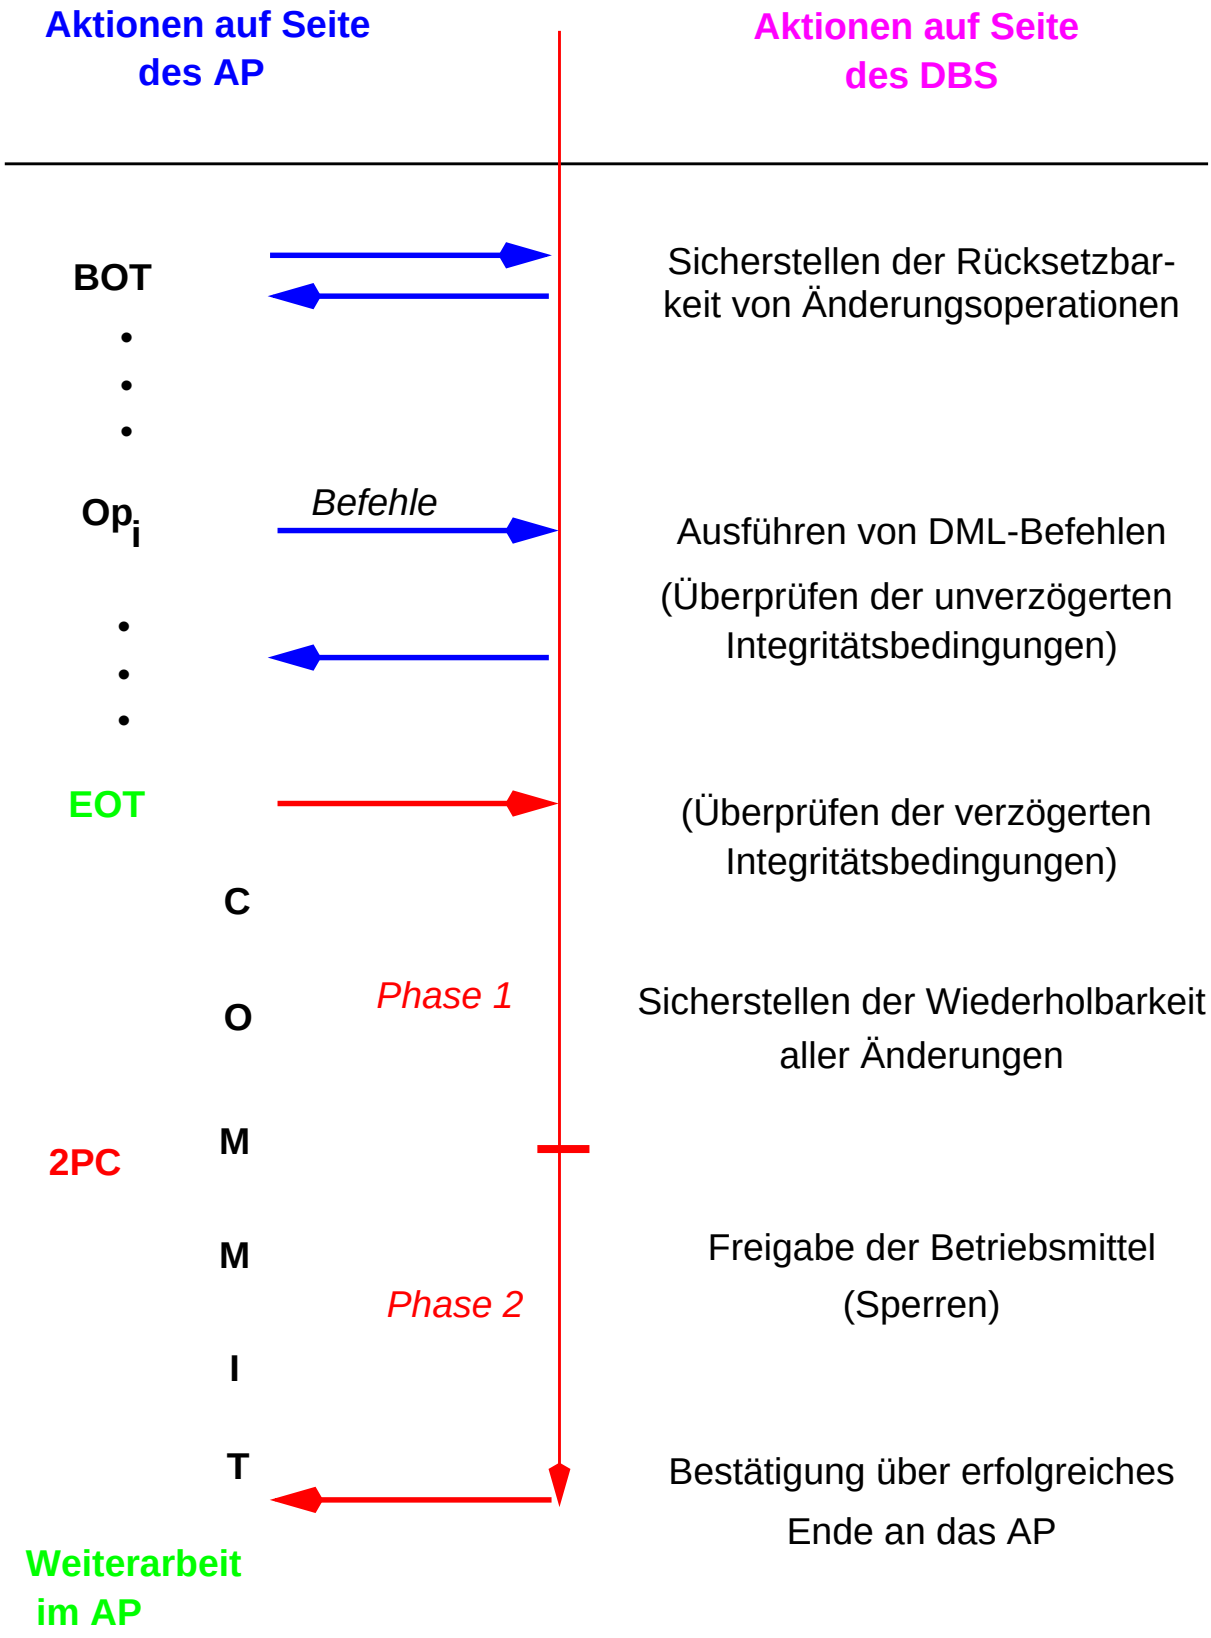

Verarbeitung in Verteilten Systemen

- Ein ***verteiltes System*** besteht aus autonomen Subsystemen, die koordiniert zusammenarbeiten, um eine gemeinsame Aufgabe zu erfüllen
  - Client/Server-Systeme
  - Mehrrechner-DBS, . . .

- **Beispiel: The „Coordinated Attack“ Problem**

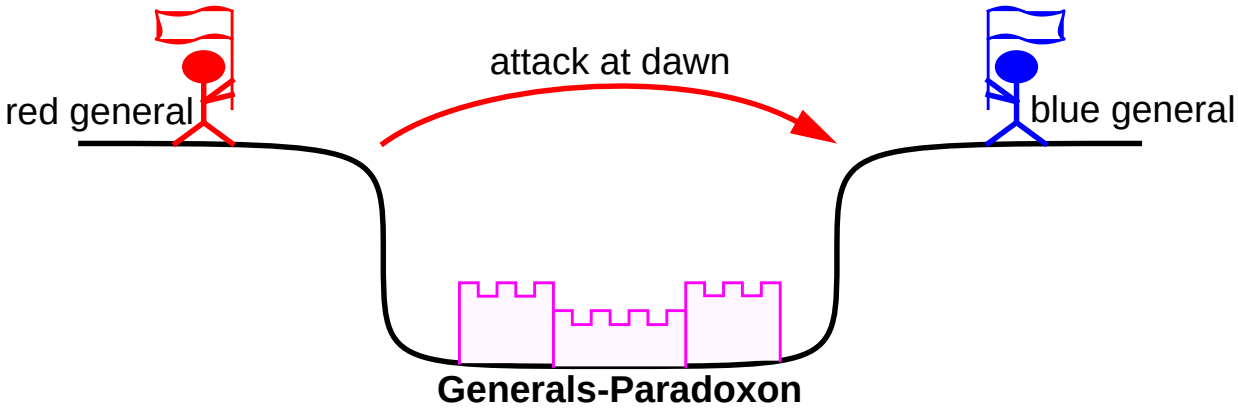

Generals-Paradoxon

- **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 (2)

- **Erweitertes Transaktionsmodell**

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

1 Koordinator

N Teiltransaktionen (Agenten)

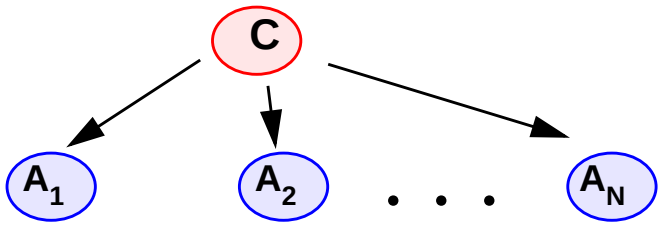

➥ *rechnerübergreifendes Mehrphasen-Commit-Protokoll notwendig, um Atomarität einer globalen Transaktion sicherzustellen*

- **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

- **Fehlermodell**
  - allgemein: Transaktionsfehler, Crash (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

➥ keine speziellen Annahmen: Kommunikationssystem arbeitet mit Datagrammen als einfachstem Typ von unbestätigten, sitzungsfreien Nachrichten

➥ schwierige Fehlererkennung, z. B. oft über Timeout

Zentralisiertes Zweiphasen-Commit

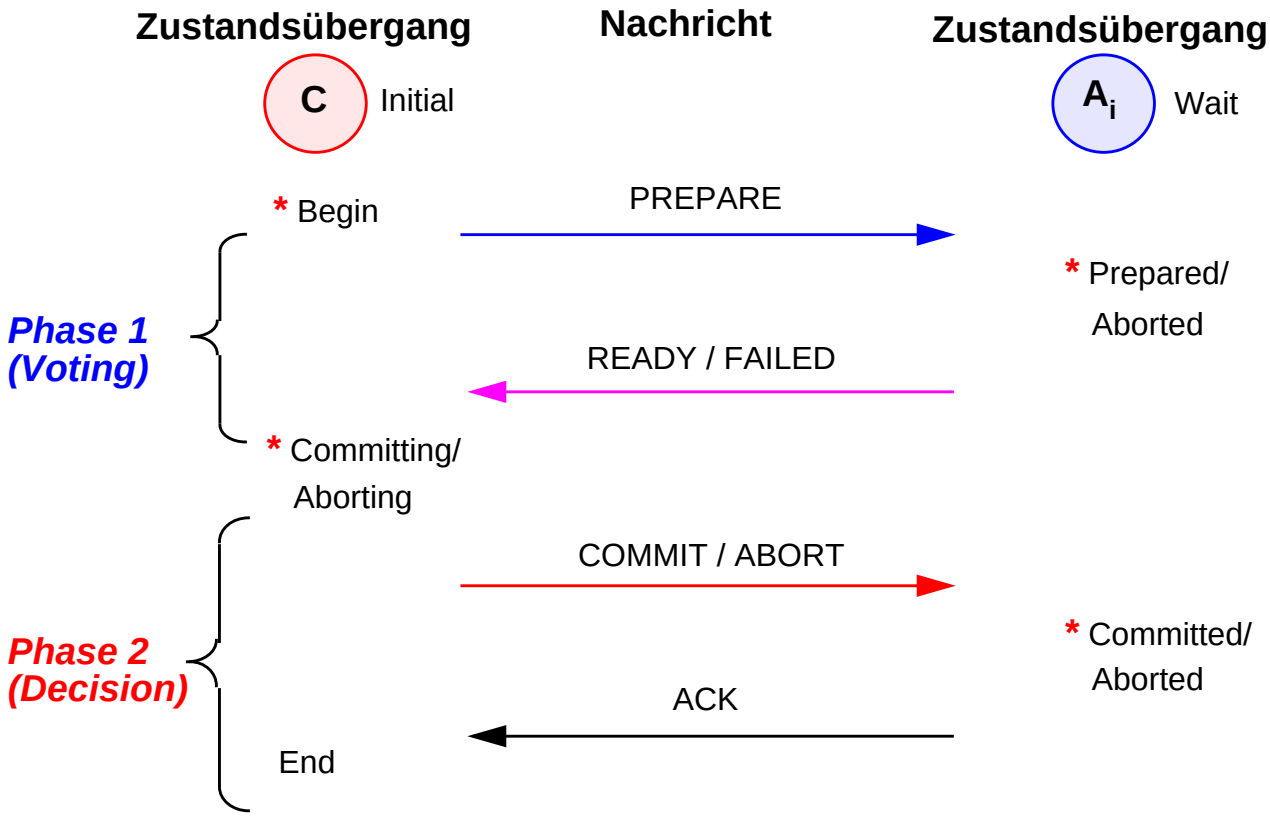

* synchrone Log-Ausgabe (log record is force-written)
„End“ ist wichtig für Garbage Collection im Log von C

- **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

Koordinator C

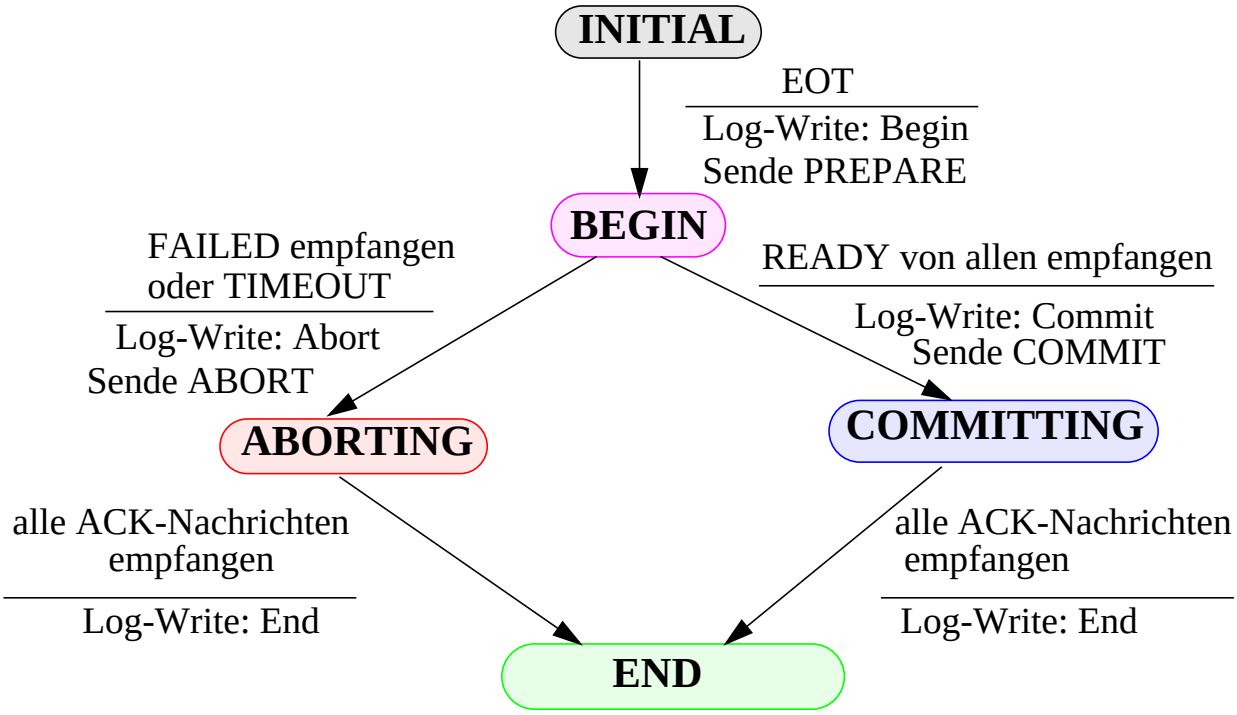

Agent A_i

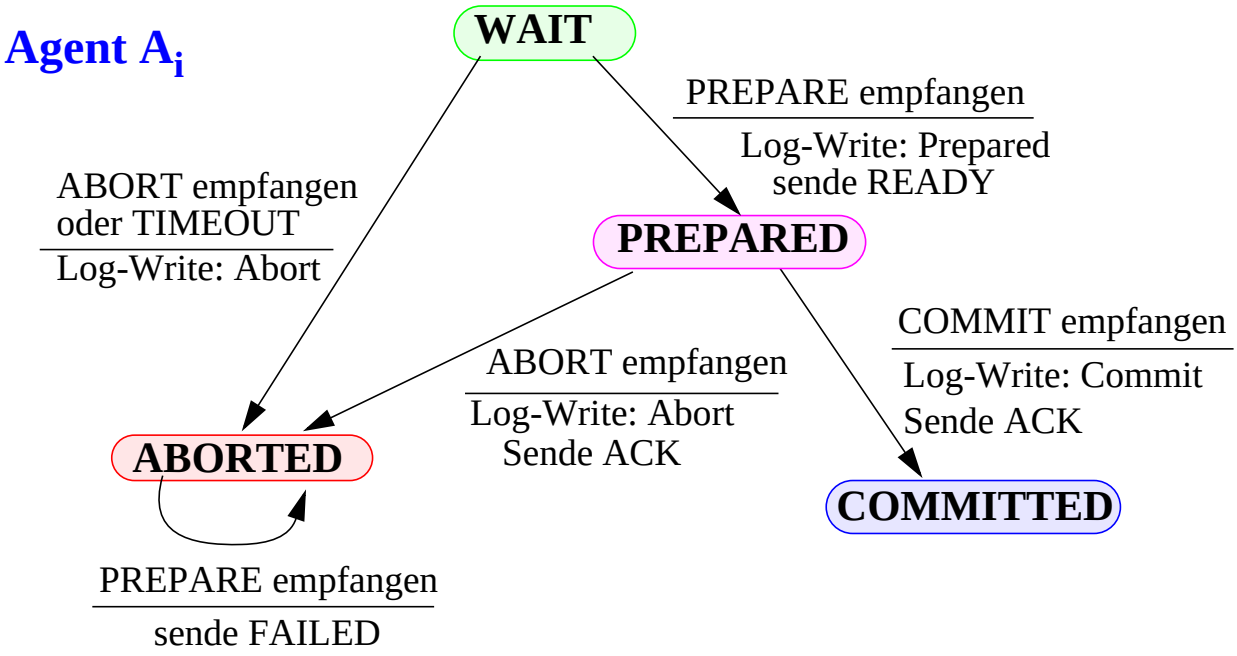

2PC: Fehlerbehandlung

- **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 noch 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 (PCs), Applikations-Server, DB-Server
  - unterschiedliche *Quality of Service* bei Zuverlässigkeit, Erreichbarkeit, Leistung, ...

- **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

- **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

Initiator = Coordinator

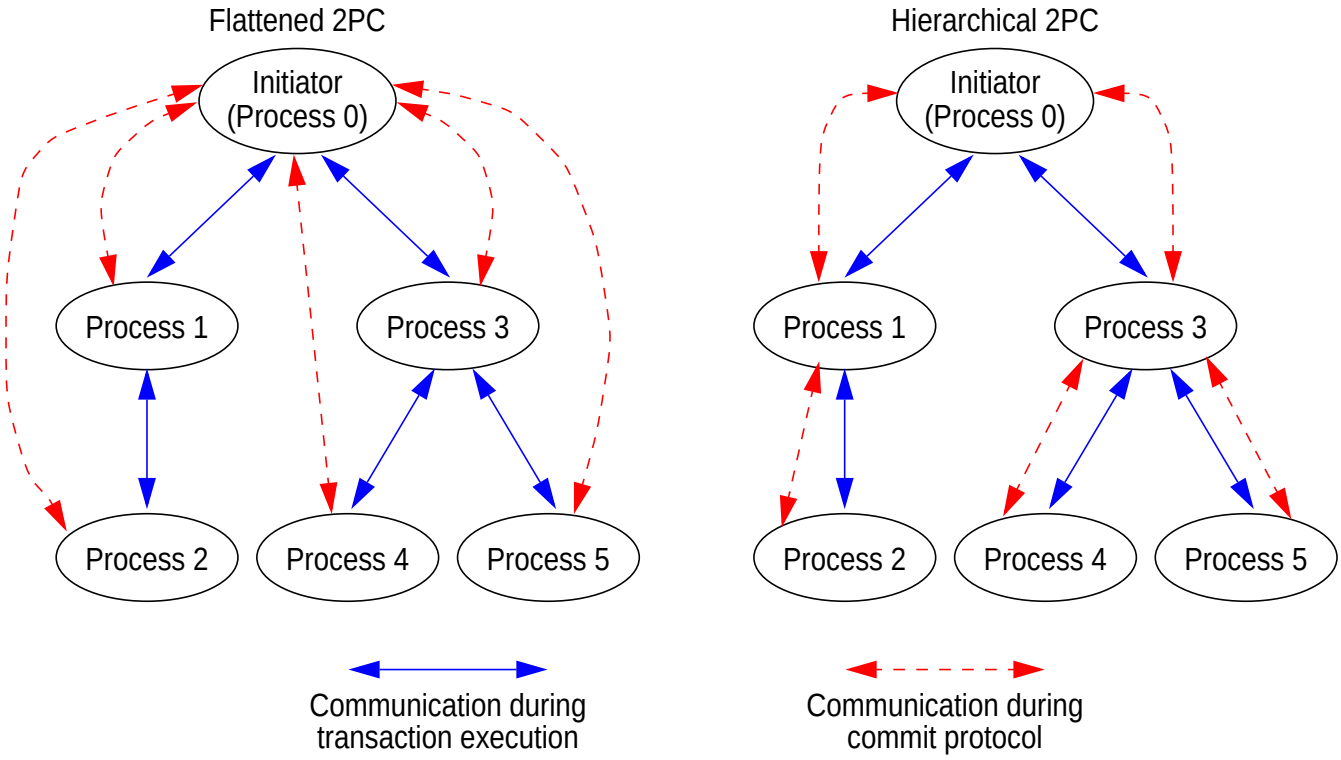

  - „Flachmachen“ kann als spezieller Fall der Restrukturierung der C/S-Aufrufhierarchie gesehen werden
    - Es könnte auch ein zuverlässiger innerer Knoten als Koordinator ausgewählt werden
    - „Rotation“ der Aufrufhierarchie um den neu gewählten Koordinatorknoten

Hierarchisches 2PC

- **Allgemeineres Ausführungsmodell**
  - beliebige Schachtelungstiefe, angepasst an Client/Server-Modell
  - Modifikation des Protokolls für “Zwischenknoten”

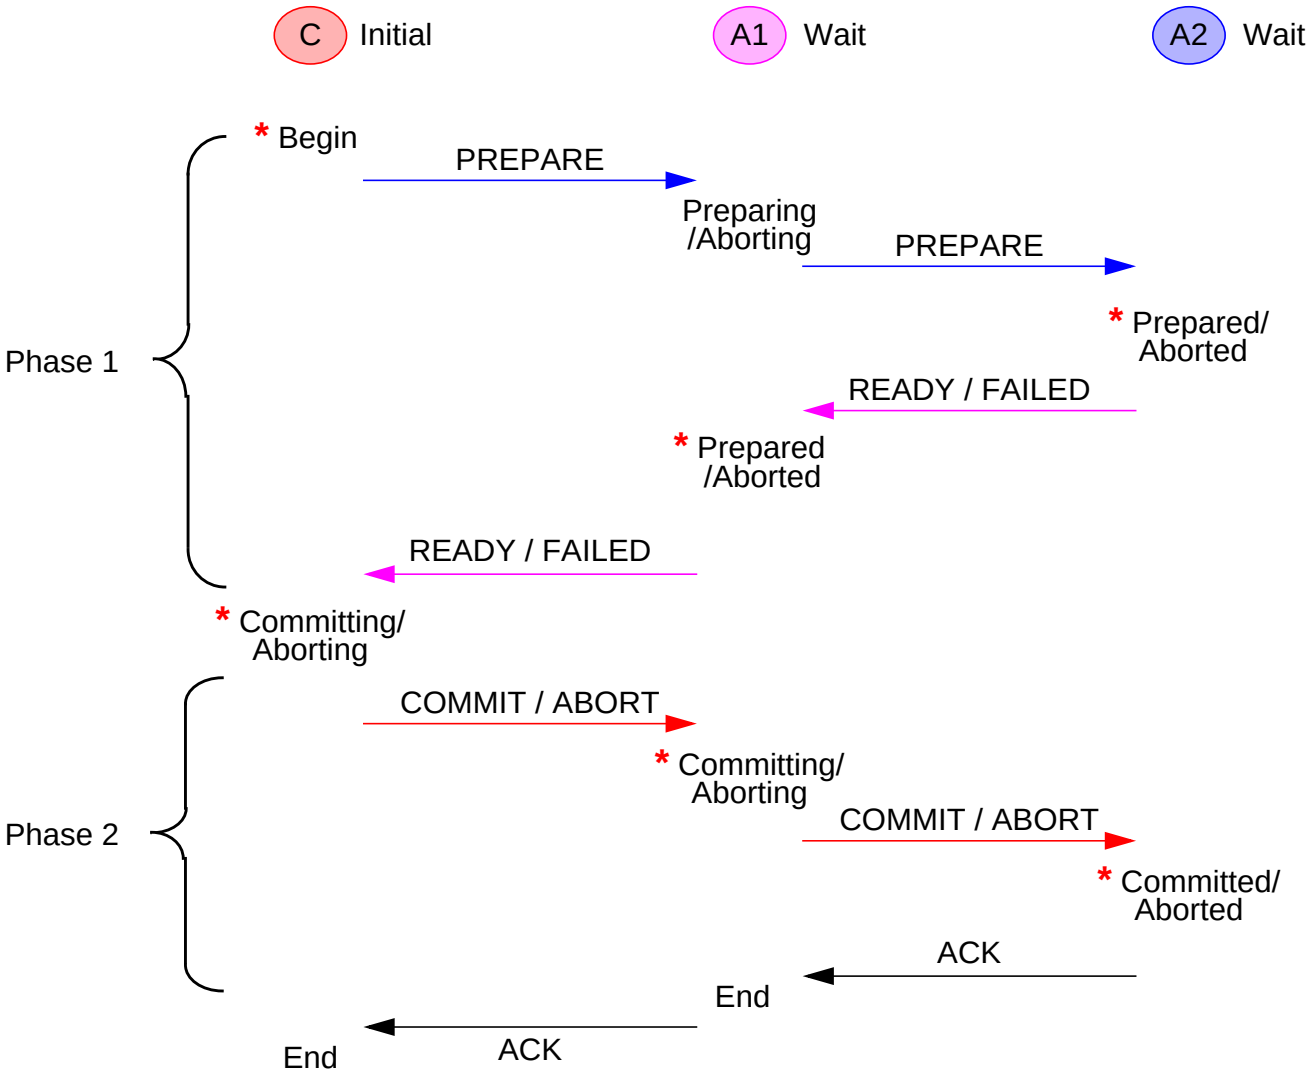

* synchrone Log-Ausgabe (log record is force-written)
„End“ ist wichtig für Garbage Collection im Log

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

Commit: Optimierungen

- **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 auf mehrfache Art 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)

- **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: 4 N
  - Log-Ausgaben: 2 + 2 N
  - 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** teilnehmen[2]
    - 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

2. 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)

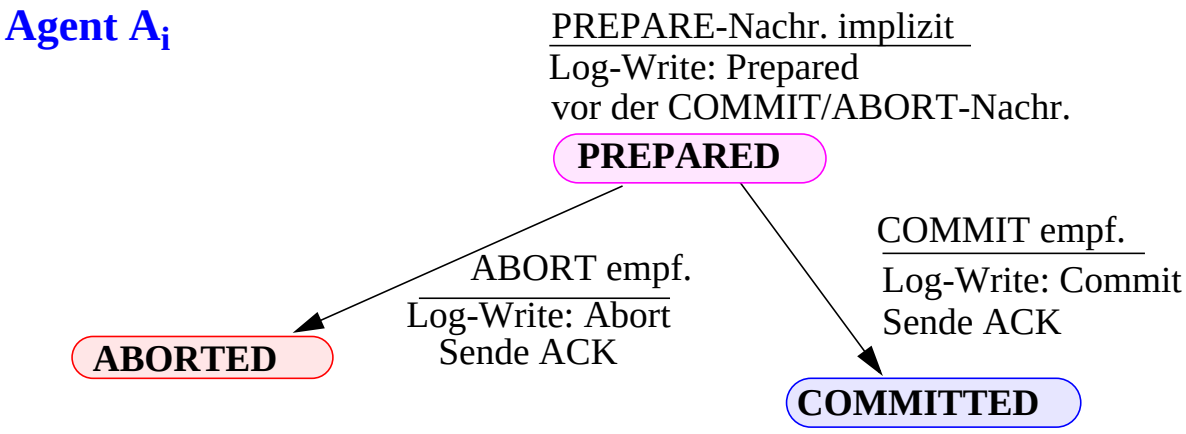

  - Nachrichten:
  - durchschnittlich K Aufträge pro Agent;
    Log-Ausgaben:

- **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:

Commit: Kostenbetrachtungen (3)

- **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:

- **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) !**

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

- **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