FRIEDRICH-SCHILLER-
UNIVERSITÄT
JENA

Datenbanksysteme II

Prof. Dr. Viktor Leis

Professur für Datenbanken und Informationssysteme

Transaktionsverwaltung

Transaktionsverwaltung

- Transaktionsverwaltung beinhaltet die folgenden zwei Teilgebiete
  - **Recovery**, d.h. die Behebung von eingetretenen, oft unvermeidbaren Fehlersituationen.
  - **Synchronisation** von mehreren gleichzeitig auf der Datenbank ablaufenden Transaktionen.

Beispiel für Transaktion (TA)

- Überweise Geld von Konto A nach Konto B:
  - Lies den Kontostand von A in die Variable a: **read**(A,a);
  - Reduziere den Kontostand um 50 EUR: $a := a - 50$;
  - Schreibe den neuen Kontostand in die Datenbasis: **write**(A,a);
  - Lies den Kontostand von B in die Variable b: **read**(B,b);
  - Erhöhe den Kontostand um 50 EUR: $b := b + 50$;
  - Schreibe den neuen Kontostand in die Datenbasis: **write**(B,b);

Operationen

- begin of transaction (BOT):
  - Kennzeichnet den Beginn einer Transaktion
- commit:
  - Erfolgreiche Beendigung einer Transaktion
  - Dauerhafte Einbringung aller Änderungen in die Datenbasis
- abort:
  - Selbstabbruch der Transaktion, erfolglose Beendigung
  - Zurücksetzen der Datenbasis in den Zustand vor Beginn der Transaktion

Operationen (2)

- define savepoint:
  - Sicherungspunkt definieren, auf den sich die (noch aktive) Transaktion zurücksetzen lässt.
- backup transaction:
  - Die noch aktive Transaktion wird auf den jüngsten (zuletzt angelegten) Sicherungspunkt zurückgesetzt
  - Evtl. auch Rücksetzen auf weiter zurückliegende Sicherungspunkte möglich

Systemabsturz

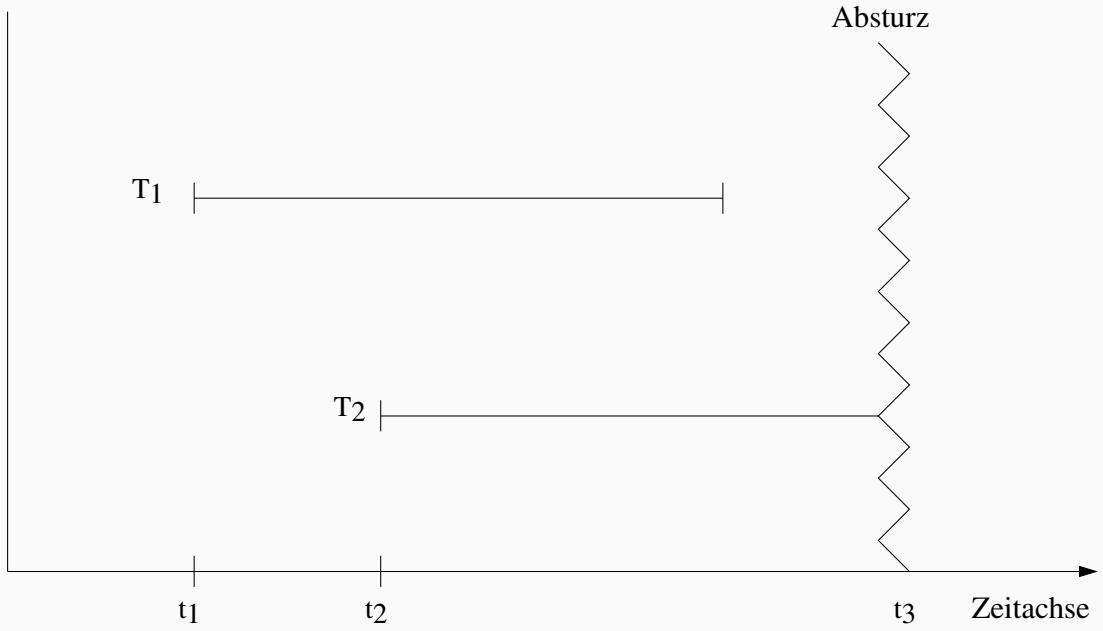

- Änderungen der zum Zeitpunkt t_3 abgeschlossenen TA T_1 müssen in der Datenbasis vorhanden sein
- Änderungen der zu t_3 noch nicht abgeschlossenen TA T_2 müssen vollständig aus der Datenbasis entfernt werden (Durchführung von T_2 durch Neustart)

Transaktionen und SQL

- commit (work):
  - Beende Transaktion und schreibe Änderungen fest
  - funktioniert nur, wenn keine anderen Fehler aufgetreten sind (z.B. Konsistenzverletzung durch Transaktion)
- rollback (work):
  - Beende Transaktion und setze alle Änderungen zurück
  - Anders als **commit** muss DBMS die “erfolgreiche” Ausführung von **rollback** immer garantieren können

Transaktionen und SQL (2)

- Beispiel:

```
insert into Vorlesungen
    values (5275, 'Kernphysik', 3, 2141);

insert into Professoren
    values (2141, 'Meitner', 'C4', 205);

commit work
```

- **commit** nach dem ersten **insert** könnte nicht erfolgreich durchgeführt werden, da zu diesem Zeitpunkt referentielle Integrität verletzt

Zusammenfassung

- Transaktionen sollten ACID-Eigenschaften haben
- ACID:
  - Atomicity
  - Consistency
  - Isolation
  - Durability

Zusammenfassung (2)

- Atomicity (Atomarität): “alles oder nichts”, d.h. entweder werden all Operationen einer TA ausgeführt oder keine
- Consistency (Konsistenz): wenn eine TA auf einem konsistenten Datenbankzustand aufsetzt, ist dieser nach Beendigung der TA immer noch konsistent
- Isolation: nebenläufig ausgeführte Transaktionen dürfen keine Seiteneffekte aufeinander haben
- Durability (Dauerhaftigkeit): alle mit commit festgeschriebenen Änderungen müssen bestehen bleiben (selbst bei Systemabsturz)

Recovery

Recovery

- Wichtige Aufgabe eines DBMS ist das Verhindern von Datenverlust durch Systemabstürze
- Die zwei wichtigsten Mechanismen des Recovery sind:
  - Sicherungspunkte (Backups)
  - Log-Dateien

Recovery (2)

- Ein *Sicherungspunkt* ist ein Schnappschuss des Datenbankinhalts zu einem bestimmten Zeitpunkt
- In einer *Log-Datei* werden alle Änderungen an der Datenbasis mitprotokolliert
- Offensichtlich sollten Sicherungspunkte und Log-Dateien nicht auf der gleichen Maschine gespeichert werden ...

Vollständiger Verlust

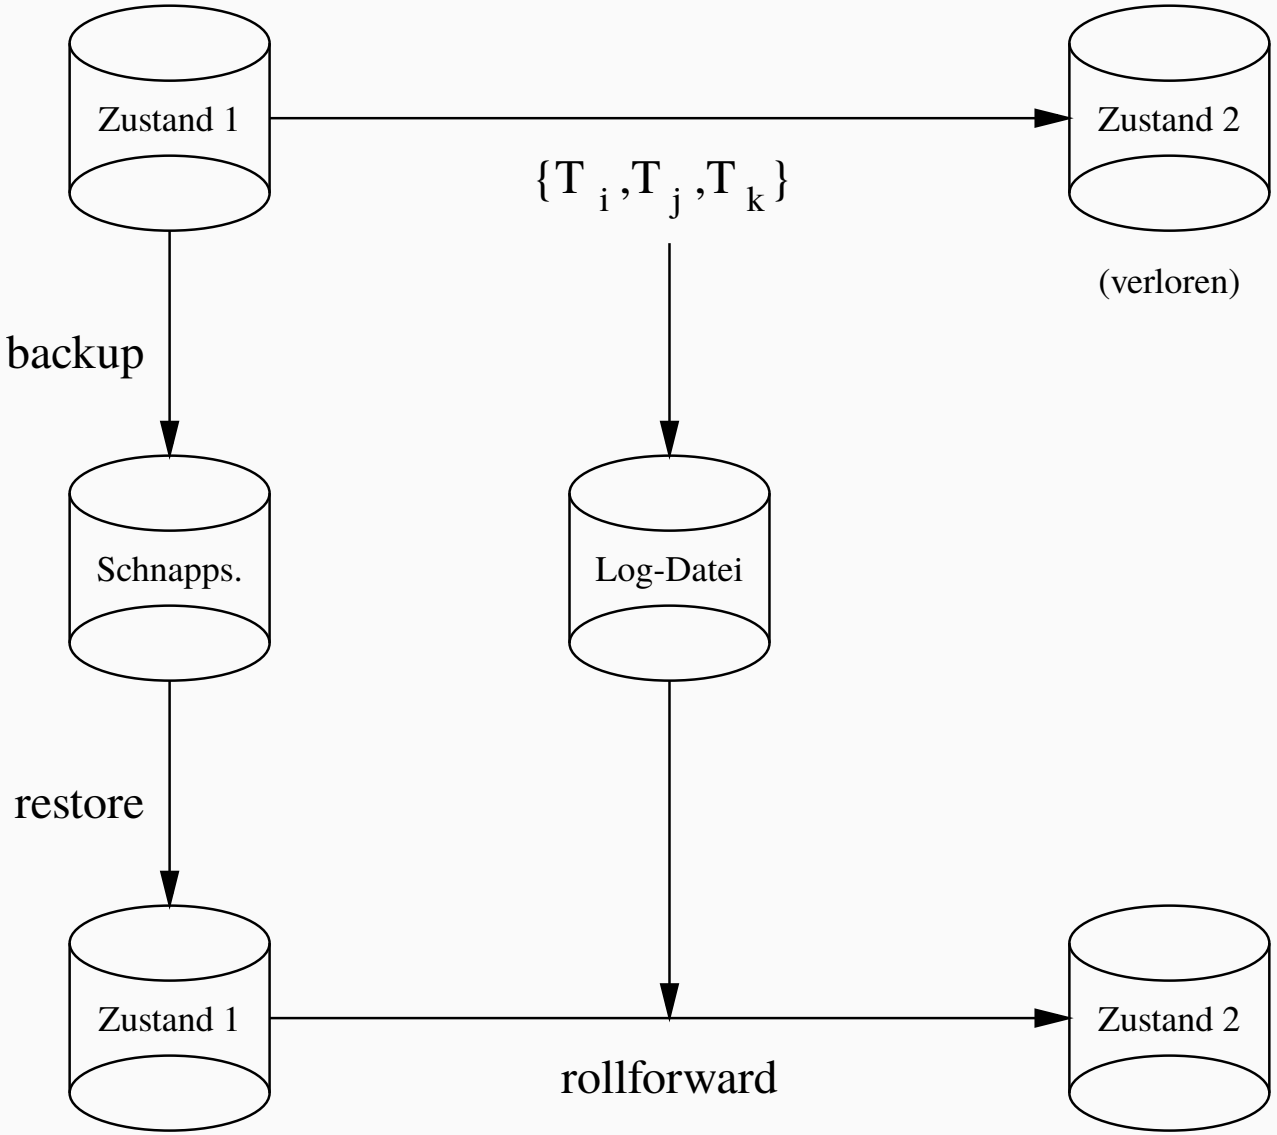

Verlust des Hauptspeichers

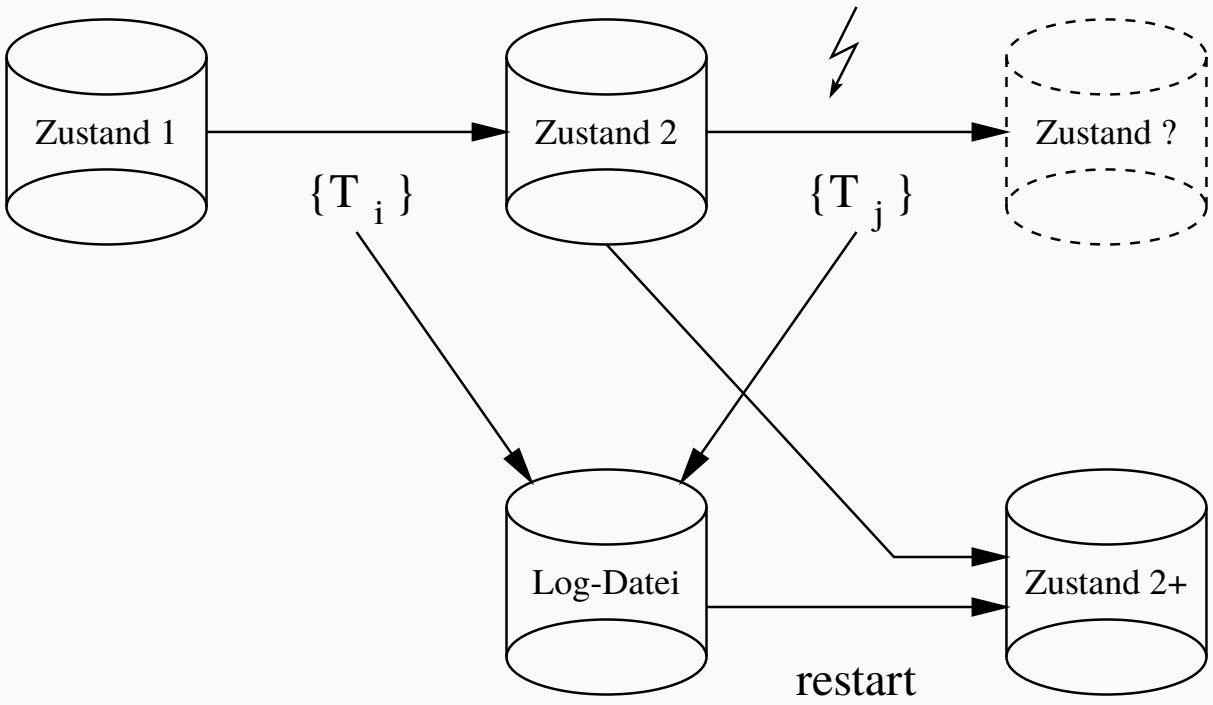

- Problem: einige TAs in $\{T_j\}$ waren noch aktiv, andere haben schon committet
- Restart stellt Zustand 2 + die Änderungen der committeten TAs in $\{T_j\}$ wieder her

Abbruch einer Transaktion

- Log-Dateien können auch dazu verwendet werden die Änderungen einer abgebrochenen TA zurückzusetzen
- Nach diesem groben Überblick werfen wir jetzt einen Blick hinter die Kulissen

Fehlerklassifikation

- Lokaler Fehler in einer noch nicht festgeschriebenen (committed) Transaktion
  - Wirkung muss zurückgesetzt werden
  - R1-Recovery
- Fehler mit Hauptspeicherverlust
  - abgeschlossene TAs müssen erhalten bleiben (R2-Recovery)
  - noch nicht abgeschlossene TAs müssen zurückgesetzt werden (R3-Recovery)
- Fehler mit Hintergrundspeicherverlust
  - R4-Recovery

Speicherhierarchie

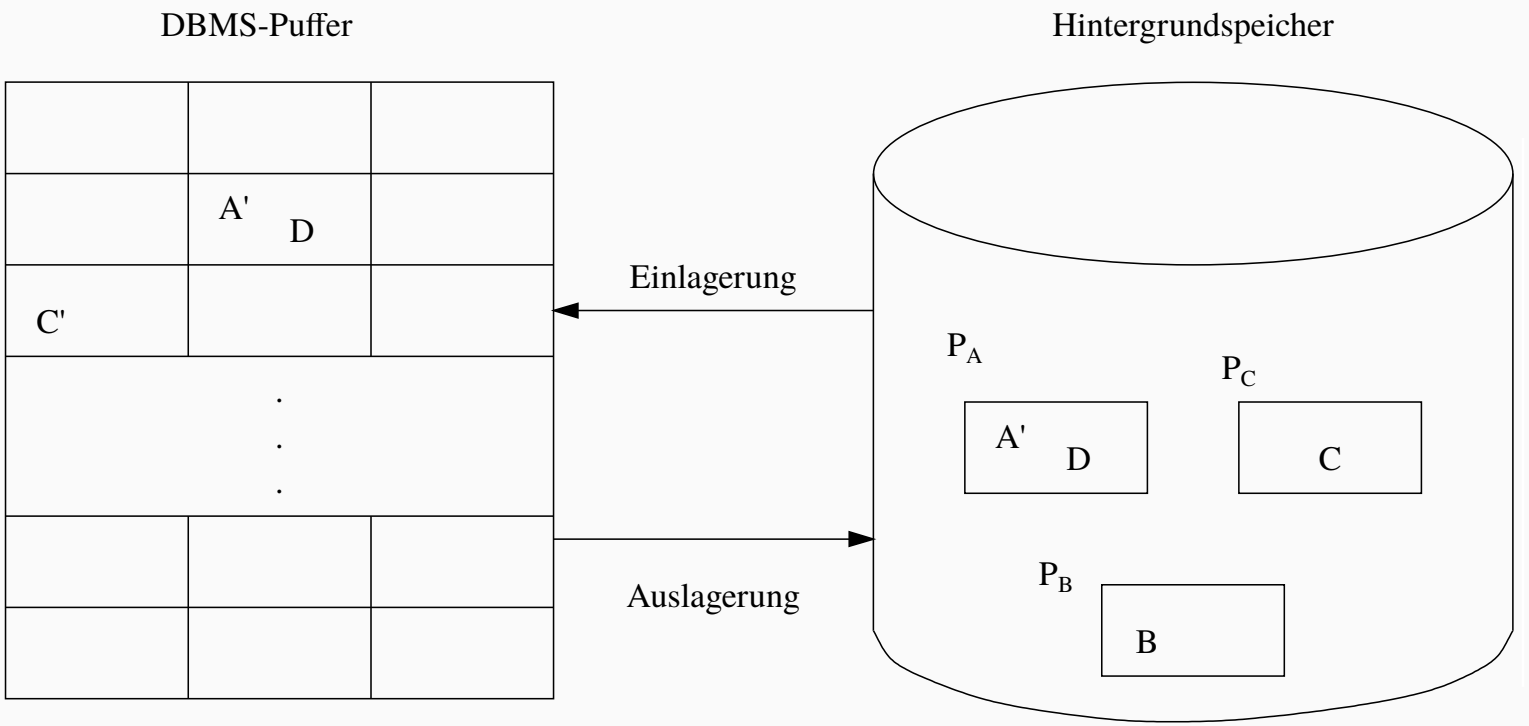

Speicherhierarchie (2)

- Ersetzungsstrategien von Puffer-Seiten
  - $\neg$*steal*: Ersetzung von Seiten, die von einer noch aktiven Transaktion modifiziert wurden, ausgeschlossen
  - *steal*: Jede nicht fixierte Seite ist prinzipiell ein Kandidat für die Ersetzung, falls neue Seiten eingelagert werden müssen

Speicherhierarchie (3)

- Einbringen von Änderungen abgeschlossener TAs
  - *force*-Strategie: Änderungen werden zum Transaktionsende auf den Hintergrundspeicher geschrieben
  - ¬*force*-Strategie: geänderte Seiten können im Puffer verbleiben und später zurückgeschrieben werden

Auswirkung auf Recovery

	force	¬force
¬steal	• kein Redo • kein Undo	• Redo • kein Undo
steal	• kein Redo • Undo	• Redo • Undo

Einbringstrategien

- Update in Place
  - jede Seite hat genau eine ”Heimat” auf dem Hintergrundspeicher
  - der alte Zustand der Seite wird überschrieben
- Twin-Block-Verfahren

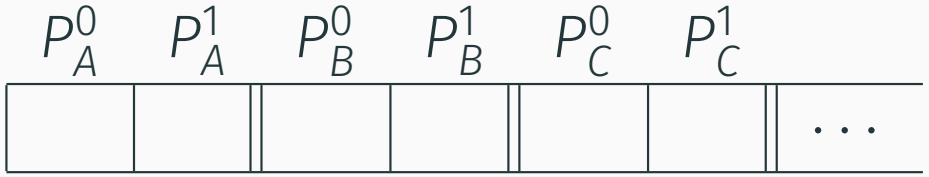

- Schattenspeicherkonzept
  - nur geänderte Seiten werden dupliziert
  - weniger Redundanz als beim Twin-Block-Verfahren

Systemkonfiguration

- steal
- ¬force
- update-in-place
- Kleine Sperrgranulate

ARIES-Protokoll

- ARIES-Protokoll ist weit verbreitetes Protokoll zur Fehlerbehandlung in DBMSen
- Log-Datei enthält:
  - Redo-Information: gibt an, wie Änderungen nachvollzogen werden können
  - Undo-Information: beschreibt, wie Änderungen rückgängig gemacht werden können

Schreiben der Log-Daten

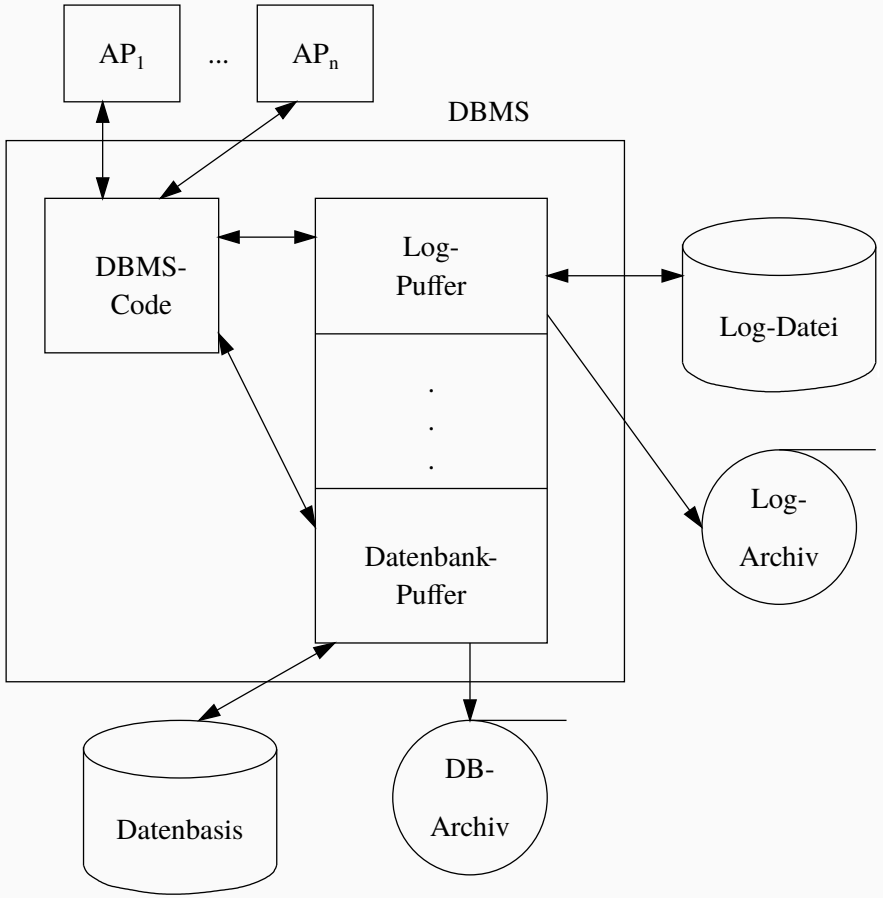

- Die Log-Information wird zweimal geschrieben
  - Log-Datei für schnellen Zugriff: R1, R2 und R3-Recovery
  - Log-Archiv: R4-Recovery

Schreiben der Log-Daten (2)

- Anordnung des Log-Ringpuffers:

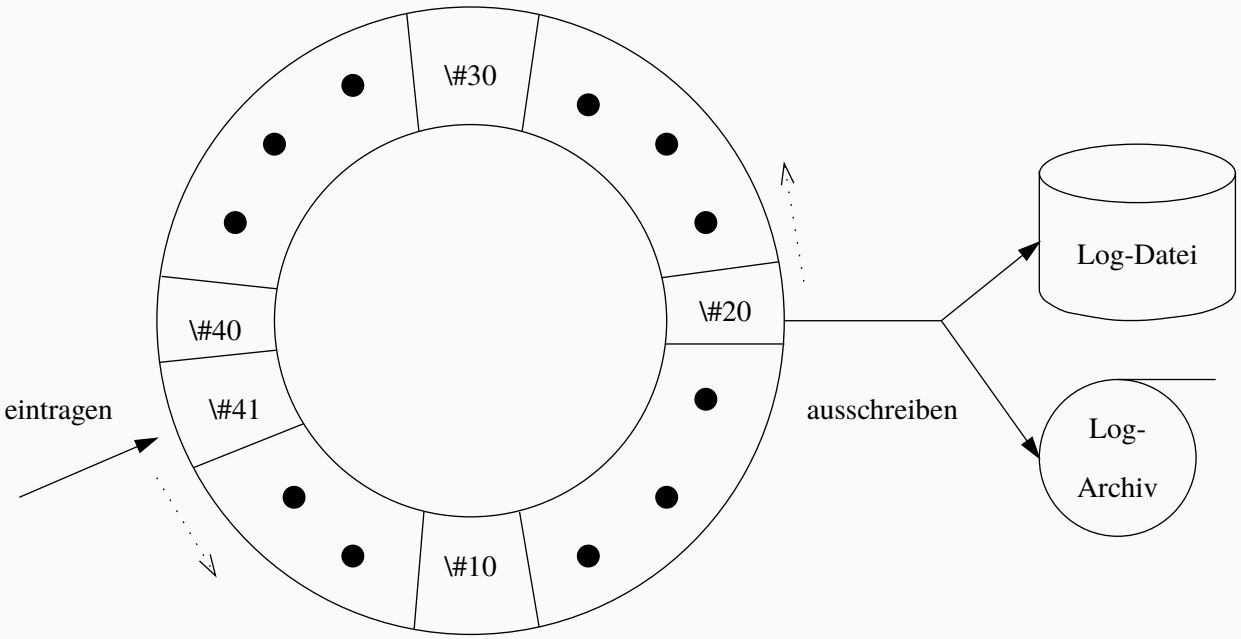

Schreiben der Log-Daten (3)

- **W**rite **A**head **L**og-Prinzip (WAL-Prinzip)
  - Bevor eine Transaktion festgeschrieben (**committed**) wird, müssen alle ”zu ihr gehörenden” Log-Einträge ausgeschrieben werden
  - Bevor eine modifizierte Seite ausgelagert werden darf, müssen alle Log-Einträge, die zu dieser Seite gehören, in das temporäre und das Log-Archiv ausgeschrieben werden

Wiederanlauf nach Fehler

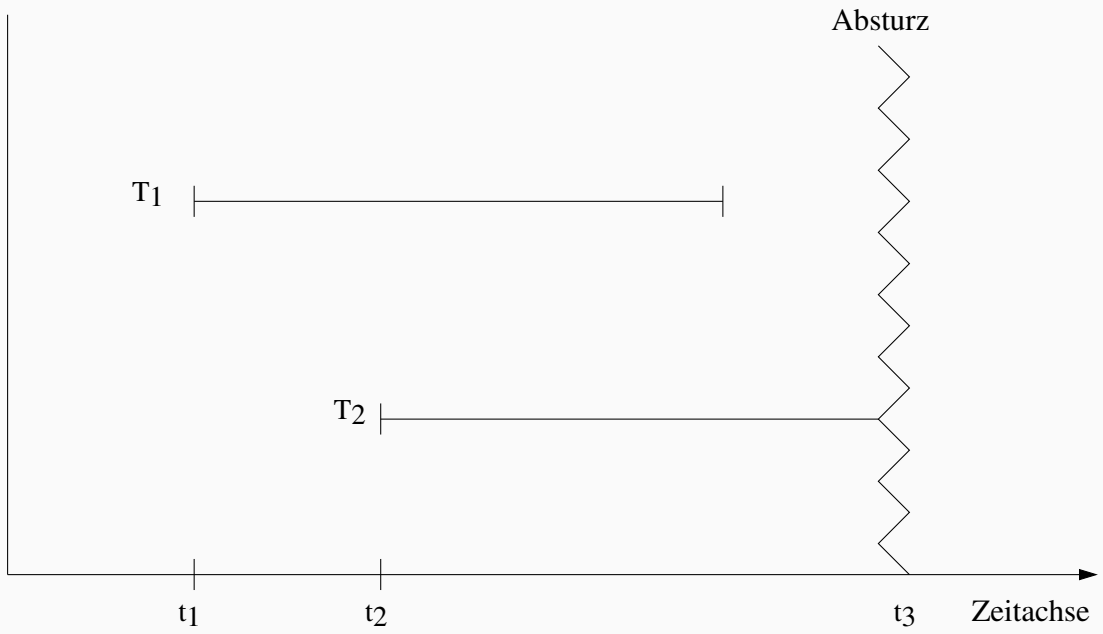

- TAs der Art T_1 sind *Winner*: müssen vollständig nachvollzogen werden
- TAs der Art T_2 sind *Loser*: müssen rückgängig gemacht werden

Phasen des Wiederanlaufs

- *Analyse*:
  - Ermittlung der *Winner*-Menge von Transaktionen des Typs T_1
  - Ermittlung der *Loser*-Menge von Transaktionen der Art T_2.
- *Wiederholung der Historie*:
  - *Alle* protokollierten Änderungen werden in der Reihenfolge ihrer Ausführung in die Datenbasis eingebracht
- *Undo der Loser*:
  - Die Änderungoperationen der *Loser*-Transaktionen werden in umgekehrter Reihenfolge ihrer ursprünglichen Ausführung rückgängig gemacht

Phasen des Wiederanlaufs (2)

Struktur der Log-Einträge

[LSN,TA,PageID,Redo,Undo,PrevLSN]

- Redo:
  - Physische Protokollierung: After-Image
  - Logische Protokollierung: Code mit dem aus dem Before-Image das After-Image erzeugt werden kann
- Undo:
  - Physische Protokollierung: Before-Image
  - Logische Protokollierung: Code mit dem aus dem After-Image das Before-Image erzeugt werden kann

Struktur der Log-Einträge (2)

- *LSN* (*Log Sequence Number*),
  - eine eindeutige Kennung des Log-Eintrags
  - *LSNs* müssen monoton aufsteigend vergeben werden,
  - die chronologische Reihenfolge der Protokolleinträge kann dadurch ermittelt werden
- *TA*
  - Transaktionskennung der Transaktion, die die Änderung durchgeführt hat

Struktur der Log-Einträge (3)

- *PageID*
  - die Kennung der Seite, auf der die Änderungsoperation vollzogen wurde
  - Wenn eine Änderung mehr als eine Seite betrifft, müssen entsprechend viele Log-Einträge generiert werden
- *PrevLSN*,
  - Zeiger auf den vorhergehenden Log-Eintrag der jeweiligen Transaktion
  - Diesen Eintrag benötigt man aus Effizienzgründen

Beispiel einer Log-Datei

	T_1	T_2	Log [LSN,TA,PageID,Redo,Undo,PrevLSN]
1.	BOT		[#1, T_1,BOT, 0]
2.	$r(A, a_1)$		
3.		BOT	[#2, T_2, BOT, 0]
4.		$r(C, c_2)$	
5.	$a_1 := a_1 - 50$		
6.	$w(A, a_1)$		[#3, T_1, P_A, A−=50, A+=50, #1]
7.		$c_2 := c_2 + 100$	
8.		$w(C, c_2)$	[#4, T_2, P_C, C+=100, C−=100, #2]
9.	$r(B, b_1)$		
10.	$b_1 := b_1 + 50$		
11.	$w(B, b_1)$		[#5, T_1, P_B, B+=50, B−=50, #3]
12.	commit		[#6, T_1, commit, #5]
13.		$r(A, a_2)$	
14.		$a_2 := a_2 - 100$	
15.		$w(A, a_2)$	[#7, T_2, P_A, A−=100, A+=100, #4]
16.		commit	[#8, T_2, commit, #7]

Fehlertoleranz Wiederanlauf: Idempotenz

$$undo(undo(\cdots(undo(a))\cdots)) = undo(a)$$
$$redo(redo(\cdots(redo(a))\cdots)) = redo(a)$$

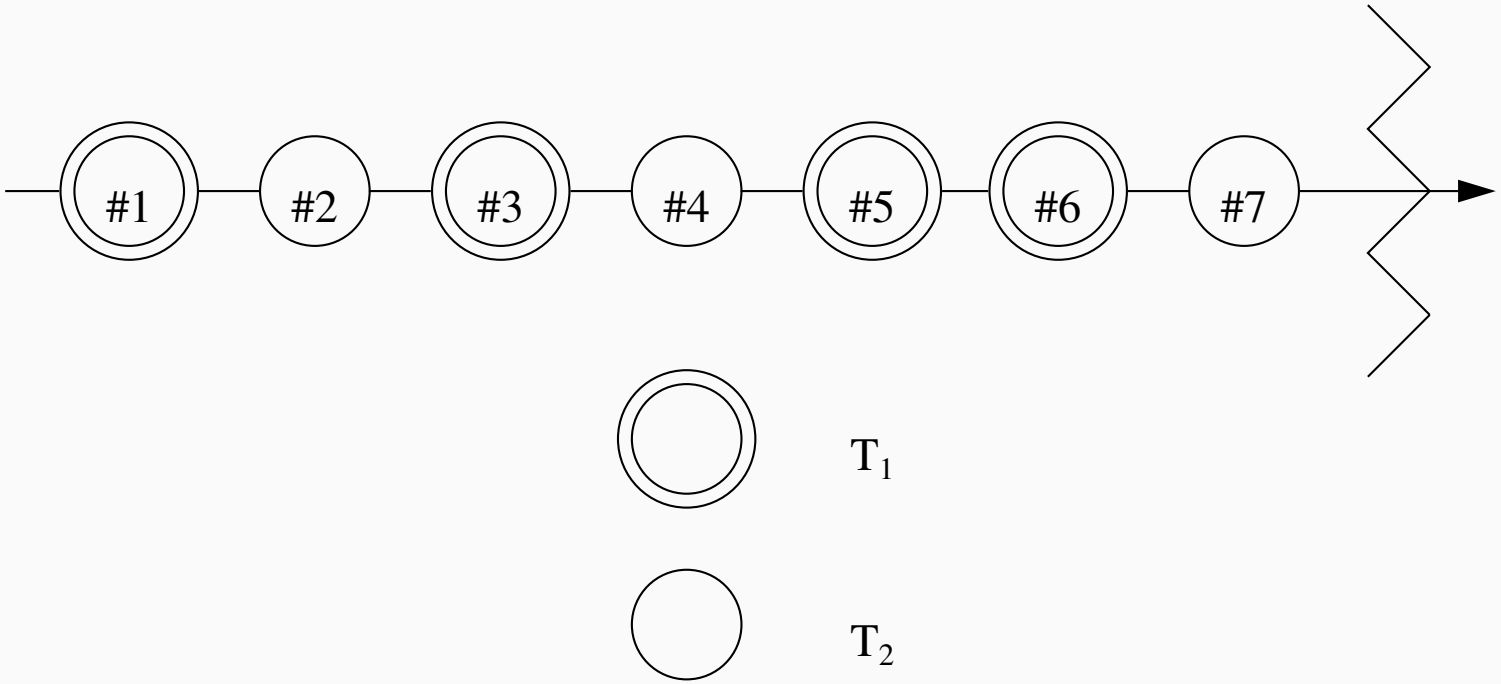

Fehlertoleranz Wiederanlauf: Idempotenz bei Redo

- Die Idempotenz der Redo-Phase wird dadurch erreicht, dass die LSN des Log-Records, für den ein Redo (tatsächlich) ausgeführt wird, in die Seite eingetragen wird.
- Dadurch wird sichergestellt, dass auch nach einem Absturz während des Wiederanlaufs ein Redo einer Operation nicht “versehentlich” auf dem After-Image der Operation ausgeführt wird.

Fehlertoleranz Wiederanlauf: Idempotenz bei Undo

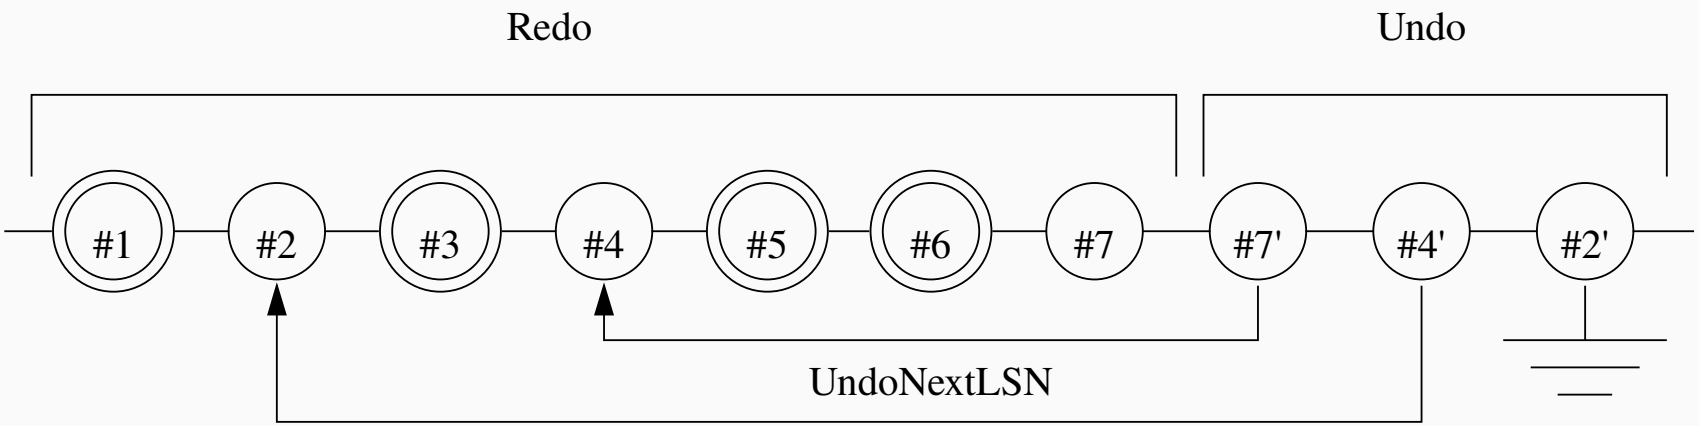

- Kompensationseinträge (CLR: compensating log record) für rückgängig gemachte Änderungen.
- #7’ ist CLR für #7
- #4’ ist CLR für #4

Logeinträge nach Wiederanlauf

$$[\#1, T_1, \textbf{BOT}, 0]$$
$$[\#2, T_2, \textbf{BOT}, 0]$$
$$[\#3, T_1, P_A, A{-}{=}50, A{+}{=}50, \#1]$$
$$[\#4, T_2, P_C, C{+}{=}100, C{-}{=}100, \#2]$$
$$[\#5, T_1, P_B, B{+}{=}50, B{-}{=}50, \#3]$$
$$[\#6, T_1, \textbf{commit}, \#5]$$
$$[\#7, T_2, P_A, A{-}{=}100, A{+}{=}100, \#4]$$
$$\langle \#7', T_2, P_A, A{+}{=}100, \#7, \#4 \rangle$$
$$\langle \#4', T_2, P_C, C{-}{=}100, \#7', \#2 \rangle$$
$$\langle \#2', T_2, -, -, \#4', 0 \rangle$$

- CLRs sind durch spitze Klammern $\langle \ldots \rangle$ gekennzeichnet

CLR

- der Aufbau eines CLR ist wie folgt
  - LSN
  - TA-Identifikator
  - betroffene Seite
  - Redo-Information
  - PrevLSN
  - UndoNxtLSN (Verweis auf die nächste rückgängig zu machende Änderung)

Partielles Zurücksetzen

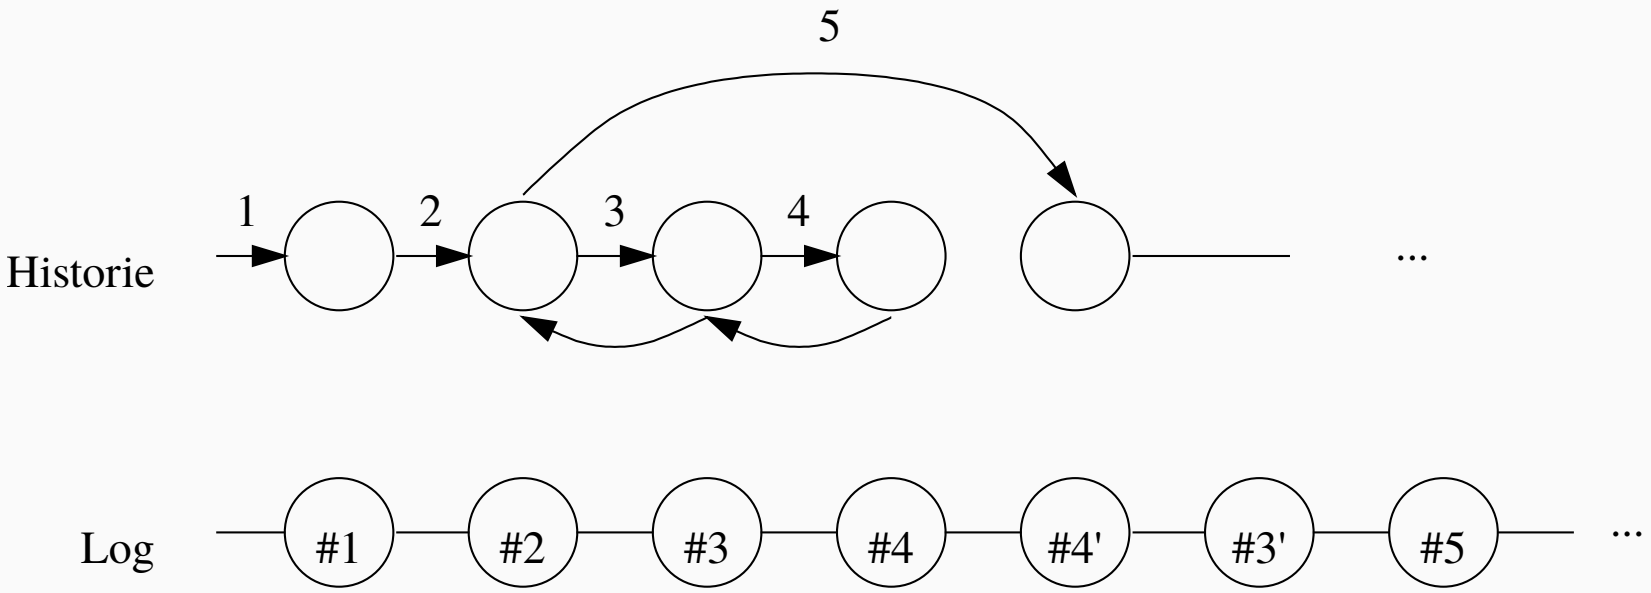

- Schritte 3 und 4 werden zurückgenommen
- notwendig für die Realisierung von Sicherungspunkten innerhalb einer TA

Sicherungspunkte

- prinzipiell ist logging ausreichend für ACID
- allerdings würden die Log-Größe und die Recovery-Zeit unbeschränkt wachsen
- deswegen will man periodisch Sicherungspunkte (“checkpoints”) anlegen, die es einem ermöglichen alte Log-Einträge zu ignorieren
- schreibt modifizierte (“dirty”) Seiten auf Platte

Transaktionskonsistenter Sicherungspunkt

- wartet bis laufende Transaktionen beenden sind
- verzögert neue Transaktionen
- schreibt alle modifizierten Seiten

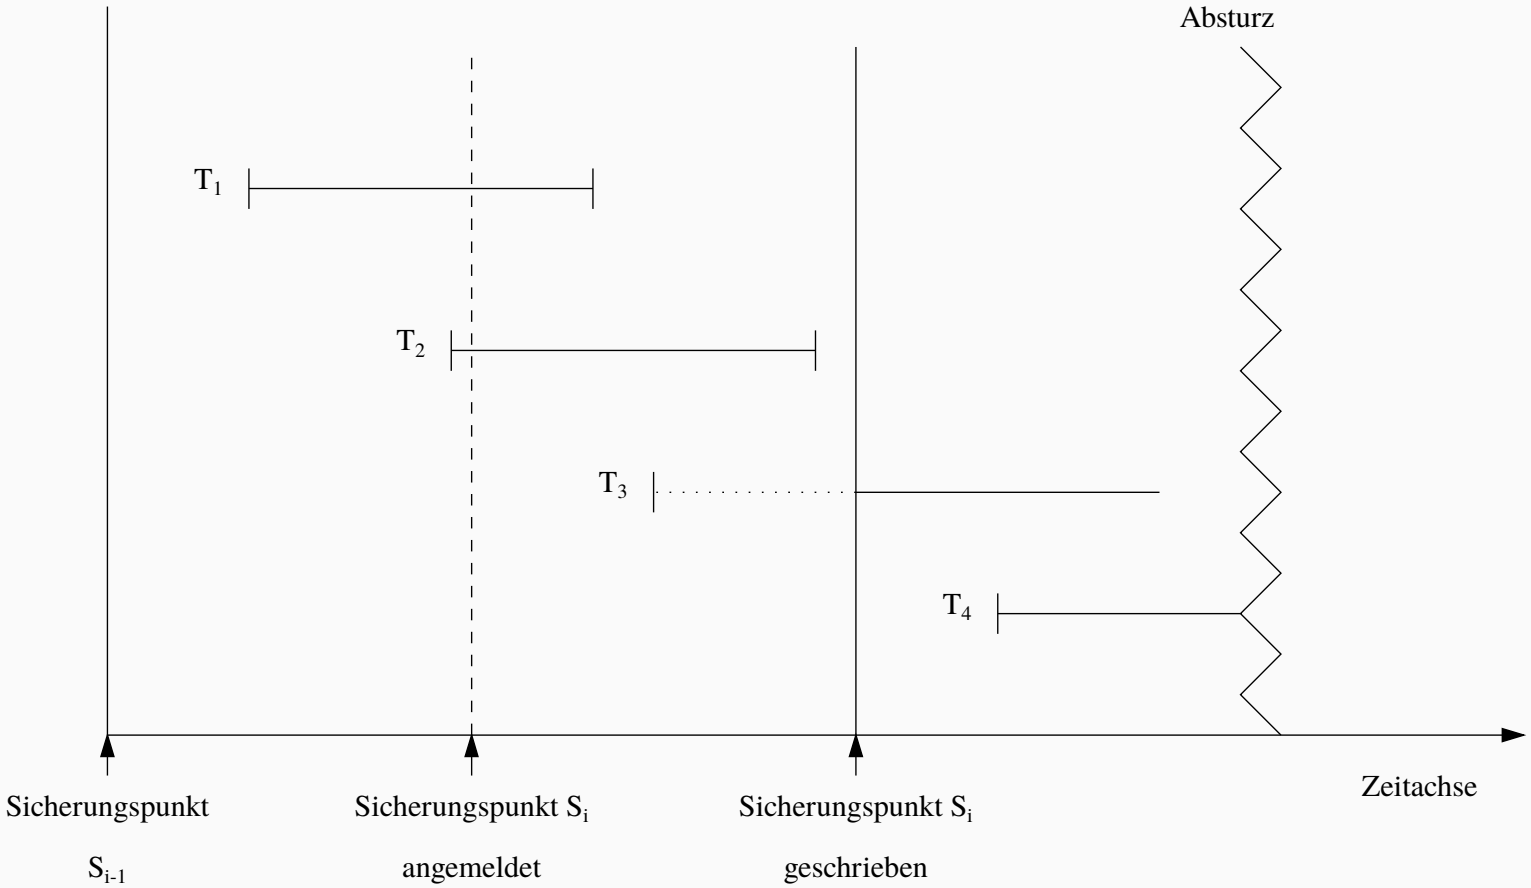

Transaktionskonsistenter Sicherungspunkt (2)

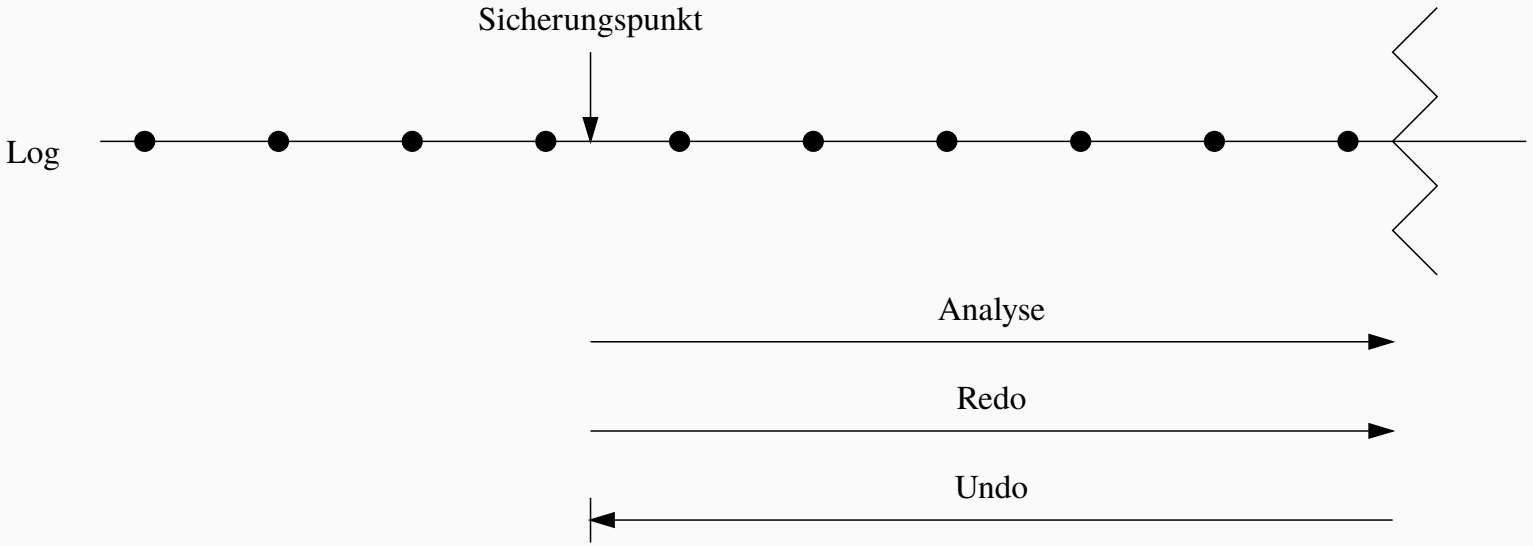

Aktionskonsistenter Sicherungspunkt

- wartet auf elementare Operationen (INSERT, UPDATE, DELETE)
- verzögert neue Operationen
- schreibt alle modifizierten Seiten

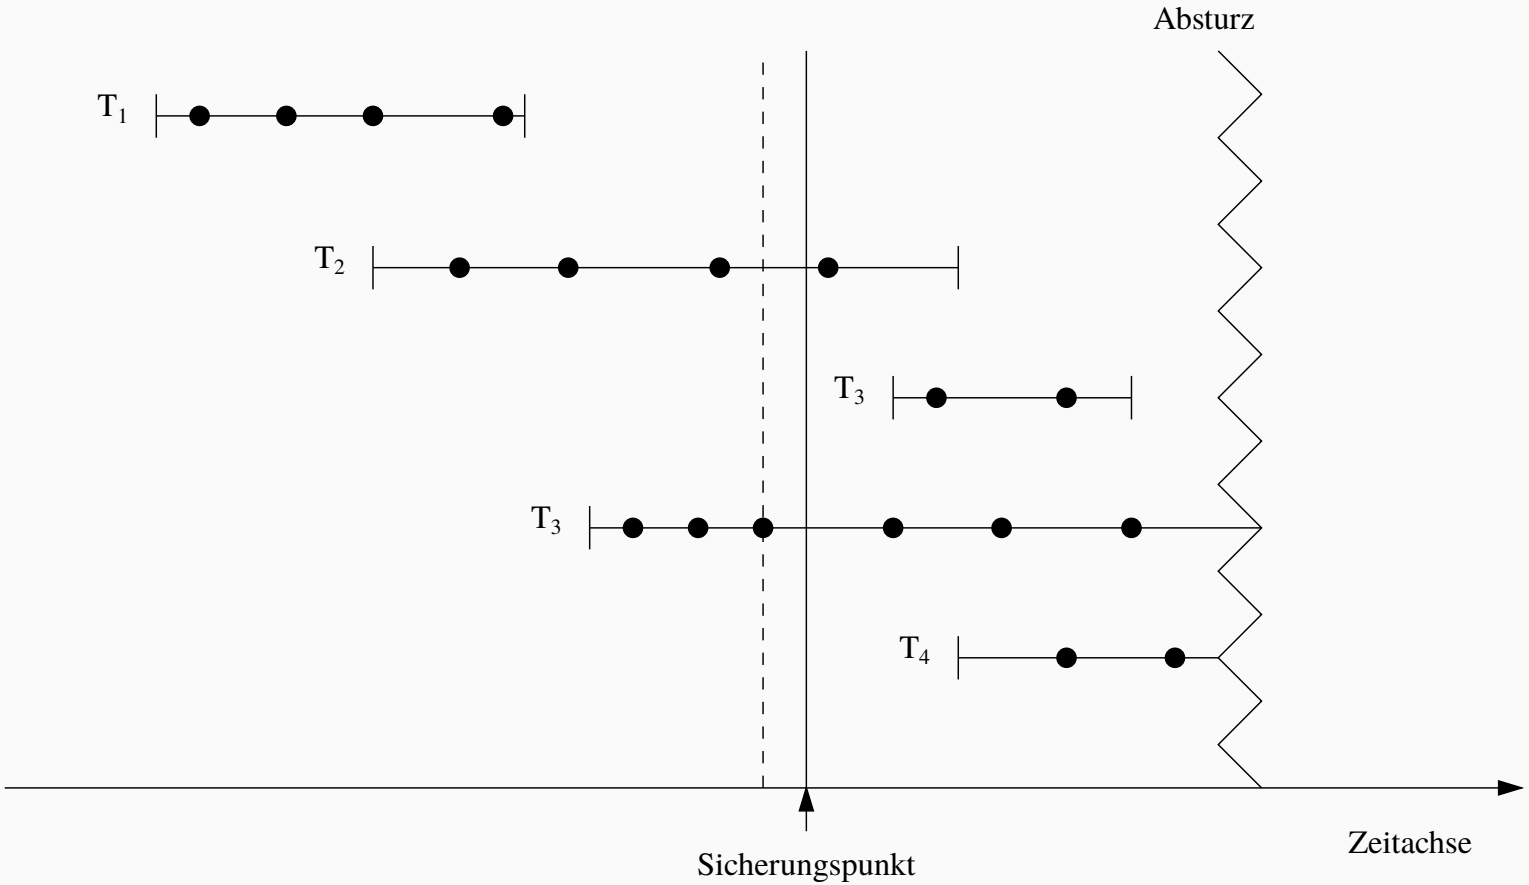

Aktionskonsistenter Sicherungspunkt (2)

- MinLSN: kleinste LSN aller aktiven Transaktionen zum Zeitpunkt des Sicherungspunktes

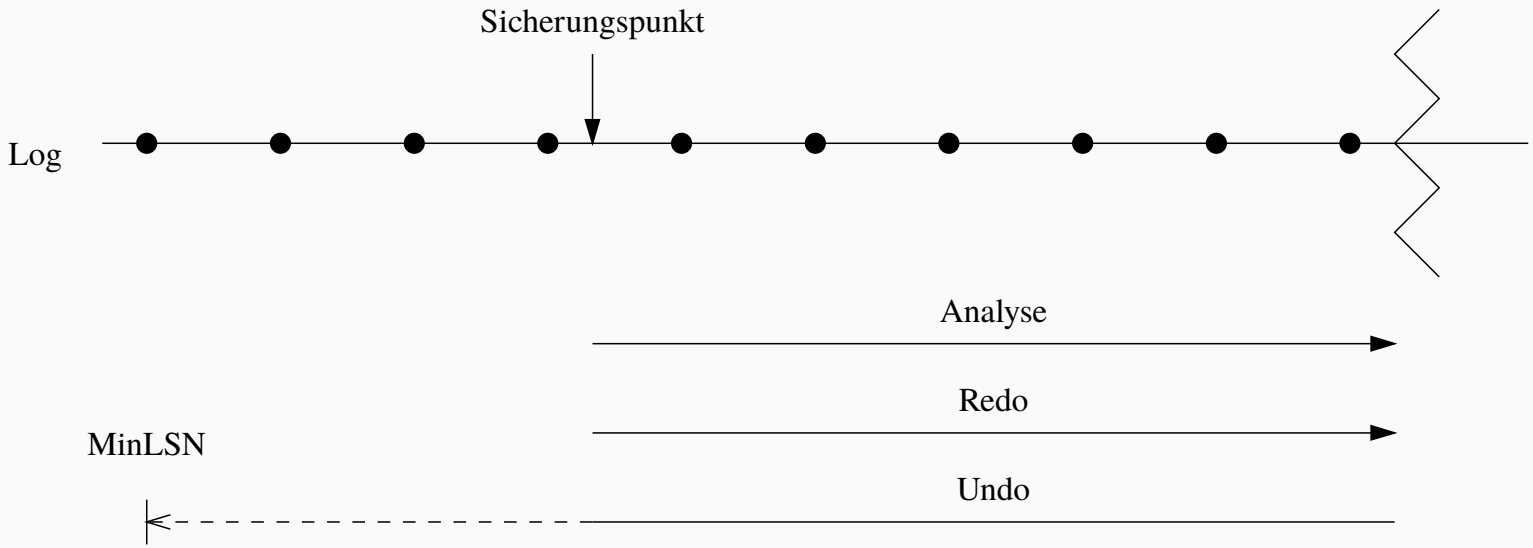

Unscharfer Sicherungspunkt

- behindert Ausführung normaler Transaktionen nicht

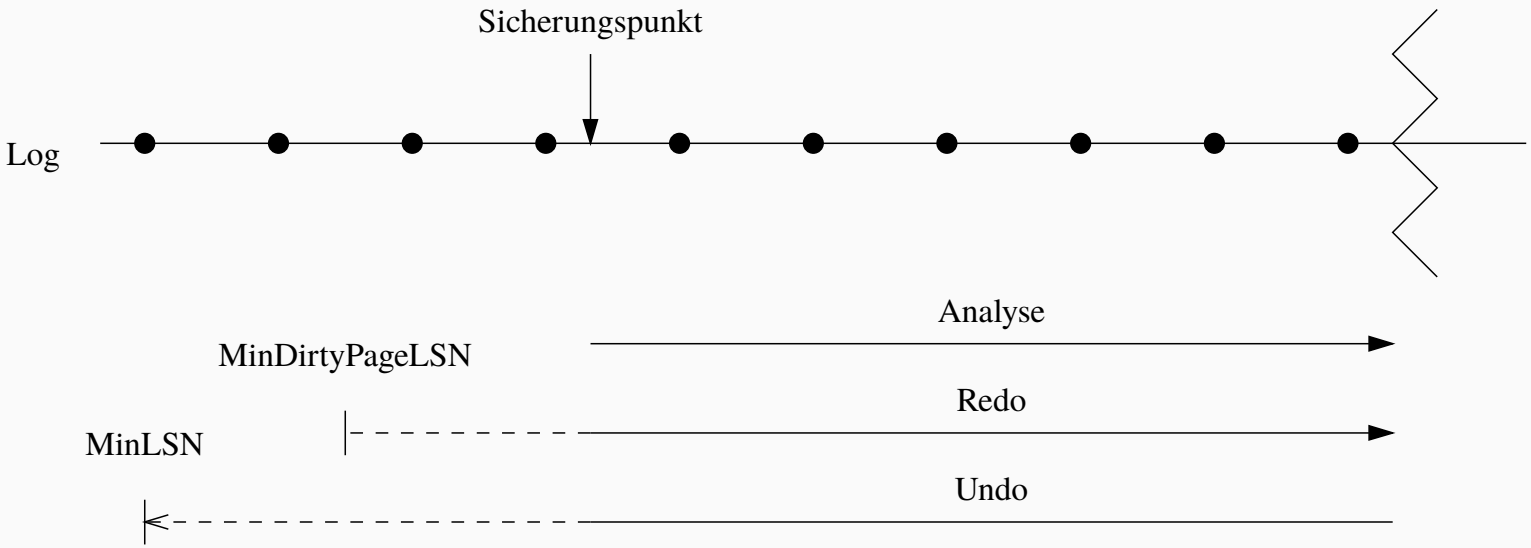

Unscharfer Sicherungspunkt (2)

- modifizierte Seiten werden nicht ausgeschrieben, nur deren Kennung
  - *Dirty Pages*=Menge der modifizierten Seiten
- *MinDirtyPageLSN*: die minimale LSN, deren Änderungen noch nicht ausgeschrieben wurde

Unscharfer Sicherungspunkt (3)

- bei unscharfen Sicherungspunkte müssen modifizierte Seiten nicht geschrieben werden
- trotzdem ist es natürlich sinnvoll dies periodisch zu tun
- insbesondere ist es wichtig “hot-spot” Seiten, die ständig modifiziert werden und deswegen dauerhaft im Puffer verbleiben, von Zeit zu Zeit zu schreiben

Zusammenfassung

- Fehlerbehandlung (Recovery) kann Zustand der Datenbasis zum Absturzzeitpunkt wiederherstellen
- Die zwei Hauptmechanismen dazu sind:
  - Log-Dateien
  - Sicherungspunkte
- In der Praxis sind unscharfe Sicherungspunkte zu bevorzugen und werden deswegen von den meisten Systemen implementiert
- Sicherungspunkte ermöglichen es alte Log-Dateien zu entfernen

Mehrbenutzersynchronisation

Mehrbenutzersynchronisation

- Alle TAs strikt seriell (also nacheinander) auszuführen ist sicher, aber langsam
- Oft werden Systemressourcen nicht voll ausgenutzt, da eine TA auf Plattenzugriff oder Benutzereingabe wartet
- Diese TA blockiert dann alle anderen TAs
- Um Systemressourcen auszunutzen bietet sich Nebenläufigkeit an

Mehrbenutzersynchronisation (2)

- Nicht abgesicherte Nebenläufigkeit kann aber zu folgenden Problemen führen:
  - lost update
  - dirty read
  - non-repeatable read
  - phantom problem

Dirty Read

T_1	T_2
bot	
$\hookrightarrow$	bot
	$r_2(x)$
	$w_2(x)$
$r_1(x)$	$\hookleftarrow$
$w_1(y)$	
commit	
$\hookrightarrow$	abort

T_1 liest einen Wert für x der so nicht gültig ist!

Lost Update

T_1	T_2
bot	
$r_1(x)$	
$\hookrightarrow$	bot
	$r_2(x)$
$w_1(x)$	$\hookleftarrow$
$\hookrightarrow$	$w_2(x)$
commit	$\hookleftarrow$
$\hookrightarrow$	commit

Das Ergebnis der Transaktion T_1 ist verlorengegangen!

Non-Repeatable Read

T_1	T_2
bot	
$r_1(x)$	
$\hookrightarrow$	bot
	$w_2(x)$
	commit
$r_1(x)$	$\hookleftarrow$
...	

T_1 liest x zweimal mit verschiedenem Ergebnis!

Phantom Problem

T_1	T_2
bot	
select count(*) from R;	
$\hookrightarrow$	bot
	insert into R ...;
	commit
select count(*) from R;	$\hookleftarrow$
...	

T_1 findet ein weiteres Tupel beim Abarbeiten der zweiten Anfrage!

Vermeidung der Probleme

- Im Idealfall sollten alle diese Probleme vermieden werden
- Man muss dabei allerdings einen Kompromiß zwischen Performanz und Genauigkeit schließen
- Je mehr Sicherheit, desto langsamer wird die Ausführung
- Über die *Isolation Levels* kann man DBMS mitteilen, welche Sicherheit erwünscht ist

Transaktionen und SQL

- Festsetzen von Eigenschaften einer TA:

  set transaction isolation level *Stufe, Zugriffsmodus*

- Folgende Stufen für den Isolation Level sind möglich:
  - read uncommitted
  - read committed
  - repeatable read
  - serializable
- Achtung: in vielen Systemen ist read committed die Standardeinstellung
- Mögliche Zugriffsmodi:
  - read only
  - read write

Transaktionen und SQL (2)

	dirty read	lost update	nonrep. read	phant. probl.
read uncommitted				
read committed	√			
repeatable read	√	√	√	
serializable	√	√	√	√

default in PostgreSQL: read committed

Transaktionen und SQL (3)

- “read only” sagt dem DBMS, dass eine TA nur Leseoperationen enthält
- Das hat Auswirkungen auf die Performanz
- Nebenläufiges Ausführen von TAs die nur lesen ist unkritisch, d.h. beliebig vieler solcher TAs können völlig uneingeschränkt parallel laufen
- Erst wenn eine TA dazukommt, die auch schreibt müssen Vorkehrungen getroffen werden

Transaktionen und SQL (4)

- Befehl zum Markieren eines Transaktionsbeginns

  start transaction; oder **begin;**

- Befehl zur erfolgreichen Beendigung

  commit [work];

- Befehl zum Abbruch

  rollback [work];

Bonusanomalie: Write Skew (“Serialization Anomaly”)

T_1	T_2
bot	
$\hookrightarrow$	bot
	$p := r_2(x)$
	$w_2(y, p)$
$q := r_1(y)$	$\hookleftarrow$
$w_1(x, q)$	
commit	
$\hookrightarrow$	commit?

Bei einer beliebigen seriellen Ausführung ist $x = y$.

Write Skew und Snaptshot Isolation

- Viele Systeme (z.B. Oracle) lassen obige Ausführung auch im `serializable` Modus zu
- Ergebnis ist, dass die Werte *x* und *y* vertauscht werden
- Solche Systeme implementieren “Snapshot Isolation”, bei dem Leser keine Sperren halten
- Es ist nicht klar, ob dieses Verhalten dem SQL Standard entspricht
- Seit Version 9.5 machte PostgreSQL es “richtig”, d.h. eine der beiden Transaktionen wird abgebrochen

Was macht ein DBMS?

- Um Lösungsansätze besser verstehen zu können, wird das Problem zunächst etwas formaler betrachtet
- Danach werden Lösungen vorgestellt, die in DBMS eingesetzt werden

Formale Definition einer TA

- Operationen einer TA T_i
  - $r_i(A)$: Lesen des Datenobjekts A
  - $w_i(A)$: Schreiben des Datenobjekts A
  - a_i: Abbruch
  - c_i: erfolgreiche Beendigung

  - *bot*: begin of transaction (implizit)

Formale Definition einer TA (2)

- Eine TA T_i ist eine partielle Ordnung von Operationen mit der Ordnungsrelation $<_i$ so dass:
  - $T_i \subseteq \{r_i[x], w_i[x] \mid x \text{ ist ein Datenobjekt}\}$ $\cup\{a_i, c_i\}$
  - $a_i \in T_i$, gdw. $c_i \notin T_i$
  - Sei t gleich a_i oder c_i, dann gilt für jede andere Operation p_i: $p_i <_i t_i$
  - Falls $r_i[x]$ und $w_i[x] \in T_i$, dann gilt entweder $r_i[x] <_i w_i[x]$ oder $w_i[x] <_i r_i[x]$

Darstellung

- Transaktionen werden oft als gerichtete azyklische Graphen (DAGs) dargestellt:

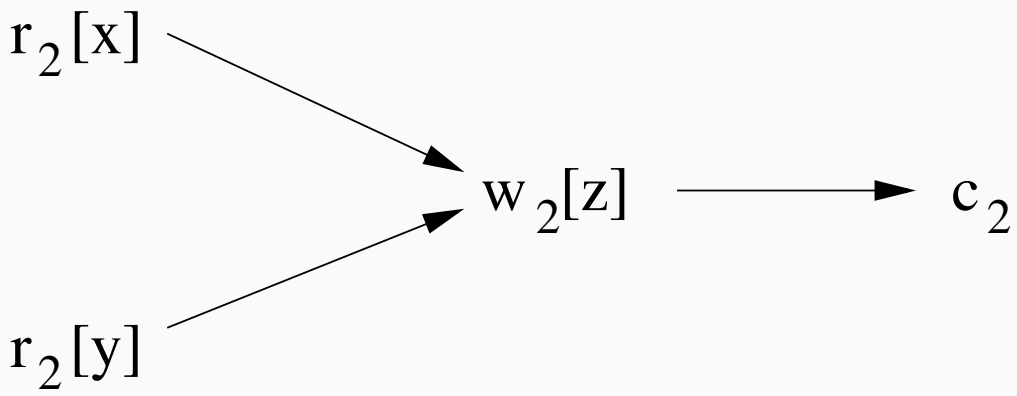

- $r_2[x] <_2 w_2[z]$, $w_2[z] <_2 c_2$, $r_2[x] <_2 c_2$, $r_2[y] <_2 w_2[z]$, $r_2[y] <_2 c_2$
- Transitive Beziehungen sind im Graph implizit enthalten

Historien (Schedules)

- Mehrere TAs können nebenläufig ausgeführt werden
- Dies wird durch eine *Historie* (Schedule) beschrieben
- Eine Historie gibt an, wie Operationen aus verschiedenen TAs relativ zueinander ausgeführt werden
- Da verschiedene Operationen parallel ausgeführt werden können, ist eine Historie eine partielle Ordnung

Konfliktoperationen

- Operationen, die in Konflikt miteinander stehen, dürfen nicht parallel ausgeführt werden
- Zwei Operationen stehen in Konflikt miteinander, wenn beide auf dem gleichen Datenobjekt arbeiten und mindestens eine davon eine Schreiboperation ist

	T_i	
T_j	$r_i[x]$	$w_i[x]$
$r_j[x]$		$\neg$
$w_j[x]$	$\neg$	$\neg$

Definition von Historien

- Sei $T = \{T_1, T_2, \ldots, T_n\}$ eine Menge von Transaktionen
- Eine Historie H über T ist eine partielle Ordnung mit der Ordnungsrelation $<_H$, so dass
  - $H = \bigcup_{i=1}^{n} T_i$
  - $<_H \supseteq \bigcup_{i=1}^{n} <_i$
  - Für zwei beliebige Operationen $p, q \in H$ die in Konflikt miteinander stehen gilt: entweder $p <_H q$ oder $q <_H p$

Beispiel einer Historie

$$
\begin{array}{llllll}
 & & r_2[x] \rightarrow & w_2[y] \rightarrow & w_2[z] \rightarrow & c_2 \\
 & & \uparrow & \uparrow & \uparrow & \\
H = & r_3[y] \rightarrow & w_3[x] \rightarrow & w_3[y] \rightarrow & w_3[z] \rightarrow & c_3 \\
 & & \uparrow & & & \\
 & r_1[x] \rightarrow & w_1[x] \rightarrow & c_1 & &
\end{array}
$$

(Konflikt-)Äquivalenz

- Zwei Historien H und H' sind *(konflikt-)äquivalent* ($H \equiv H'$), wenn:
  - Sie enthalten die gleichen Mengen von TAs (samt allen dazugehörigen Operationen)
  - Sie ordnen die Konfliktoperationen der nicht abgebrochenen TAs in der gleichen Art und Weise an
- Die Idee dabei ist, das berechnete Endergebnis nicht zu verändern

Beispiel

$$
\begin{aligned}
& r_1[x] \to w_1[y] \to r_2[z] \to c_1 \to w_2[y] \to c_2 \\
\equiv \quad & r_1[x] \to r_2[z] \to w_1[y] \to c_1 \to w_2[y] \to c_2 \\
\equiv \quad & r_2[z] \to r_1[x] \to w_1[y] \to w_2[y] \to c_2 \to c_1 \\
\not\equiv \quad & r_2[z] \to r_1[x] \to w_2[y] \to w_1[y] \to c_2 \to c_1
\end{aligned}
$$

Serialisierbarkeit

- Da serielle Historien sicher sind, ist es wünschenswert Historien mit ähnlichen Eigenschaften zu haben
- Insbesondere möchte man eine Historie haben die äquivalent zu einer seriellen Historie ist
- Eine solche Historie nennt man *serialisierbar*

Serialisierbarkeit (2)

- Präzise Definition:
  - Die *abgeschlossene Projektion* $C(H)$ einer Historie H enthält nur die erfolgreich abgeschlossenen TAs
  - Eine Historie H ist serialisierbar, wenn $C(H)$ äquivalent zu einer seriellen Historie H_s ist

Serialisierbarkeitstheorem

- Wie überprüft man die Serialisierbarkeit?
- Eine Historie ist genau dann serialisierbar, wenn ihr *Serialisierbarkeitsgraph* $SG(H)$ azyklisch ist

Serialisierbarkeitsgraph

- Der Serialisierbarkeitsgraph $SG(H)$ einer Historie $H = \{T_1, \ldots, T_n\}$ ist ein gerichteter Graph mit folgenden Eigenschaften:
  - Die Knoten sind die erfolgreich abgeschlossenen TAs aus H
  - Eine Kante zwischen zwei TAs T_i und T_j wird eingetragen, wenn es zwei Konfliktoperationen p_i und q_j gibt und $p_i <_H q_j$

Beispiel

- Historie H

$$H = w_1[x] \rightarrow w_1[y] \rightarrow c_1 \rightarrow r_2[x] \rightarrow r_3[y] \rightarrow w_2[x] \rightarrow c_2 \rightarrow w_3[y] \rightarrow c_3$$

- $SG(H)$

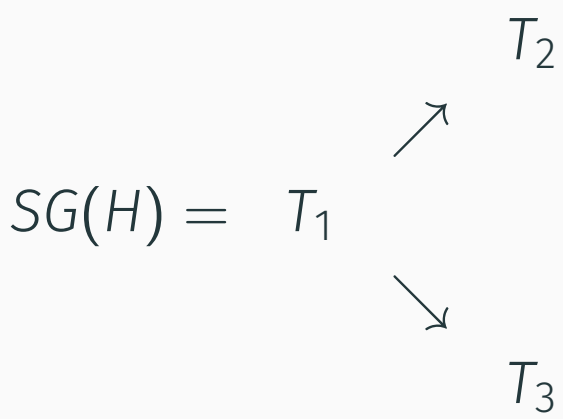

Beispiel (2)

- H ist serialisierbar
- Mögliche Ordnungen

$$H_s^1 = T_1 \mid T_2 \mid T_3$$
$$H_s^2 = T_1 \mid T_3 \mid T_2$$
$$H \equiv H_s^1 \equiv H_s^2$$

Beispiel (3)

$$
H = \begin{array}{ccccccc}
 & r_1[x] & \rightarrow & w_1[x] & \rightarrow & w_1[y] & \rightarrow & c_1 \\
 & & & \uparrow & & \uparrow & & \\
 & & \swarrow & r_2[x] & \rightarrow & w_2[y] & \rightarrow & c_2 \\
 & & & \downarrow & & & & \\
 & r_3[x] & \rightarrow & w_3[x] & \rightarrow & c_3 & &
\end{array}
$$

$$
SG(H) = \begin{array}{ccc}
 & & T_3 \\
 & \nearrow & \\
T_2 & & \uparrow \\
 & \searrow & \\
 & & T_1
\end{array}
$$

Beispiel (4)

- H ist serialisierbar
- Mögliche Ordnung

$$H_s^1 = T_2 \mid T_1 \mid T_3$$
$$H \equiv H_s^1$$

Beispiel (5)

$$H = \begin{array}{ccccc} & w_1[x] & \rightarrow & w_1[y] & \rightarrow & c_1 \\ & \uparrow & & \downarrow & & \\ & r_2[x] & \rightarrow & w_2[y] & \rightarrow & c_2 \end{array}$$

$$SG(H) = \quad T_1 \quad \leftrightarrows \quad T_2$$

- H ist nicht serialisierbar

Weitere Eigenschaften

- Für TAs sind weitere Eigenschaften wünschenswert:
  - Rücksetzbarkeit (Recoverability)
  - Vermeidung kaskadierenden Rücksetzens (avoiding cascading aborts: ACA)
  - Striktheit (strictness)

Weitere Eigenschaften (2)

- Zuerst müssen wir Schreib-/Leseabhängigkeiten (reads-from relationship) definieren
- Eine TA T_i liest (Datenobjekt x) von TA T_j, wenn
  - $w_j[x] < r_i[x]$
  - $a_j \not< r_i[x]$
  - Falls ein $w_k[x]$ existiert mit $w_j[x] < w_k[x] < r_i[x]$, dann $a_k < r_i[x]$
- Eine TA kann auch von sich selbst lesen

Rücksetzbarkeit

- Eine Historie ist *rücksetzbar*, wenn folgendes gilt
  - Immer wenn eine TA T_i von einer anderen TA T_j liest ($i \neq j$) und $c_i \in H$, dann $c_j < c_i$
- Die TAs müssen eine bestimmte Commit-Reihenfolge einhalten
- Bei nicht rücksetzbaren Historien können Probleme mit dem C und D der ACID-Eigenschaften auftreten

Rücksetzbarkeit (2)

$$H = w_1[x]\ r_2[x]\ w_2[y]\ c_2\ a_1$$

- H ist nicht rücksetzbar
- Die Konsequenzen sind:
  - Wenn Ergebnis von T_2 so stehen bleibt, dann haben wir inkonsistente Daten (T_2 hat Daten von einer abgebrochenen TA gelesen)
  - Wenn wir T_2 zurücksetzen, dann nehmen wir Änderungen einer fest zugesicherten TA zurück

Kaskadierendes Rücksetzen

Schritt	T_1	T_2	T_3	T_4	T_5
0.	$\ldots$				
1.	$w_1[x]$				
2.		$r_2[x]$			
3.		$w_2[y]$			
4.			$r_3[y]$		
5.			$w_3[z]$		
6.				$r_4[z]$	
7.				$w_4[v]$	
8.					$r_5[v]$
9.	a_1 (abort)				

Kaskadierendes Rücksetzen (2)

- Eine Historie *vermeidet kaskadierendes Rücksetzen*, wenn folgendes gilt
  - Immer wenn eine TA T_i von einer anderen TA T_j liest ($i \neq j$), dann $c_j < r_i[x]$
- Es darf nur von bereits erfolgreich abgeschlossenen TAs gelesen werden

Striktheit

- Eine Historie ist *strikt*, wenn folgendes gilt
  - Bei zwei Operationen $w_j[x] < o_i[x]$ (mit $o_i[x] = r_i[x]$ oder $w_i[x]$) gilt entweder $a_j < o_i[x]$ oder $c_j < o_i[x]$
- Nur von bereits erfolgreich abgeschlossenen TAs darf gelesen oder dürfen Datenobjekte überschrieben werden

Striktheit (2)

- Nur bei strikten Historien darf physische Protokollierung beim Recovery angewendet werden

$$
\begin{array}{ll}
x = 0 & \\
w_1[x, 1] & \text{before image von } T_1\text{: } 0 \\
x = 1 & \\
w_2[x, 2] & \text{before image von } T_2\text{: } 1 \\
x = 2 & \\
a_1 & \\
c_2 &
\end{array}
$$

Bei Abbruch von T_1 wird x fälschlicherweise auf 0 gesetzt

Einordnung

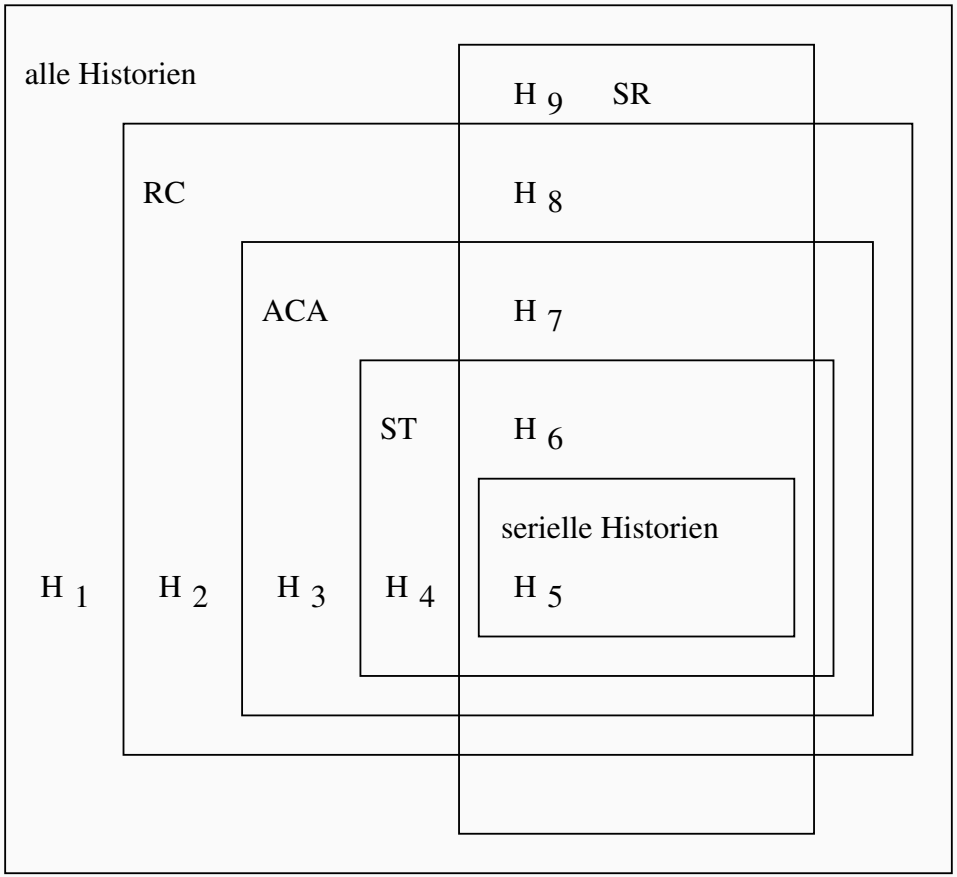

SR: serialisierbar, RC: rücksetzbar, ACA: vermeidet kaskadierendes Rücksetzen, ST: strikt

Datenbank-Scheduler

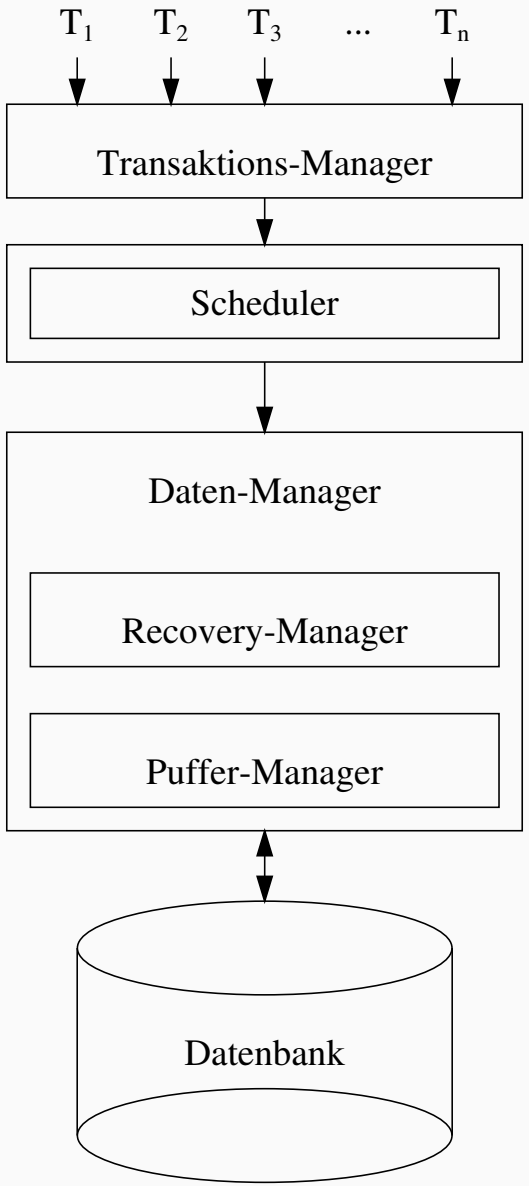

Datenbank-Scheduler (2)

- Ein *Scheduler* ist ein Programm, das die eingehenden Operationen ordnet und für eine serialisierbare und rücksetzbare Historie sorgt
- Mehrere Möglichkeiten nach Entgegennahme einer Operation:
  - (Sofort) ausführen
  - Zurückweisen
  - Verzögern

Datenbank-Scheduler (3)

- Es existieren zwei grobe Strategien:
  - Pessimistisch
  - Optimistisch

Pessimistische Scheduler

- Scheduler verzögert entgegengenommene Operationen
- Wenn mehrere Operationen da sind, legt Scheduler möglichst geschickte Reihenfolge fest
- Wichtigster Vertreter: Sperrbasierter Scheduler (in der Praxis weit verbreitet)

Optimistische Scheduler

- Scheduler schickt entgegengenommene Operationen möglichst schnell zur Ausführung,
- Muss später eventuell ”Schaden” reparieren

Sperrbasierte Synchronisation

- Hauptidee relativ einfach:
  - Jedes Datenobjekt hat eine zugehörige Sperre
  - Bevor eine TA T_i zugreifen darf, muss sie Sperre anfordern
  - Falls eine andere TA T_j Sperre hält, bekommt T_i die Sperre nicht und muss warten, bis T_j die Sperre freigegeben hat
  - Nur eine TA kann Sperre halten und auf Datenobjekt zugreifen
- Wie garantiert man Serialisierbarkeit?

Zwei-Phasen-Sperrprotokoll

- Abgekürzt durch 2PL
- Zwei Sperrmodi:
  - *S* (shared, read lock, Lesesperre)
  - *X* (exclusive, write lock, Schreibsperre)
  - Verträglichkeitsmatrix (auch Kompatibilitätsmatrix genannt):

	gehaltene Sperre		
angeford. Sp.	keine	*S*	*X*
S	√	√	–
X	√	–	–

Definition

- Jedes Objekt, das von einer TA benutzt werden soll, muss vorher entsprechend gesperrt werden
- Eine TA kann eine Sperre die sie hält nicht noch einmal anfordern
- Wenn eine Sperre nicht gewährt werden kann (nach Matrix), wird TA in Warteschlange eingereiht
- Eine TA darf nach der ersten Freigabe einer Sperre keine weitere anfordern (es gibt zwei Phasen)
- Bei Transaktionsende muss eine TA alle Sperren zurückgeben

Zwei Phasen

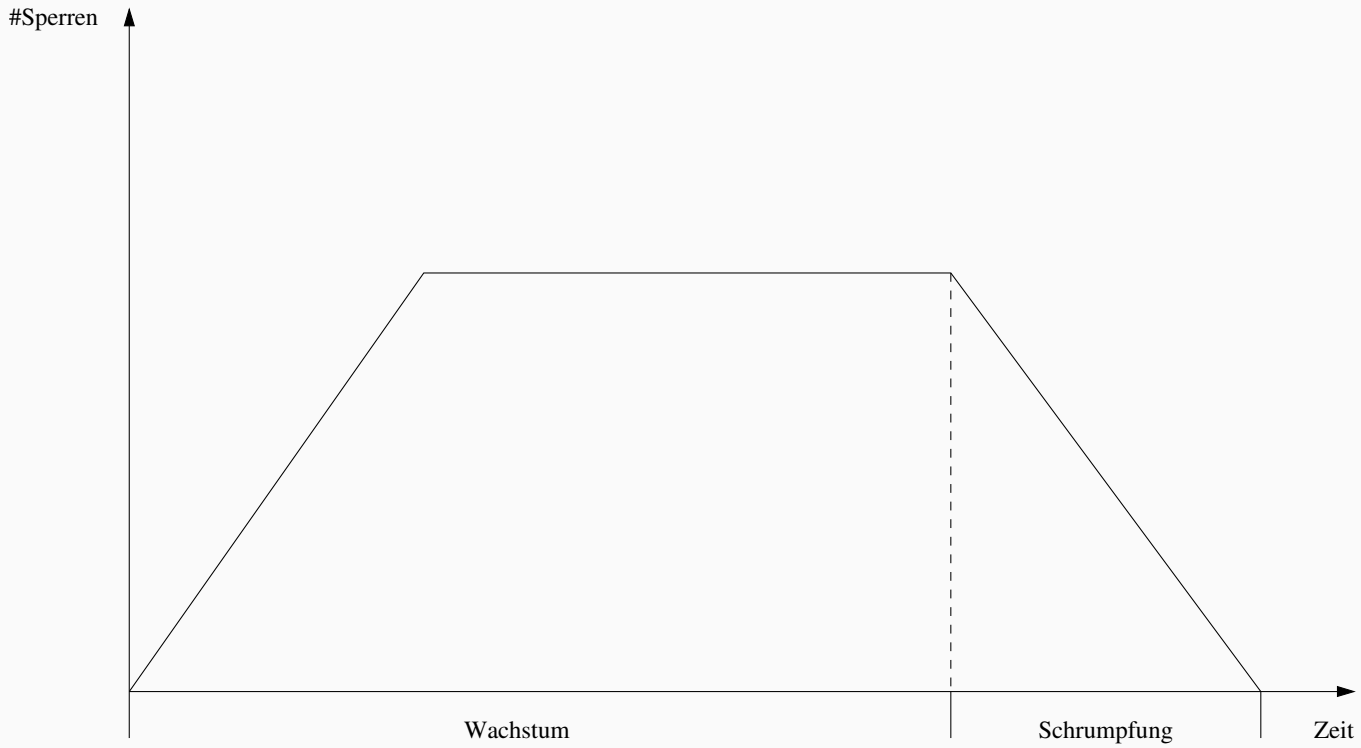

- Wachstumsphase: es werden Sperren angefordert, aber keine freigegeben
- Schrumpfungsphase: es werden Sperren freigegeben, aber keine angefordert

Verzahnung nach 2PL

Schritt	T_1	T_2	Bemerkung
1.	BOT		
2.	lockX[x]		
3.	r[x]		
4.	w[x]		
5.		BOT	
6.		lockS[x]	T_2 muss warten
7.	lockX[y]		
8.	r[y]		
9.	unlockX[x]		T_2 wecken
10.		r[x]	
11.		lockS[y]	T_2 muss warten
12.	w[y]		
13.	unlockX[y]		T_2 wecken
14.		r[y]	
15.	commit		
16.		unlockS[x]	
17.		unlockS[y]	
18.		commit	

Strenges 2PL

- 2PL schließt kaskadierendes Rücksetzen nicht aus und lässt sogar nicht-rücksetzbare Historien zu
- Erweiterung zum *strengen* 2PL:
  - alle Sperren werden bis zum Ende der Transaktion gehalten
  - damit ist kaskadierendes Rücksetzen ausgeschlossen (die erzeugten Schedules sind sogar strikt)

Strenges 2PL (2)

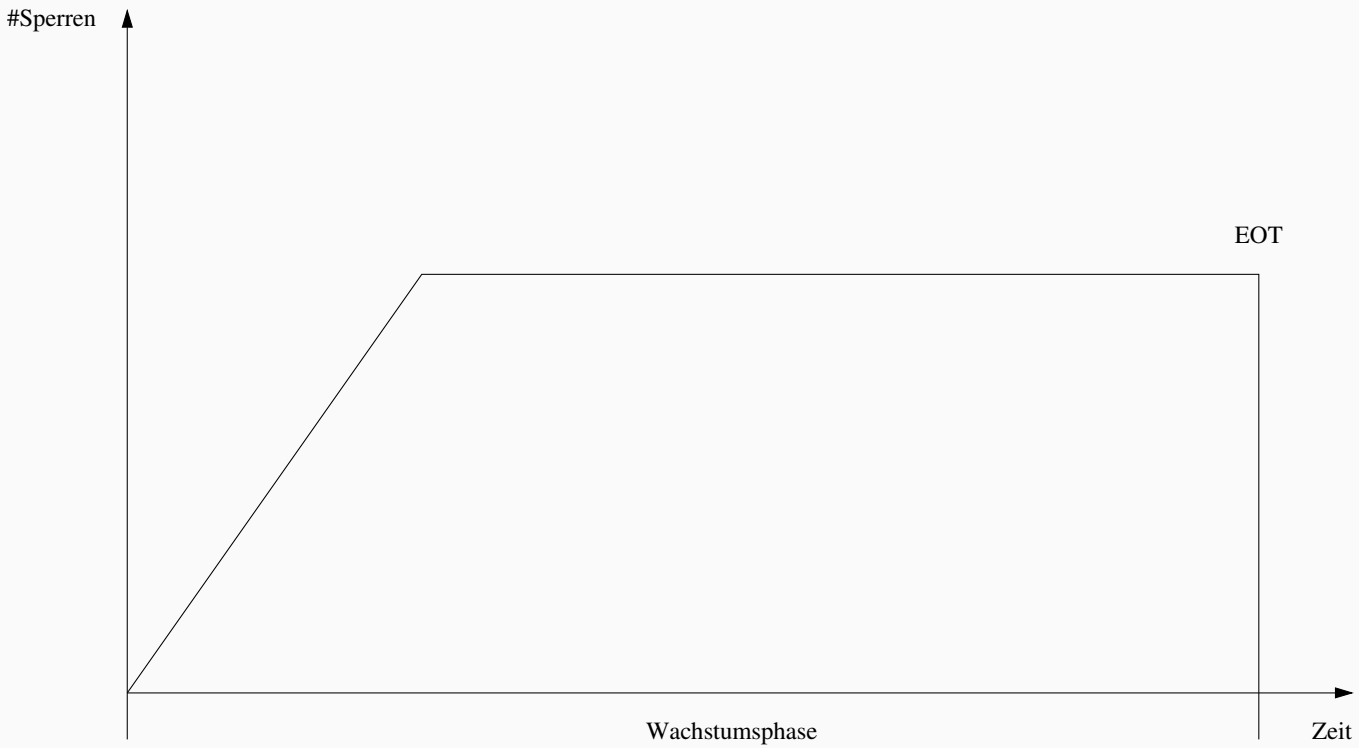

Verklemmungen (Deadlocks)

- Beispiel für ein Deadlock:

T_1	T_2
bot	
$\text{lockX}_1(a)$	
$w_1(a)$	
$\hookrightarrow$	bot
	$\text{lockS}_2(b)$
	$r_2(b)$
$\text{lockX}_1(b)$	$\hookleftarrow$
$\hookrightarrow$	$\text{lockS}_2(a)$

Deadlocks erkennen

- Keine TA soll ”ewig” auf eine Sperre warten
- Eine Strategie zum Erkennen von Deadlocks ist Time-Out
  - Richtige Zeitdauer zu finden ist problematisch
- Präzise Methode benutzt Wartegraphen
  - Knoten sind TAs, Kanten sind Wartet-auf-Beziehungen
  - Wenn Graph Zyklen aufweist, liegt ein Deadlock vor

Wartegraph

- Beispiel

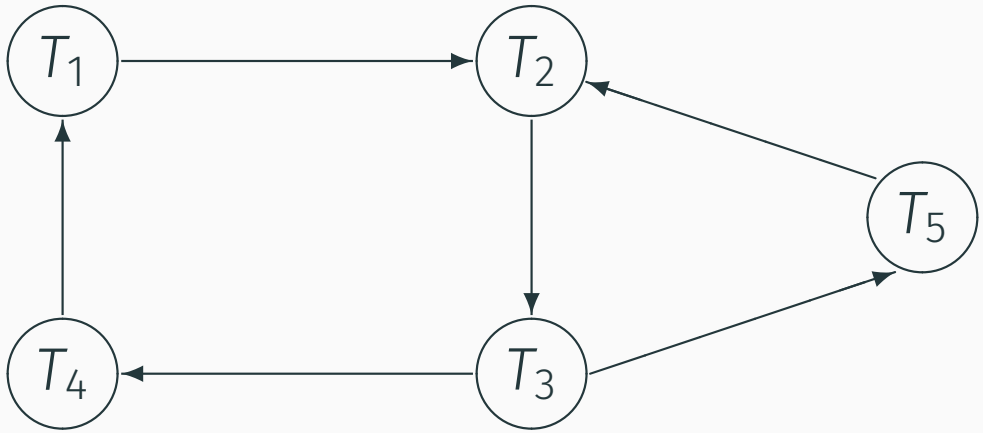

- Wartegraph hat Zyklen, d.h. Deadlock liegt vor
- Zyklen können hier durch Zurücksetzen von T_2 oder T_3 aufgelöst werden

Deadlock-Vermeidung

- Deadlocks können durch *Preclaiming* vermieden werden
- Preclaiming bedeutet, dass alle Sperren zu Beginn einer TA angefordert werden
- In der Praxis unrealistisch

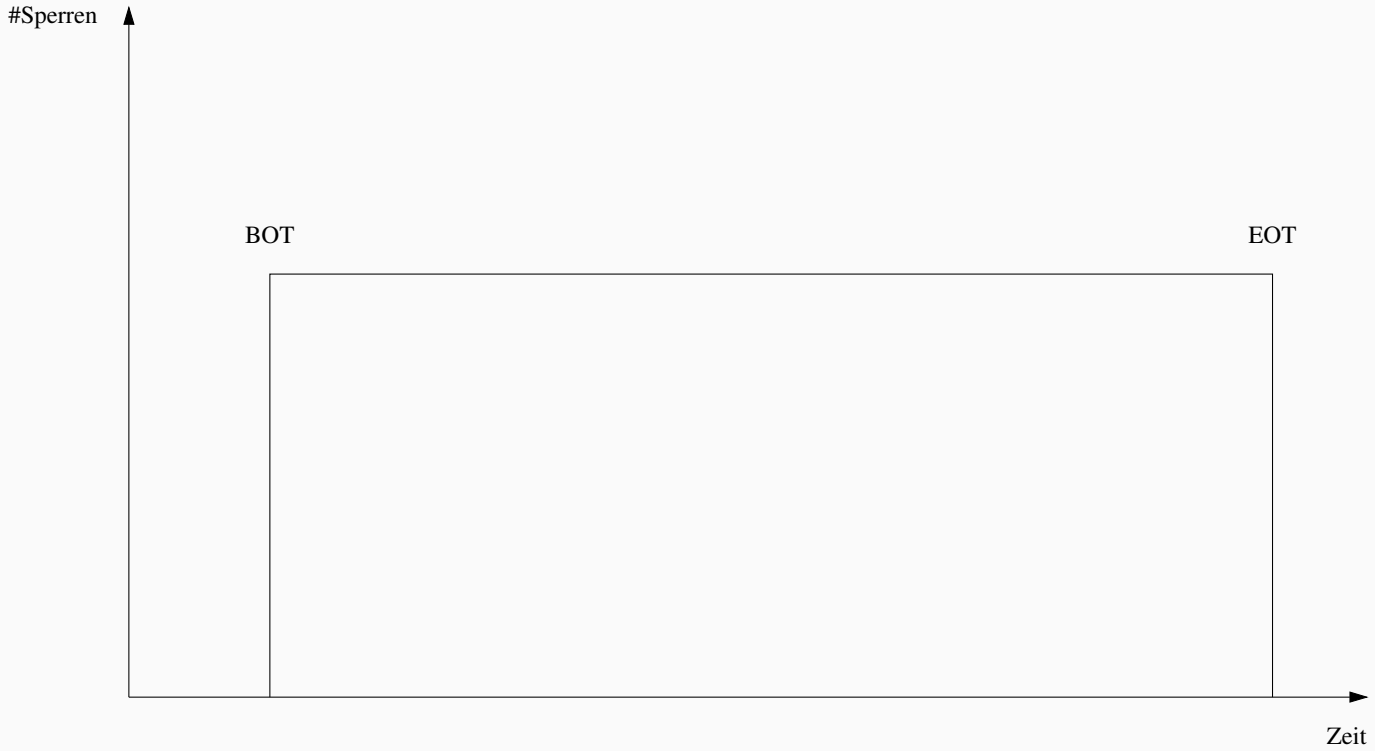

Deadlock-Vermeidung (2)

- Time-Out-Verfahren ist oft zu vorsichtig, z.T. werden TAs abgebrochen, wenn nur der Verdacht auf ein Deadlock besteht
- Eine andere Methode besteht darin zum Zeitpunkt wenn T_i eine Sperre anfordert, die von T_j gehalten wird, zu entscheiden
  - TAs bekommen Prioritäten zugewiesen
  - Wenn Priorität von T_i höher ist, darf T_i warten
  - Wenn Priorität von T_i kleiner ist, wird T_i abgebrochen

Deadlock-Vermeidung (3)

- Durch Prioriäten wird vermieden, dass durch ein Warten ein Deadlock entstehen kann
- Prioritätenvergabe muss umsichtig erfolgen
  - Wenn eine abgebrochene TA T_i beim Neutstart ständig niedrige Prioritäten erhält, können sich immer TAs mit höheren Prioritäten ”vordrängeln”
  - T_i kommt nie zum Zug, wir haben kein Deadlock, aber ein *Livelock*

Deadlock-Vermeidung (4)

- Vermeidung von Deadlocks und Livelocks: Verwendung von Zeitstempeln als Prioritäten
- Zeitstempel sind eindeutig und wachsen monoton mit der Zeit
- Eine TA bekommt beim ersten Aufruf einen Zeitstempel *ts* zugewiesen, beim Neustart behält sie den alten Zeitstempel
- Je älter der Zeitstempel, desto höher die Priorität
- Irgendwann hat eine immer wieder abgebrochene TA den ältesten Zeitstempel, Livelocks werden verhindert

Deadlock-Vermeidung (5)

- Angenommen T_j hält Sperre, T_i fordert sie an
- Im Zeitstempelverfahren kann ein Scheduler nun zwei verschiedene Strategien fahren
  - Wait-Die:
    Falls $ts(T_i) < ts(T_j)$,
    dann wartet T_i, sonst bricht T_i ab
  - Wound-Wait:
    Falls $ts(T_i) < ts(T_j)$,
    dann bricht T_j ab, sonst wartet T_i

Phantom-Problem

- Mit strengem 2PL haben wir alle am Anfang des Kapitels angesprochenen Probleme gelöst, außer des Phantom-Problems
- Phantom-Problem lässt sich mit Sperren auf Datenobjekten nicht lösen, da keine Sperren auf nichtexistenten Datenobjekten angefordert werden können
- Außerdem kann die Anzahl der Sperren bei großen Transaktionen (z.B. kompletter Scan einer Tabelle) sehr groß sein
- Lösung der Probleme durch *hierarchische Sperrgranulate* (multi-granularity locking: MGL)

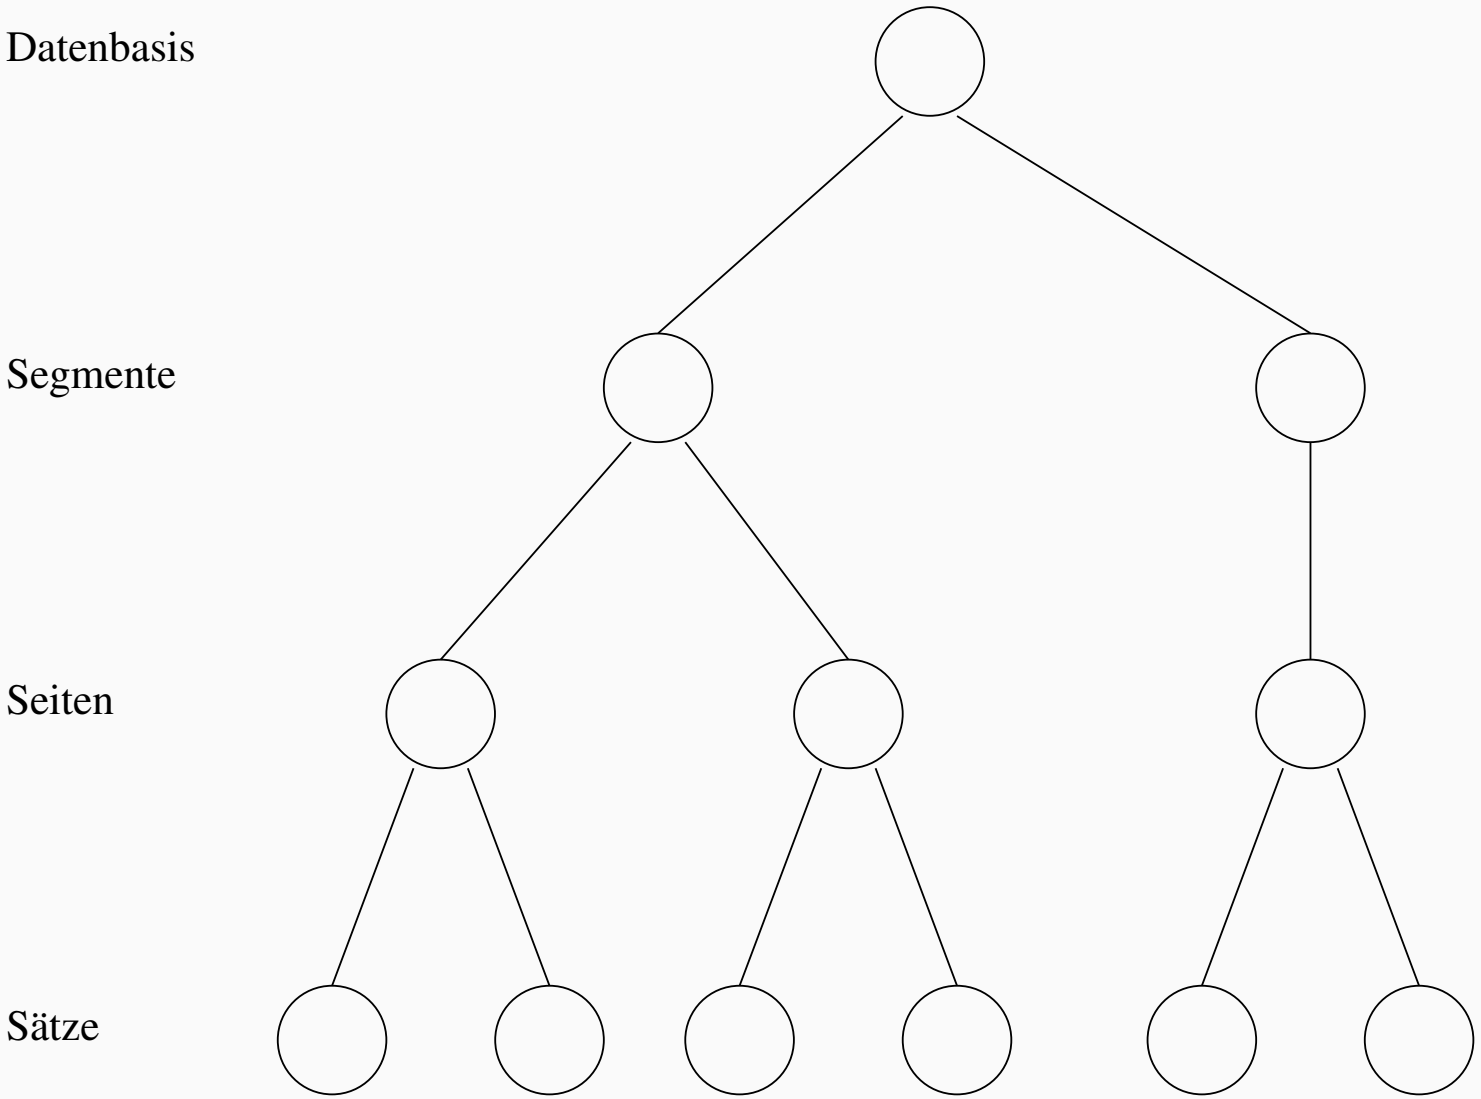
Datenbasis
Segmente
Seiten
Sätze

Erweiterte Sperrmodi für MGL

- *S* (shared): für Leser
- *X* (exclusive): für Schreiber
- *IS* (intention share): für beabsichtigtes Lesen weiter unten in der Hierarchie
- *IX* (intention exclusive): für beabsichtigtes Schreiben weiter unten in der Hierarchie

Kompatibilitätsmatrix

	gehaltene Sperre				
angef. Sp.	keine	*S*	*X*	*IS*	IX
S	√	√	–	√	–
X	√	–	–	–	–
IS	√	√	–	√	√
IX	√	–	–	√	√

Sperrprotokoll

- Sperren werden in der Hierarchie von oben nach unten angefordert
  - Für eine *S* oder *IS* Sperre müssen alle Vorgänger in der Hierarchie im *IS* oder *IX* Modus gesperrt sein
  - Für eine *X* oder *IX* Sperre müssen alle Vorgänger in der Hierarchie im *IX* Modus gehalten werden
- Sperren werden von unten nach oben wieder freigegeben (Sperre wird nur freigegeben, wenn auf keinem Nachfolger des Knotens noch eine Sperre gehalten wird)

Beispiel

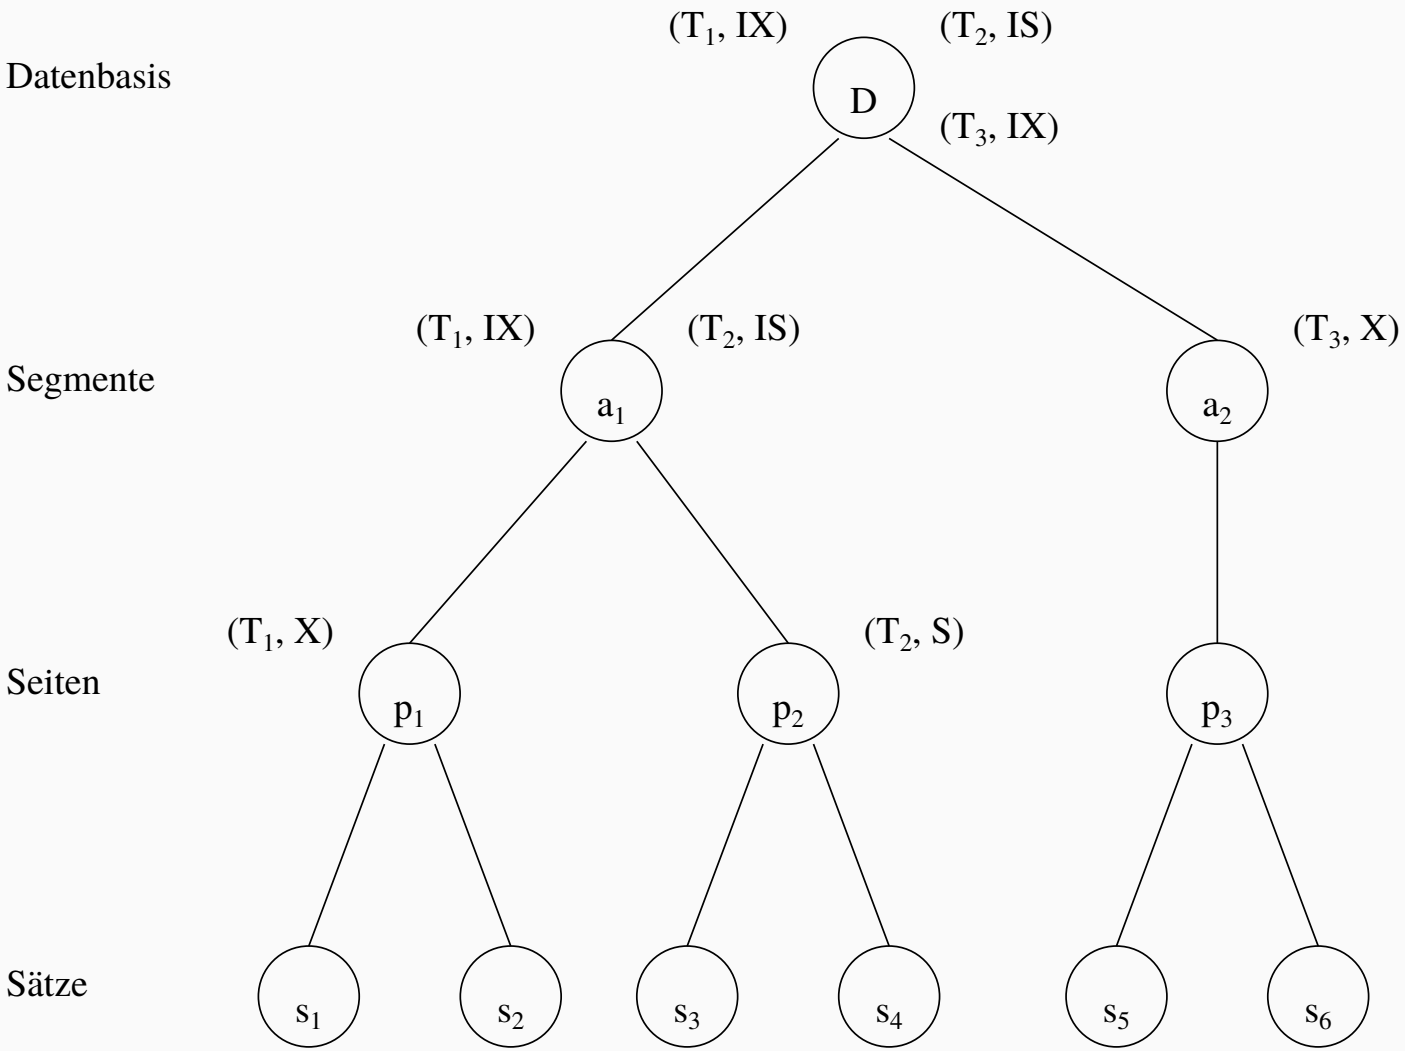
Datenbasis
Segmente
Seiten
Sätze
(T1, IX)
(T2, IS)
D
(T3, IX)
(T1, IX)
(T2, IS)
(T3, X)
a1
a2
(T1, X)
(T2, S)
p1
p2
p3
s1
s2
s3
s4
s5
s6

Beispiel (2)

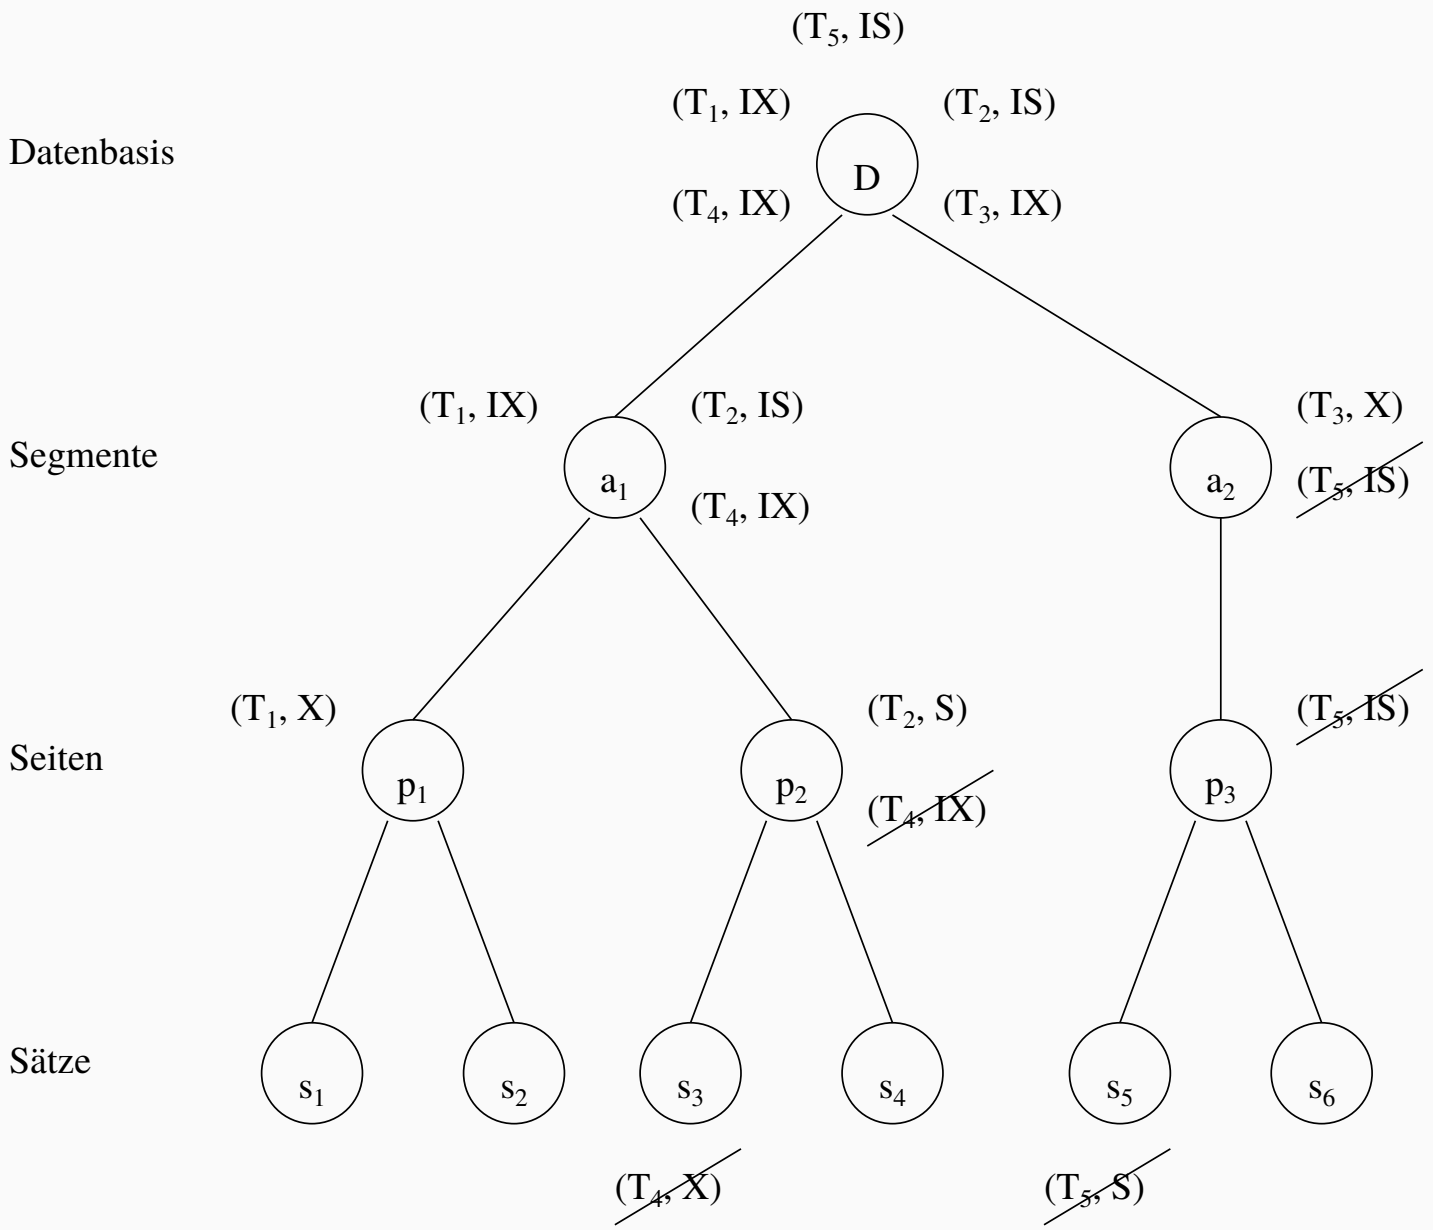
Datenbasis
Segmente
Seiten
Sätze
(T5, IS)
(T1, IX)
(T2, IS)
(T4, IX)
(T3, IX)
D
(T1, IX)
(T2, IS)
(T4, IX)
a1
(T3, X)
(T5, IS)
a2
(T1, X)
p1
(T2, S)
(T4, IX)
p2
(T5, IS)
p3
s1
s2
s3
s4
s5
s6
(T4, X)
(T5, S)

Beispiel (3)

- TAs T_4 und T_5 sind blockiert
- Hier noch kein Deadlock, aber im einfachen MGL-Protokoll sind auch Deadlocks möglich

Zeitstempelbasierte Verfahren

- Neben den sperrbasierten Protokollen gibt es noch eine weitere große Klasse an Protokollen, die zeitstempelbasierte Synchronisation
- Transaktionsmanager weist jeder TA einen eindeutigen Zeitstempel zu
- Jede Operation der TA bekommt diesen Zeitstempel

Zeitstempel

- Ein Scheduler benutzt die Zeitstempel um in Konflikt stehende Operationen zu ordnen:
  - Angenommen $p_i[x]$ und $q_j[x]$ stehen in Konflikt miteinander
  - $p_i[x]$ wird vor $q_j[x]$ ausgeführt, gdw. der Zeitstempel von T_i älter als der Zeitstempel von T_j ist

Zeitstempel (2)

- Scheduler speichert zu jedem Datenobjekt x den Zeitstempel der letzten auf x ausgeführten Operation
- Das wird für jeden Operationstypen q gemacht: max-q-scheduled(x)
- Wenn Scheduler eine Operation p bekommt, wird ihr Zeitstempel mit allen max-q-scheduled(x) verglichen, mit denen p in Konflikt steht
- Wenn der Zeitstempel von p älter als ein max-q-scheduled(x) ist, wird p zurückgewiesen (und TA abgebrochen)
- Ansonsten wird p ausgeführt und max-p-scheduled(x) aktualisiert

Weitere Eigenschaften

- Einfaches Zeitstempelverfahren erzeugt u.U. nicht rücksetzbare Schedules
- Rücksetzbarkeit kann dadurch garantiert werden, dass TAs in Zeitstempelreihenfolge committen
- Solange noch TAs laufen, von denen eine TA T_i gelesen hat, wird ein commit von T_i verzögert

Probleme von Zeitstempeln

- Zeitstempelbasierte Synchronisation wird in der Praxis kaum eingesetzt
- Phantom-Problem wird nicht gelöst
- Jede Operation wird praktisch zur Schreiboperation, da immer die max-q-scheduled(x)-Felder aktualisiert werden müssen

Optimistische Synchronisation

- Transaktion wird “einfach mal ausgeführt” und im Nachhinein wird entschieden, ob es einen Konflikt gab
- Annahme: Konflikte sind selten

Optimistische Synchronisation: Phasen

1. Lesephase: Transaktion wird ausgeführt, Lesezugriffe werden protokolliert (“read set”), Änderungen werden in lokalen Variablen zwischengespeichert (“write set”)
2. Validierungsphase: Es wird geprüft, ob es einen Konflikt gab
3. Schreibphase: Änderungen werden in die Datenbank eingebracht

Optimistische Synchronisation: Validierungsphase

- Zu Beginn der Validierungsphase einer wird der Transaktion T_i ein Zeitstempel $TS(T_j)$ zugeteilt
- Für alle Transaktionen T_a, die älter sind ($TS(T_A) < TS(T_j)$), und noch nicht vollständig abgeschlossen sind (inklusive Schreibphase) muss gelten:
  $WriteSet(T_a) \cap ReadSet(T_j) = \emptyset$
- Validierungs- und Schreibphase müssen “atomar” durchgeführt werden

Optimistische Synchronisation: Eigenschaften

- Kann unnötige Verzögerung anderer Transaktionen vermeiden
- Wenn Konflikte recht häufig sind, kann es zu häufigen Abbrüchen kommen

Multi-Version Concurrency Control (MVCC)

- Alte Versionen von Tupeln können genutzt werden um Mehrbenutzersynchronisation zu verbessern
- Entweder werden alte Versionen aus der Log-Datei wiederhergestellt oder Änderung erzeugen immer neue Tupel-Versionen (kein update in place, jedes Tupel hat ein Versionsfeld)
- Weit verbreitete Technik (PostgreSQL, Oracle)

Snapshot Isolation

- Einsatz mit MVCC
- Transaktionen laufen logisch auf einem Snapshot der Daten, indem sie nur Tupel-Versionen zum Startzeitpunkt ansehen und neuere ignorieren
- Vorteil: Leser müssen nicht sperren, Schreibsperren sind ausreichend
- $\mathit{WriteSet}(T_a) \cap \mathit{WriteSet}(T_j) = \emptyset$
- Write Skew Anomalie möglich
- Alte Versionen müssen irgendwann aufgeräumt werden (“Garbage Collection”)

Übersicht Synchronisationsverfahren

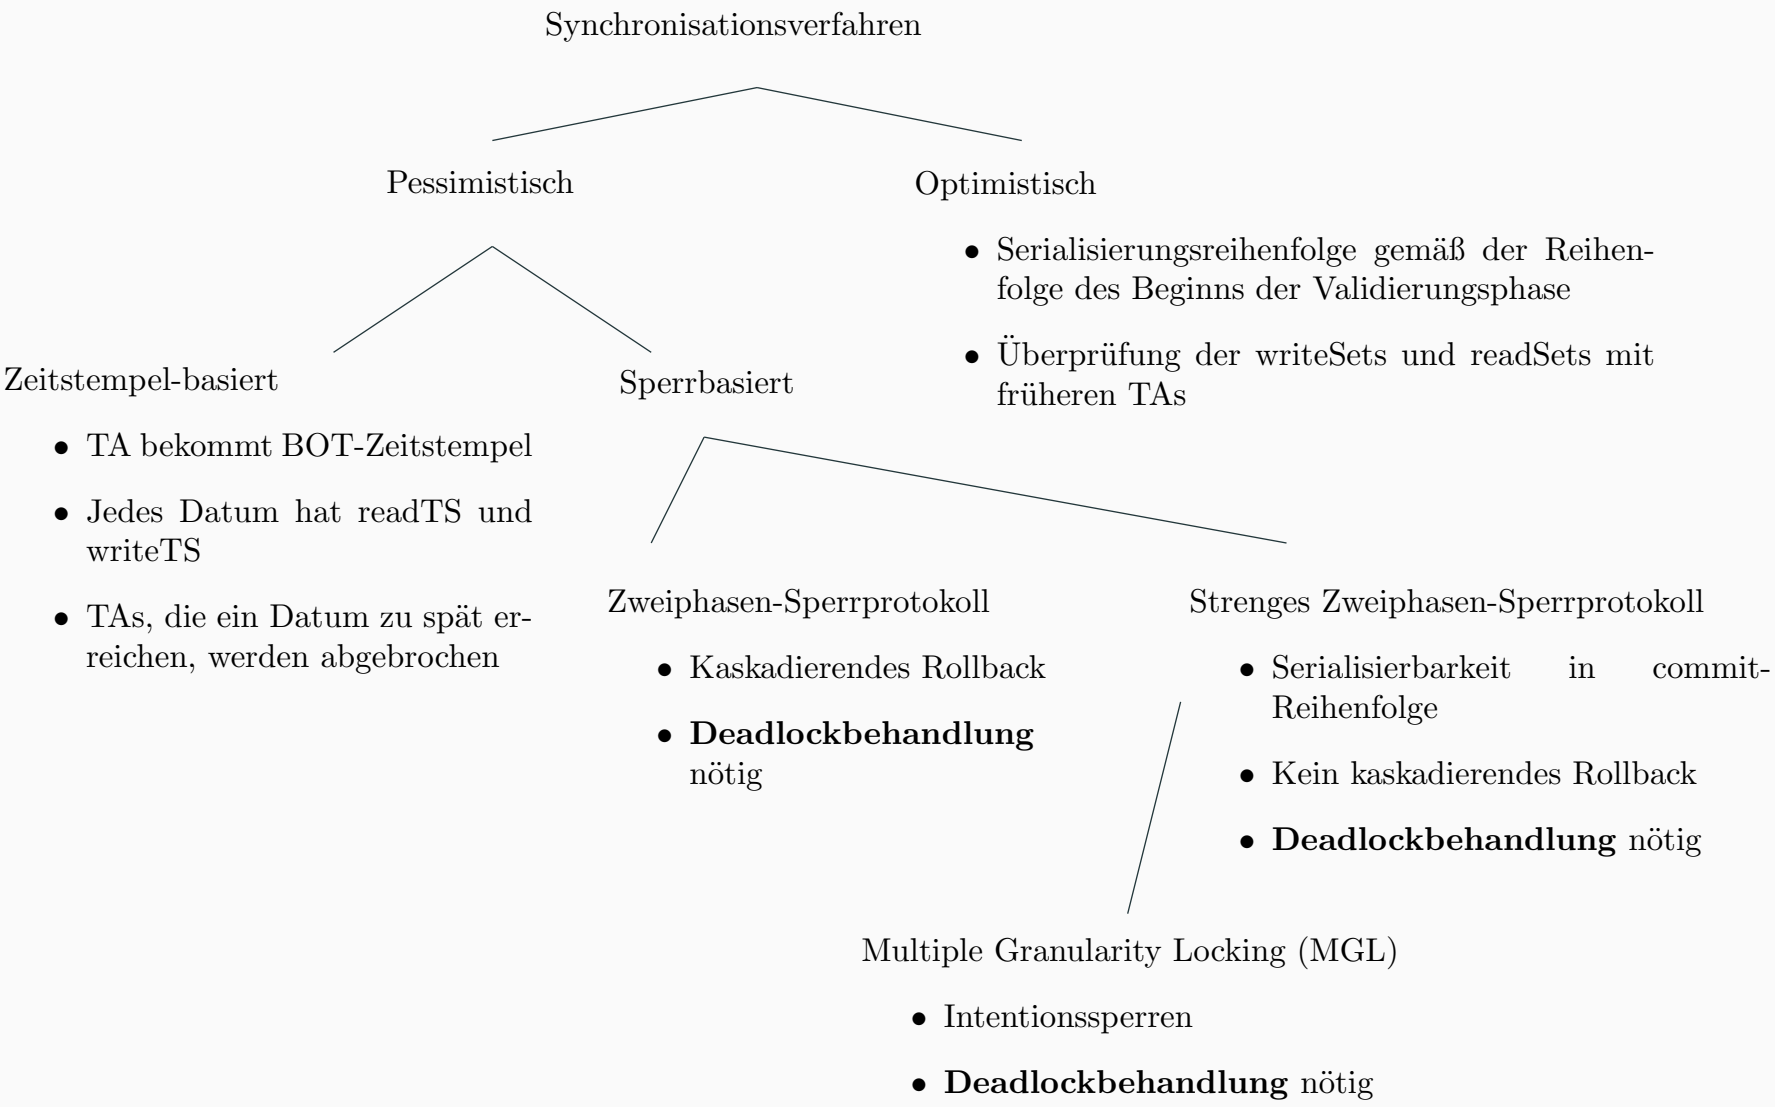

Übersicht Deadlockbehandlung

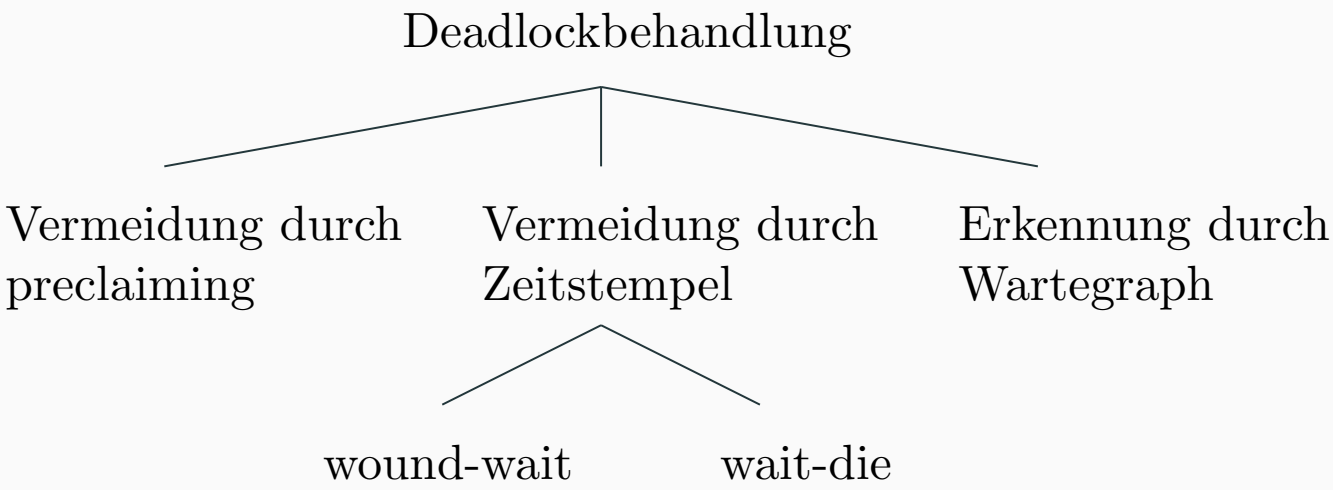

Zusammenfassung

- Mehrbenutzersynchronisation gehört mit zu den wichtigsten Funktionen eines DBMS
- Normalerweise bleibt dies den Benutzern verborgen, aber über die Einstellung der Isolation-Levels kann in die Qualität dieser Synchronisation eingegriffen werden
- Bekannte Verfahren:
  - Sperrbasierte Synchronisation
  - Zeitstempelbasierte Synchronisation
  - Optimistische Synchronisation
  - MVCC/Snapshot Isolation