Fehlerbehandlung und Recovery

VL Datenbanksysteme

Ingo Feinerer

Arbeitsbereich Datenbanken und Artificial Intelligence
Institut für Informationssysteme
Technische Universität Wien

Transaktionsverwaltung

- Systemkonfiguration
- Protokollierung
- Recovery
- Sicherungspunkte (Checkpointing)

Systemkonfiguration

- Ersetzungsstrategien
- Ausschreiben von Änderungen
- Einbringstrategien

Fehlerklassifikation und Fehlerbehandlung

Lokaler Fehler in einer noch nicht festgeschriebenen (committed) Transaktion:

- Wirkung muss (rasch!) zurückgesetzt werden
- R1-Recovery (lokales Undo)

Fehler mit Hauptspeicherverlust:

- R2-Recovery (globales Redo): Abgeschlossene TAs müssen erhalten bleiben
- R3-Recovery (globales Undo): Noch nicht abgeschlossene TAs müssen zurückgesetzt werden.

Fehler mit Hintergrundspeicherverlust:

- R4-Recovery

Zweistufige Speicherhierarchie

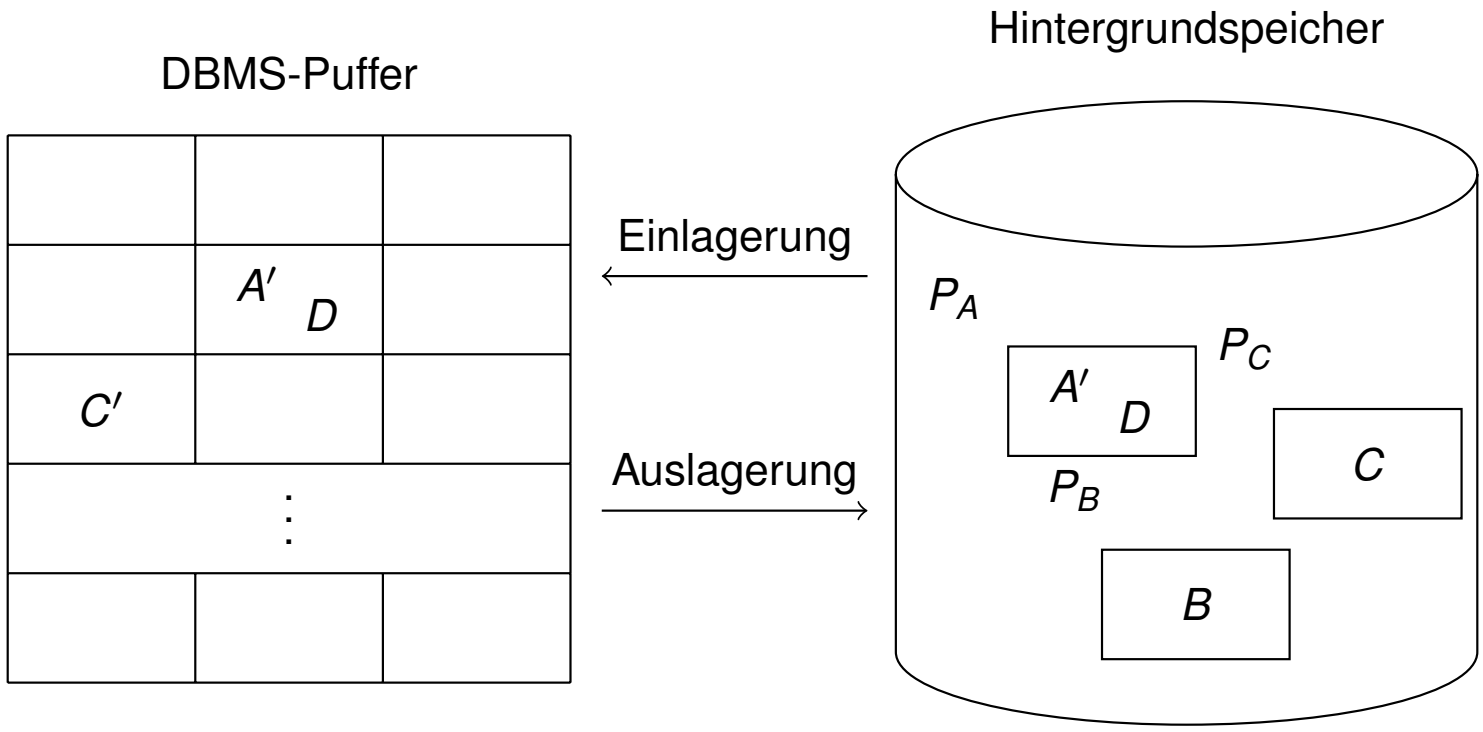

Ersetzung von Pufferseiten

Fixieren von Seiten im Datenbankpuffer:

- Während des Zugriffs auf eine Seite darf diese auf keinen Fall aus dem Puffer verdrängt werden.
- Danach ist ein Verdrängen grundsätzlich möglich (unabhängig davon, ob die Transaktion noch weitergeht).

Strategien zur Ersetzung von Pufferseiten:

steal
: Jede nicht fixierte Seite ist prinzipiell ein Kandidat für die Ersetzung, falls neue Seiten eingelagert werden müssen.

¬steal
: Seiten, die von einer noch aktiven Transaktion modifiziert wurden, dürfen nicht ersetzt werden.

Ausschreiben von Änderungen

Strategien zum Ausschreiben von Änderungen abgeschlossener Transaktionen:

- **force** Änderungen werden zum Transaktionsende auf den Hintergrundspeicher geschrieben.
- **¬force** Auch nach Transaktionsende sind geänderte Seiten eventuell nicht auf den Hintergrundspeicher geschrieben worden.

Auswirkungen auf Recovery

	force	¬force
¬steal	▶ kein Redo ▶ kein Undo	▶ Redo ▶ kein Undo
steal	▶ kein Redo ▶ Undo	▶ Redo ▶ Undo

Einige Gründe gegen ¬steal/force

- Erzwungene Propagierung aller Änderungen zum Transaktionsende ist teuer.
- Manche Seiten („hot spots“) würden ausgeschrieben werden, obwohl sie nicht aus dem Datenbankpuffer verdrängt werden.
- Ausschreiben aller geänderten Seiten zum Transaktionsende müsste atomar geschehen („alles oder nichts“).
- Kombination ¬steal/force ist nur möglich, wenn Transaktionen immer ganze Seiten sperren.

Einbringstrategien

„Direkte“ Einbringstrategie:

- Update-in-Place
  - Jede Seite hat genau eine „Heimat“ auf der Platte
  - Wenn eine (modifizierte) Seite aus dem Datenbankpuffer verdrängt wird, wird sie genau an dieser Stelle auf die Platte geschrieben.
  - Der alte Zustand der Seite wird dadurch überschrieben.

Einbringstrategien

„Indirekte“ Einbringstrategien:

- Twin-Block-Verfahren

Beispiel

Twin-Block-Anordnung der Seiten P_A, P_B, und P_C.

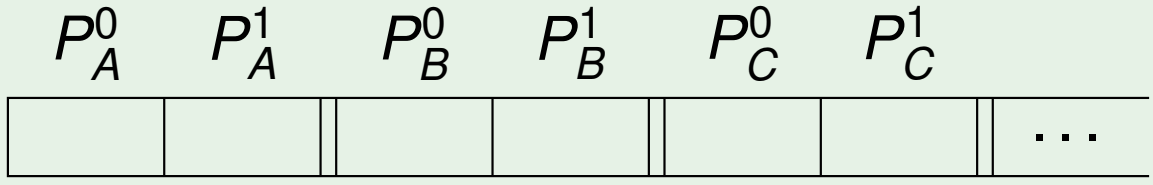

- Schattenspeicherkonzept
  - nur geänderte Seiten werden dupliziert
  - weniger Redundanz als beim Twin-Block-Verfahren
  - in der Praxis zu komplex

Übliche Systemkonfiguration

- steal: Eine Seite, die von einer nicht abgeschlossenen TA modifiziert wurde, kann auf Platte ausgeschrieben werden.
- ¬force: Geänderte Seiten sind bei Beendigung der Transaktion möglicherweise noch nicht auf die Platte geschrieben.
- update-in-place: Es gibt von jeder Seite nur eine Kopie auf der Platte.
- kleine Sperrgranulate (Kapitel Mehrbenutzersynchronisation) auf Satzebene, d.h.: eine Seite kann Datenbankänderungen sowohl von abgeschlossenen als auch von nicht abgeschlossenen Transaktionen enthalten.

Protokollierung

- Aufbau der Log-Datei
- Schreiben der Log-Information (WAL-Prinzip)

Log-Datei

Motivation:

- (wegen steal): Die Seiten auf der Platte können Änderungen von noch nicht abgeschlossenen Transaktionen enthalten, d.h. Undo muss möglich sein.
- (wegen ¬force): Die Seiten auf der Platte enthalten eventuell nicht alle Änderungen von bereits abgeschlossenen Transaktionen, d.h.: Redo muss möglich sein.

Lösung: Zusätzliche Information in Log-Datei (= Protokoll-Datei).

- Log-Datei enthält alle für Redo bzw. Undo erforderlichen Informationen über Änderungsoperationen.
- Außerdem enthält Log-Datei Informationen über Beginn und Ende von Transaktionen.

Struktur der Log-Einträge

Definition

Struktur der Log-Einträge:

[*LSN*, *TransaktionsID*, *PageID*, *Redo*, *Undo*, *PrevLSN*]

LSN (Log Sequence Number):

- Eindeutige Kennung des Log-Eintrags.
- LSNs müssen monoton aufsteigend vergeben werden.
- Die chronologische Reihenfolge der Protokolleinträge kann dadurch ermittelt werden.

TransaktionsID:

- Kennung der Transaktion, die Änderung durchgeführt hat.

PageID:

- Kennung der Seite, die geändert wurde.
- Wenn eine Änderung mehr als eine Seite betrifft, müssen entsprechend viele Log-Einträge generiert werden.

Struktur der Log-Einträge

Definition

Struktur der Log-Einträge:

[*LSN*, *TransaktionsID*, *PageID*, *Redo*, *Undo*, *PrevLSN*]

Redo:

- Gibt an, wie die Änderung nachvollzogen werden kann.

Undo:

- Gibt an, wie die Änderung rückgängig gemacht werden kann.

PrevLSN:

- Zeiger auf den vorhergehenden Log-Eintrag der jeweiligen Transaktion.
- Diesen Eintrag benötigt man aus Effizienzgründen (insbesondere für das lokale Undo).

Log-File

Beispiel

Schritt	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]

Logische vs. physische Protokollierung

Physische Protokollierung: Redo- und Undo-Eintrag enthalten Inhalte/Zustände.

- **before-image** enthält den Zustand vor Ausführung der Operation.
- **after-image** enthält den Zustand nach Ausführung der Operation.

Logische Protokollierung: Redo- und Undo-Eintrag enthalten Anweisungen für das Erreichen der Inhalte/Zustände.

- Das **before-image** wird durch Ausführung des Undo-Codes aus dem *after-image* generiert.
- Das **after-image** wird durch Ausführung des Redo-Codes aus dem *before-image* berechnet.

Logische vs. physische Protokollierung

Speicherung der Seiten-LSN:

- Beim Wiederanlauf muss das DBMS erkennen können, ob auf einer bestimmten Seite das before- oder das after-image auf dem Hintergrundspeicher steht.
- Dies ist insbesondere bei logischer Protokollierung notwendig.
- Dazu wird auf jeder Seite die LSN des jüngsten diese Seite betreffenden Log-Eintrags gespeichert.

Schreiben der Log-Information

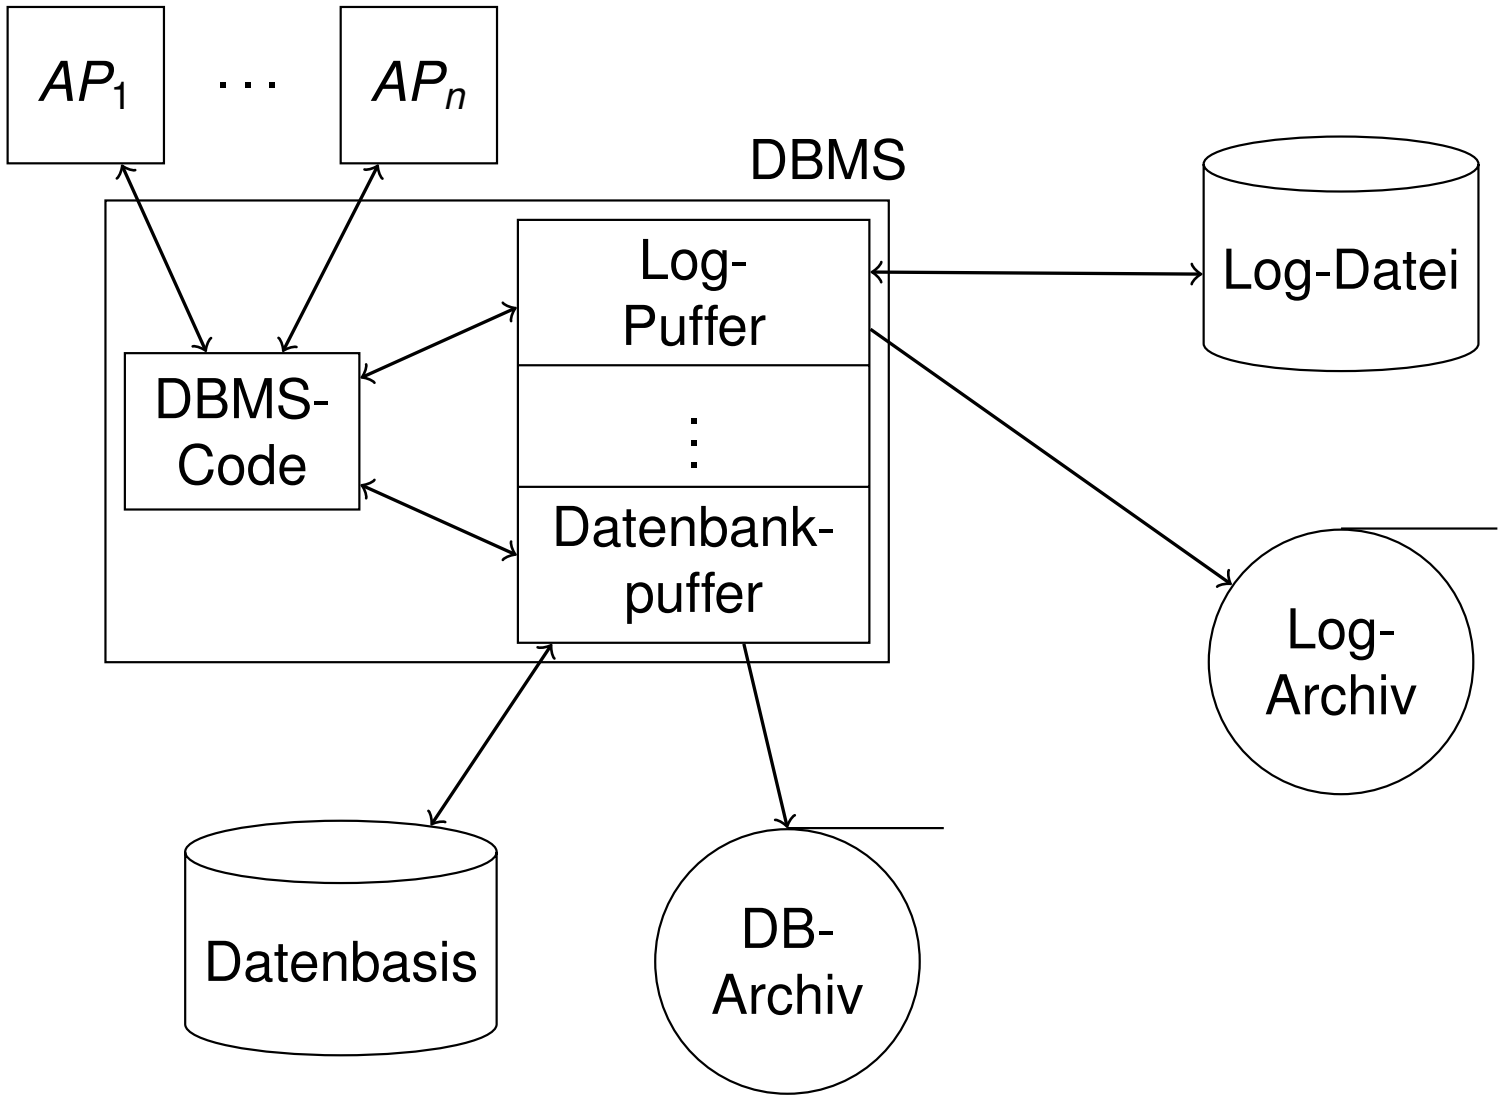

Schreiben der Log-Information

Die Log-Information wird zwei Mal geschrieben:

1. Log-Datei für schnellen Zugriff:
   R1, R2 und R3-Recovery
2. Log-Archiv:
   R4-Recovery

Anordnung des Log-Ringpuffers

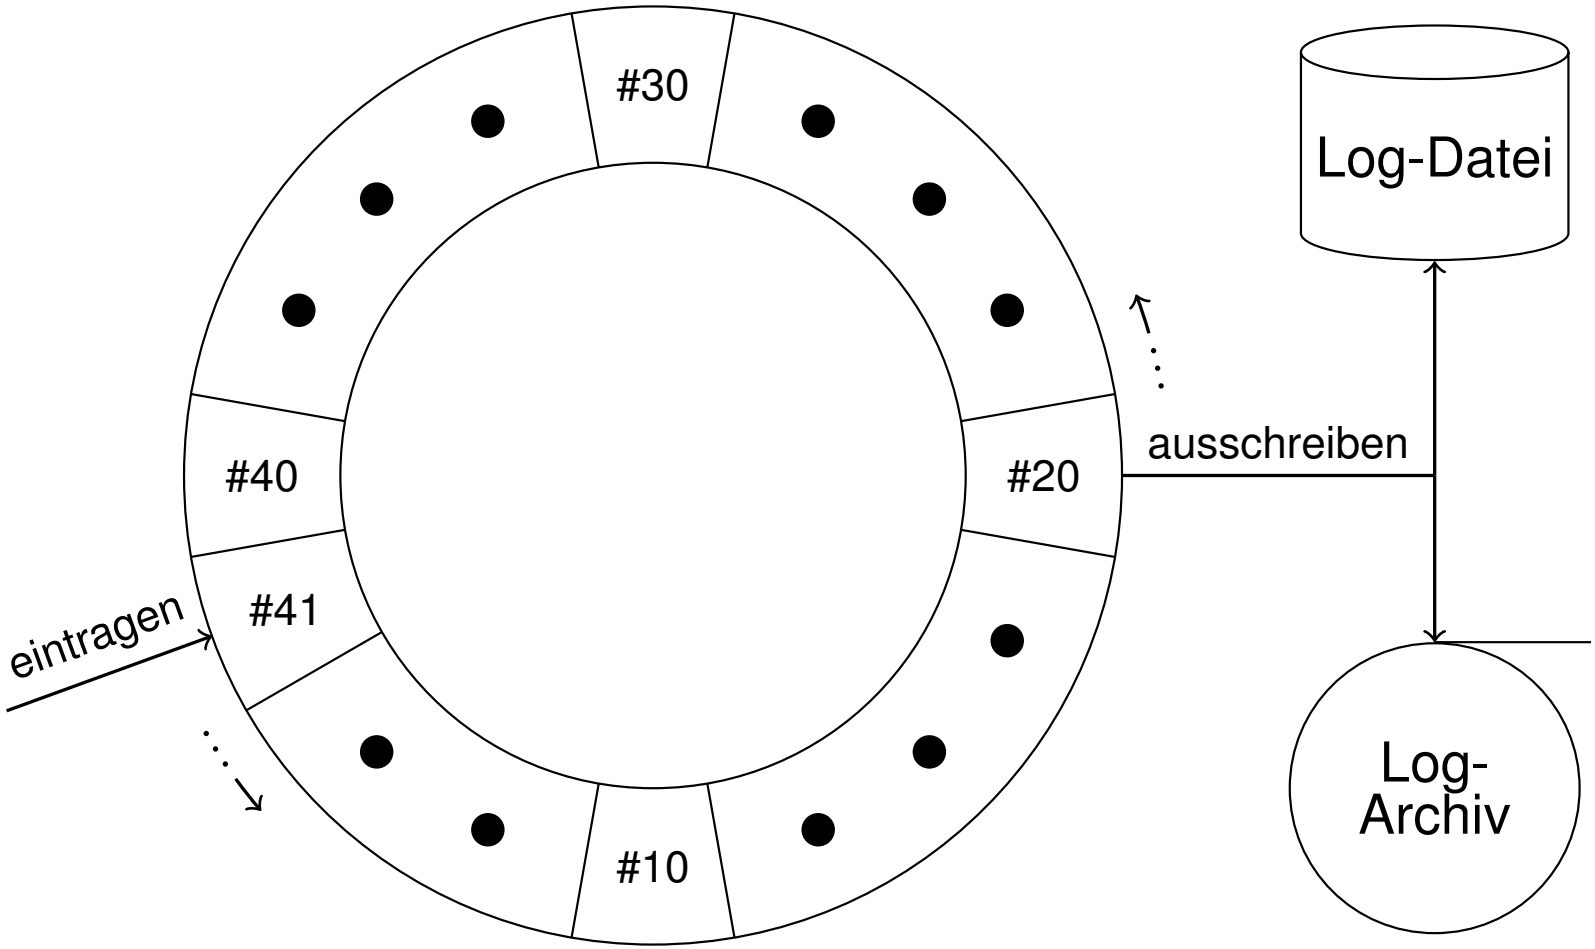

WAL-Prinzip

- Das **kontinuierliche Ausschreiben** aus dem Log-Ringpuffer vermeidet „stoßweises“ Ausschreiben bei Beendigung einer Transaktion.
- Es muss dabei aber das WAL-Prinzip (= write ahead log) eingehalten werden:
  - **für Redo**: Bevor eine Transaktion festgeschrieben (committed) wird, müssen alle „zu ihr gehörenden“ Log-Einträge ausgeschrieben werden.
  - **für Undo**: Bevor eine modifizierte Seite ausgelagert werden darf, müssen alle Log-Einträge, die zu dieser Seite gehören, ausgeschrieben werden.
  - Dabei muss die chronologische Reihenfolge der Log-Einträge laut Log-Ringpuffer erhalten bleiben.

Recovery

- Wiederanlauf nach Systemabsturz: R2/R3-Recovery
- R1-Recovery
- R4-Recovery

Wiederanlauf nach einem Fehler

Transaktionsbeginn und -ende relativ zu einem Systemabsturz

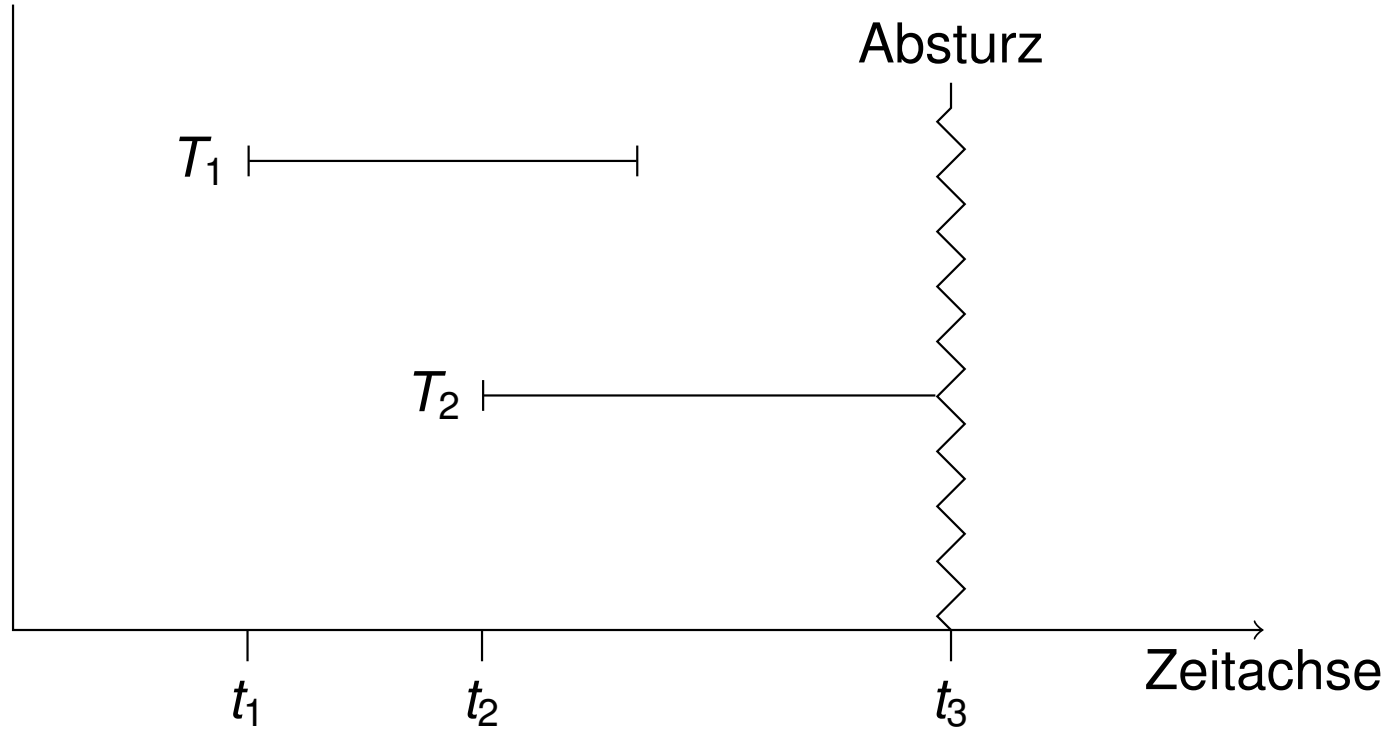

- Transaktion der Art T_1 müssen hinsichtlich ihrer Wirkung vollständig nachvollzogen werden. Transaktionen dieser Art nennt man **Winner**.
- Transaktion, die wie T_2 zum Zeitpunkt des Absturzes noch aktiv waren, müssen rückgängig gemacht werden. Diese Transaktionen nennt man **Loser**.

Drei Phasen des Wiederanlaufs

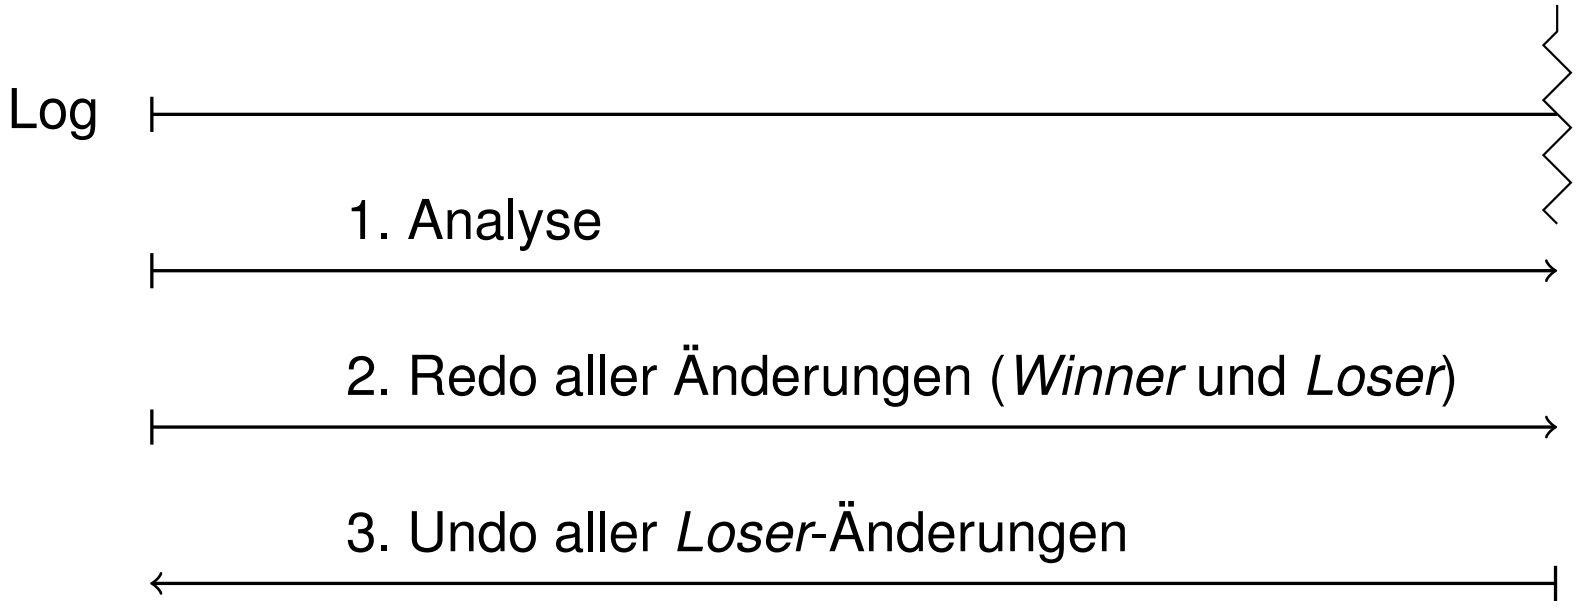

1. Analyse:
   - Die Log-Datei wird von Anfang bis zum Ende analysiert.
   - Ermittlung der **Winner**-Menge, das sind Transaktionen, für die ein BOT und ein commit in der Log-Datei gefunden wurden.
   - Ermittlung der **Loser**-Menge, das sind Transaktionen für die ein BOT aber kein commit in der Log-Datei gefunden wurde.

Drei Phasen des Wiederanlaufs

2. Redo-Phase:
   - Alle protokollierten Änderungen (sowohl von Winner- als auch von Loser-Transaktionen) werden in der Reihenfolge ihrer Ausführung in die Datenbasis eingebracht (d.h.: geordnet nach LSN und nicht nach Transaktionen).
   - Durch Vergleich der LSN des Log-Eintrags mit der LSN der betroffenen Seite wird jeweils ermittelt, ob bereits das after-image auf der Platte steht.
   - Falls log-LSN $>$ Seiten-LSN, muss die Redo-Operation durchgeführt werden und die Seiten-LSN mit log-LSN überschrieben werden.

Drei Phasen des Wiederanlaufs

3. Undo-Phase:
   - Die Änderungsoperationen der Loser-Transaktionen werden in umgekehrter Reihenfolge ihrer ursprünglichen Ausführung rückgängig gemacht (d.h. geordnet nach absteigender LSN und nicht nach Transaktionen).
   - Für jede Undo-Operation kommt ein neuer Eintrag (**CLR**, compensation log record) in die Log-Datei (siehe unten).

Fehlertoleranz (Idempotenz) des Wiederanlaufs

- Problem: auch während der Recovery-Phase kann das System abstürzen.
- Anforderung:

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

- Realisierung der Idempotenz:
  - Redo-Phase: mittels LSN (in jedem Log-Eintrag bzw. auf jeder Seite)
  - Undo-Phase: mittels CLRs

Kompensationseinträge im Log

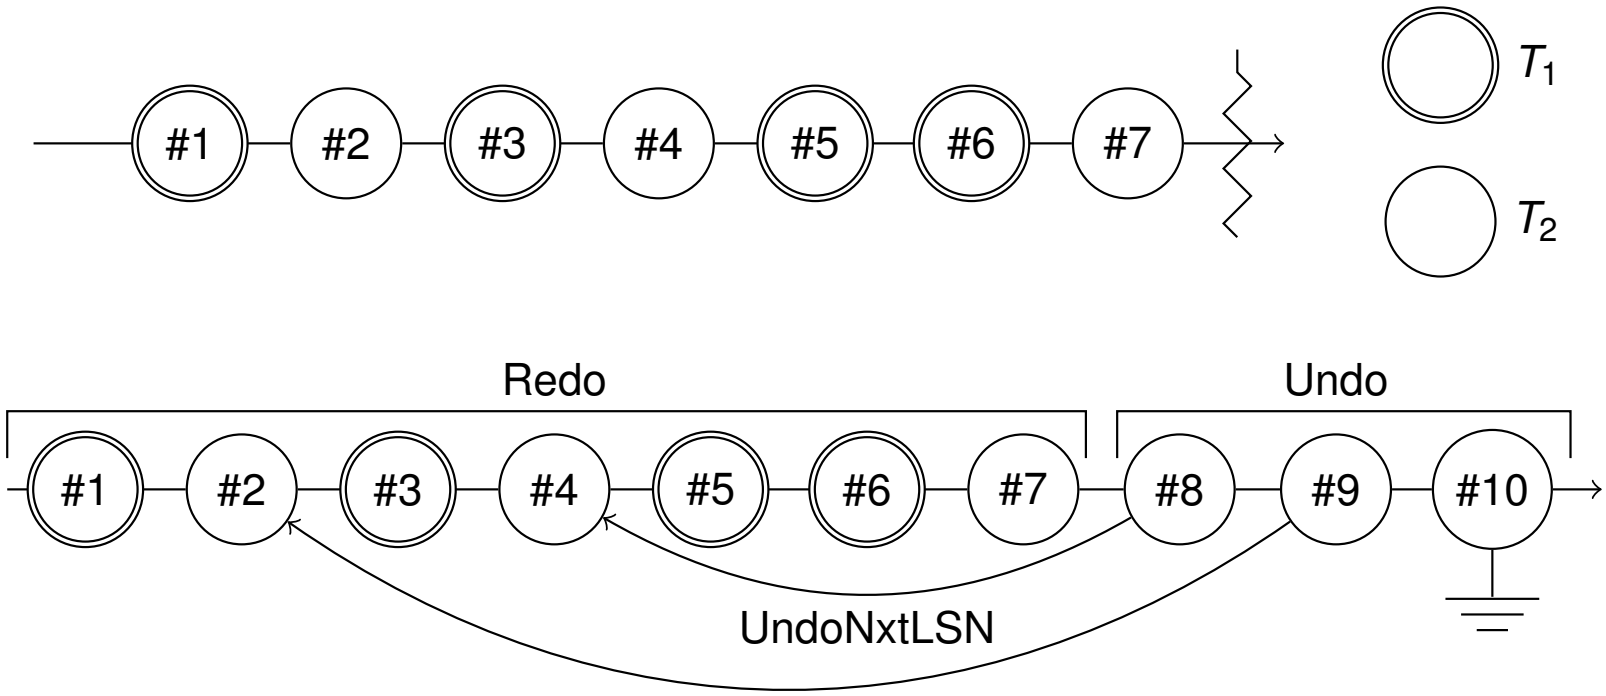

Kompensationseinträge (CLR, compensation log record) für rückgängig gemachte Änderungen und für BOT:

- #8 ist CLR für #7
- #9 ist CLR für #4
- #10 ist CLR für #2 (= BOT)

Log-Einträge nach abgeschlossenem Wiederanlauf

Beispiel

$$[\#1, T_1, \textbf{BOT}, 0]$$
$$[\#2, T_2, \textbf{BOT}, 0]$$
$$[\#3, T_1, P_A, A\text{-=}50, A\text{+=}50, \#1]$$
$$[\#4, T_2, P_C, C\text{+=}100, C\text{-=}100, \#2]$$
$$[\#5, T_1, P_B, B\text{+=}50, B\text{-=}50, \#3]$$
$$[\#6, T_1, \textbf{commit}, \#5]$$
$$[\#7, T_2, P_A, A\text{-=}100, A\text{+=}100, \#4]$$
$$\langle \#8, T_2, P_A, A\text{+=}100, \#7, \#4 \rangle$$
$$\langle \#9, T_2, P_C, C\text{-=}100, \#8, \#2 \rangle$$
$$\langle \#10, T_2, \text{-}, \text{-}, \#9, 0 \rangle$$

Erläuterung:

- #7, #8, #9: PrevLSN
- #4, #2, 0: UndoNxtLSN

Log-Einträge nach abgeschlossenem Wiederanlauf

Notation: CLRs in spitzen Klammern $\langle \ldots \rangle$

Definition

Aufbau eines CLR:

$\langle LSN, TransaktionsID, PageID, Redo, PrevLSN, UndoNxtLSN \rangle$

- *UndoNxtLSN*: Verweis auf die nächste rückgängig zu machende Änderung derselben Transaktion.
- CLRs enthalten keine Undo-Information: Im Falle eines neuerlichen Systemabsturzes soll die Undo-Operation, für die das CLR angelegt wurde, nicht zurückgenommen sondern fortgesetzt werden.

Wiederanlauf bei neuerlichem Absturz:

- CLRs sind immer Teil der Redo-Phase!

Systemabsturz während des Wiederanlaufs

Beispiel

Absturz nach dem CLR mit LSN = #8:

- Redo-Phase: Log-Records #1 bis #8.
  Änderungsoperationen werden natürlich nur dann durchgeführt, wenn die betroffene Seite auf der Platte eine kleinere LSN hat.
- Undo-Phase: Laut UndoNextLSN-Eintrag des letzten CLR muss das Undo von T_2 bei LSN = 4 fortgesetzt werden.

Beispiel

Absturz nach dem CLR mit LSN = #10:

- Redo-Phase: Log-Records #1 bis #10 (wobei wiederum die LSNs der betroffenen Seiten beachtet werden müssen).
- Undo-Phase: Wegen UndoNextLSN = 0 im letzten CLR ist keine Undo-Operation für T_2 mehr erforderlich.

R1-Recovery: Lokales Zurücksetzen einer Transaktion

Erforderliche Schritte:

- Ermittlung des letzten Log-Eintrags dieser Transaktion (üblicherweise wird ein Zeiger auf den letzten Log-Eintrag aller aktiven Transaktionen im Hauptspeicher gehalten.)
- Lokales Undo: Die Änderungsoperationen dieser Transaktion werden in umgekehrter Richtung rückgängig gemacht. Genau wie beim globalen Undo werden CLRs angelegt.

Effizienz:

- Durch die Rückwärtsverkettung mittels PrevLSN sind die Log-Einträge von T leicht zu finden.
- Bei realistischer Größe des Ringpuffers sind die meisten Log-Einträge der aktiven Transaktionen noch im Hauptspeicher. Lokales Undo geht somit schnell.

Partielles Zurücksetzen einer Transaktion

Erforderliche Schritte:

- Im Prinzip gleich wie lokales Undo, d.h. es werden Änderungsoperationen zurückgesetzt und entsprechende CLRs angelegt.
- Unterschied: Es wird nicht die gesamte Transaktion zurückgesetzt sondern nur ein Teil (und zwar der letzte Teil zurück bis zum gewünschten Rücksetzpunkt).

Bemerkung:

- Partielles Zurücksetzen ist notwendig für die Realisierung von Rücksetzpunkten (savepoints)

R4-Recovery / Media-Recovery

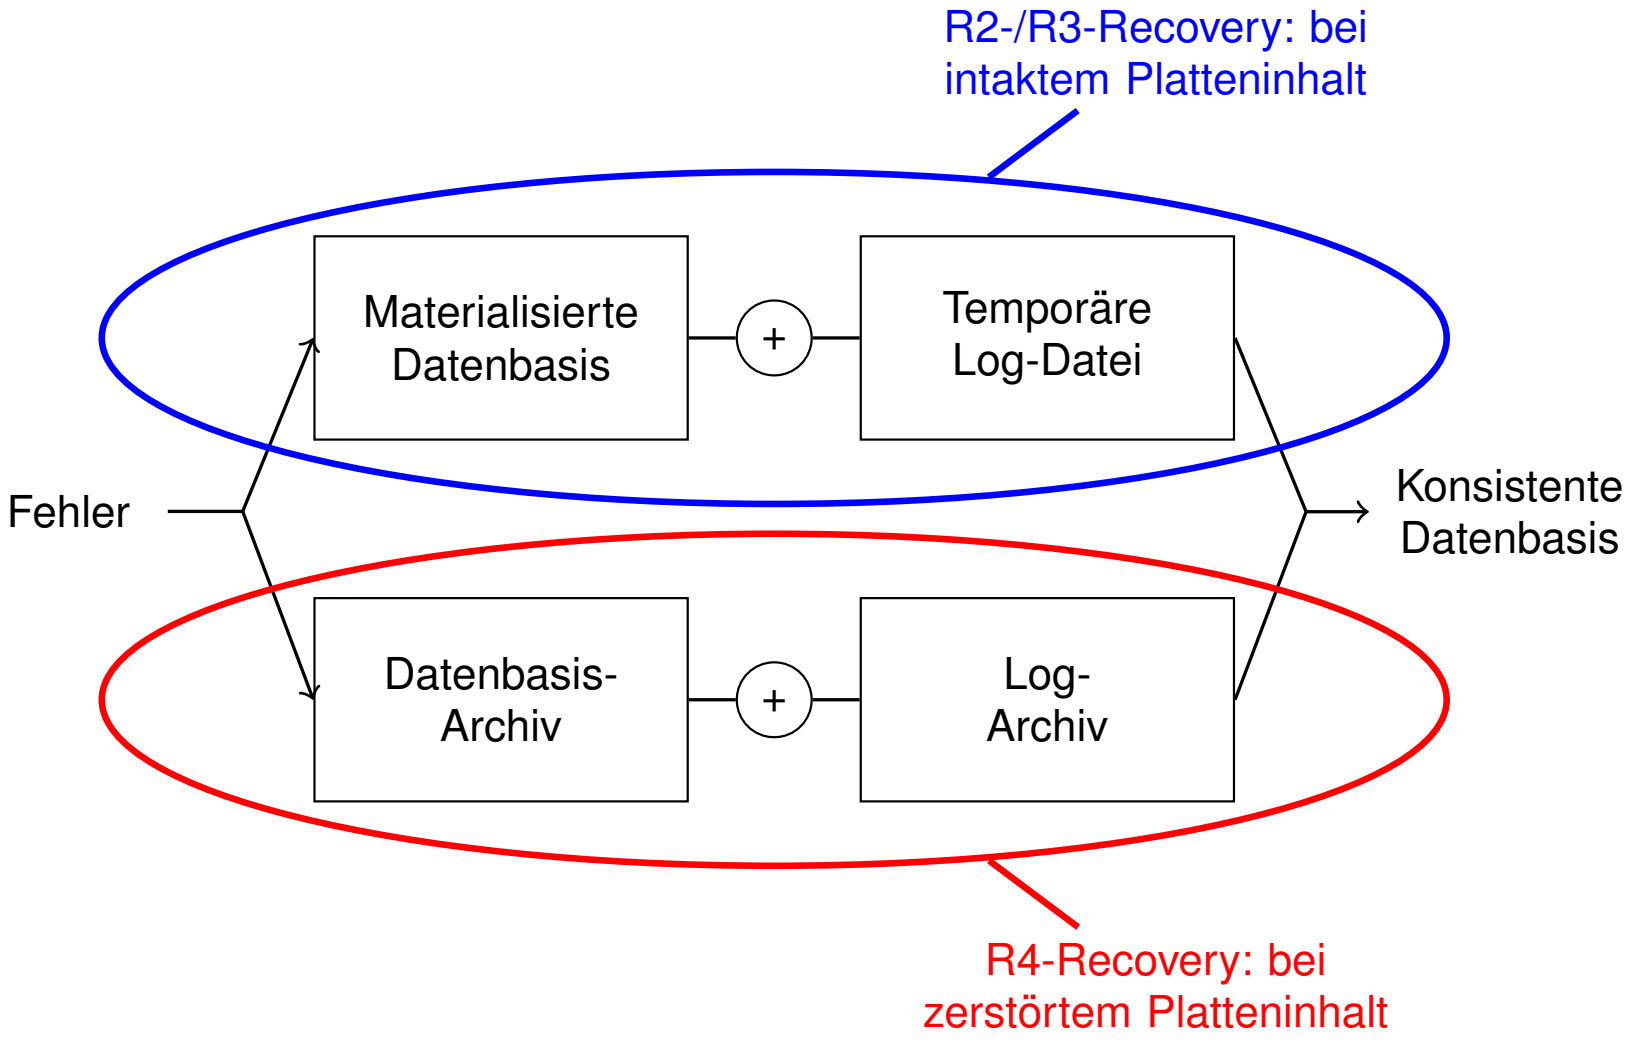

Sicherungspunkte (Checkpointing)

- unterschiedliche Sicherungspunkt-Qualitäten

Warum Sicherungspunkte?

Problem bei bisher vorgestellter Recovery-Methode:

- Die Log-Datei wird mit der Zeit immer größer.
- Dementsprechend dauert der Wiederanlauf immer länger.

Lösung:

- Durch das erzwungene Ausschreiben von geänderten Seiten wird garantiert, dass die Log-Datei erst ab einem bestimmten Log-Eintrag benötigt wird.
- Bemerkung: Die minimale LSN, die im Falle eines Wiederanlaufs noch benötigt wird, hängt vom Zeitpunkt *und* von der Qualität des Sicherungspunktes ab.

Transaktionskonsistente Sicherungspunkte

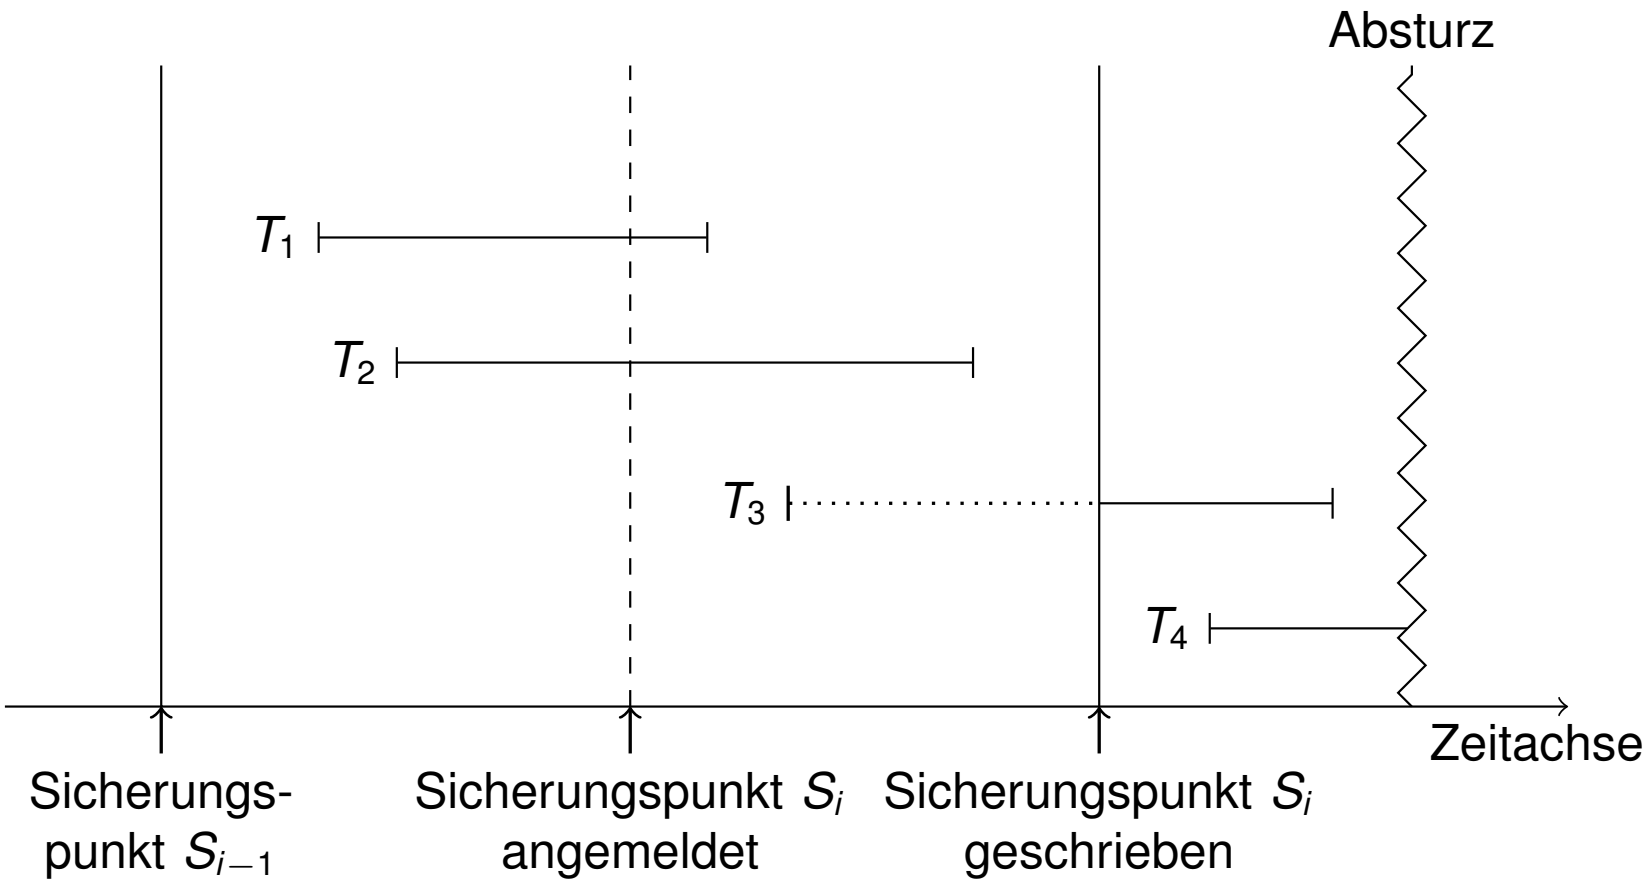

Transaktionskonsistente Sicherungspunkte

Ziel:

- Der Platteninhalt soll alle Änderungen von Transaktionen, die zum Zeitpunkt S_i abgeschlossen sind, enthalten. D.h., beim Wiederanlauf kein Redo über S_i hinaus nötig.
- Zum Zeitpunkt S_i darf es keine aktiven Transaktionen geben. D.h., beim Wiederanlauf kein Undo über S_i hinaus nötig.

Problem:

- Zwischen Anmelden und Festschreiben des Sicherungspunktes dürfen keine neuen Transaktionen gestartet werden. Das ist üblicherweise nicht akzeptabel.

Aktionskonsistente Sicherungspunkte

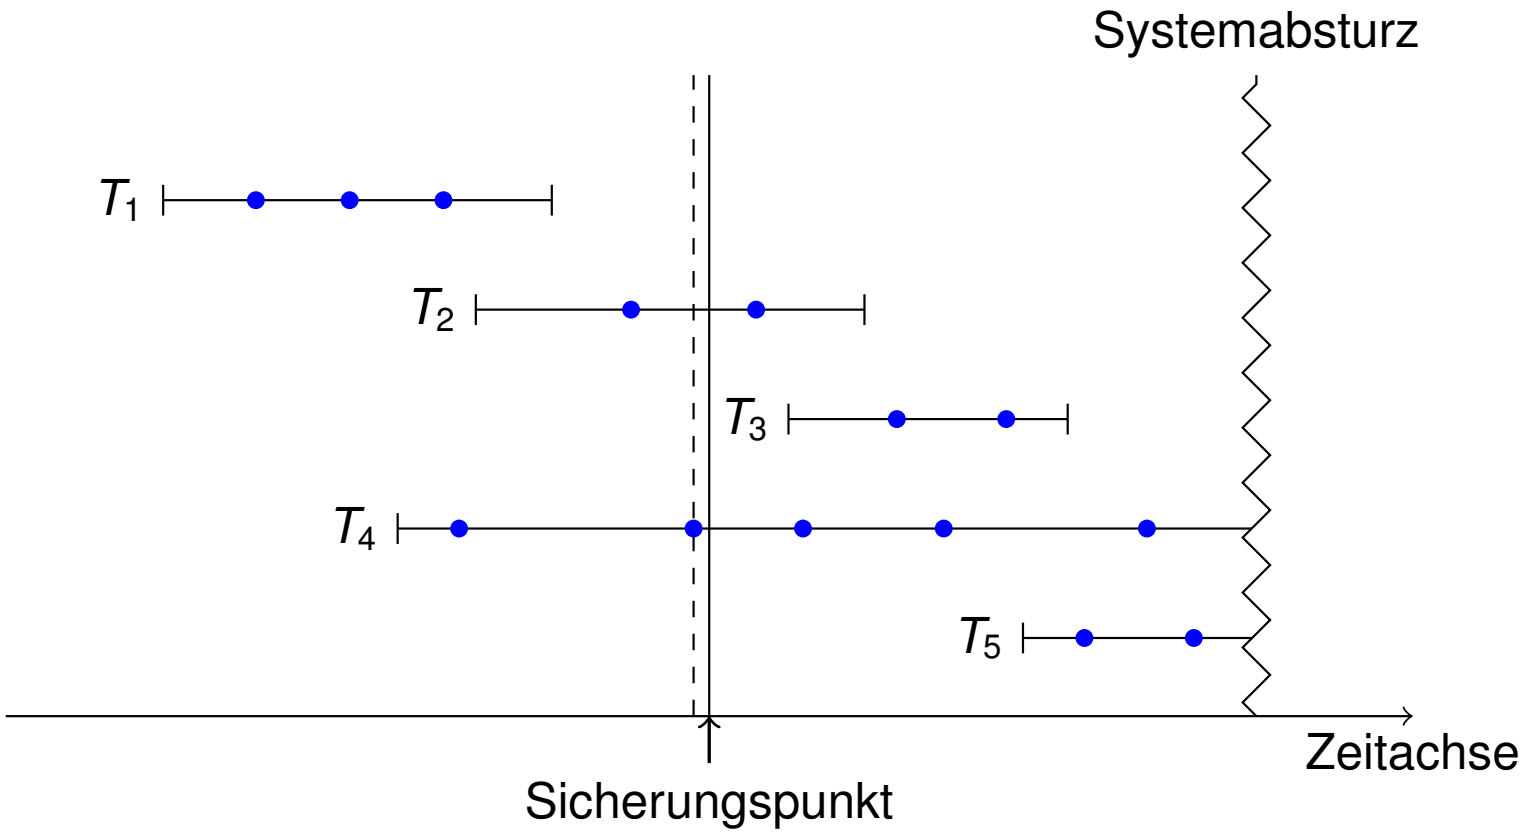

Aktionskonsistente Sicherungspunkte

Idee:

- Alle gerade angefangenen Änderungsoperationen sollen beendet werden. Danach werden alle modifizierten Seiten (= Dirty Pages) ausgeschrieben.
- Es wird nur das Starten der nächsten Änderungsoperation (aber nicht das Starten neuer Transaktionen) verzögert.

Wiederanlauf:

- Analyse-Phase setzt bei S_i auf.
- Kein **Redo** über S_i hinaus nötig.
- Im allgemeinen ist ein **Undo** über S_i hinaus nötig, und zwar bis zur *MinLSN* (= die kleinste LSN der zum Sicherungszeitpunkt aktiven TAs).

Unscharfe (fuzzy) Sicherungspunkte

Idee:

- Seiten sollen kontinuierlich ausgeschrieben werden. D.h., kein abruptes Ausschreiben vieler Seiten wegen des Sicherungspunktes.
- Statt dessen werden nur die Kennungen aller modifizierten Seiten (= Dirty Pages) ausgeschrieben.
- Zusätzlich wird *MinDirtyPageLSN* (= minimale LSN, deren Änderungen noch nicht ausgeschrieben wurden) verwaltet und bei einem Sicherungspunkt auf Platte geschrieben.

Problem:

- „hot-spots“ (laufend benötigte Seiten) werden lange nicht ausgeschrieben. Ausschreiben wird erzwungen, wenn eine Seite mehrmals in der „Dirty Pages“-Menge war.

Drei Sicherungspunkt-Qualitäten

Zusammenfassung

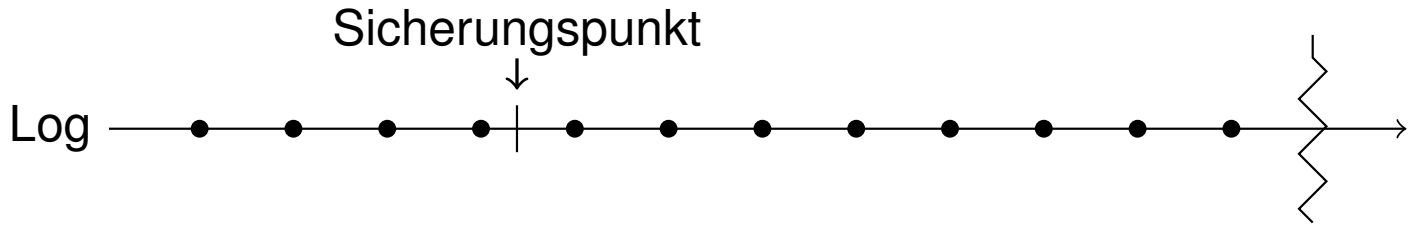

(a) **transaktionskonsistent**

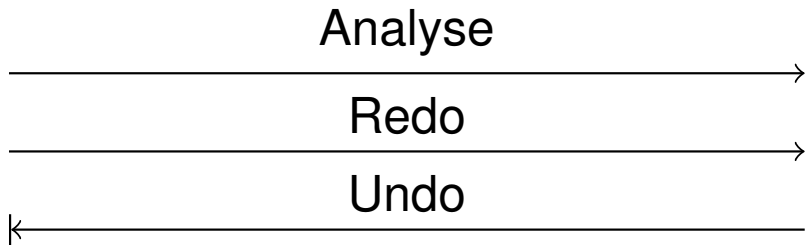

(b) **aktionskonsistent**

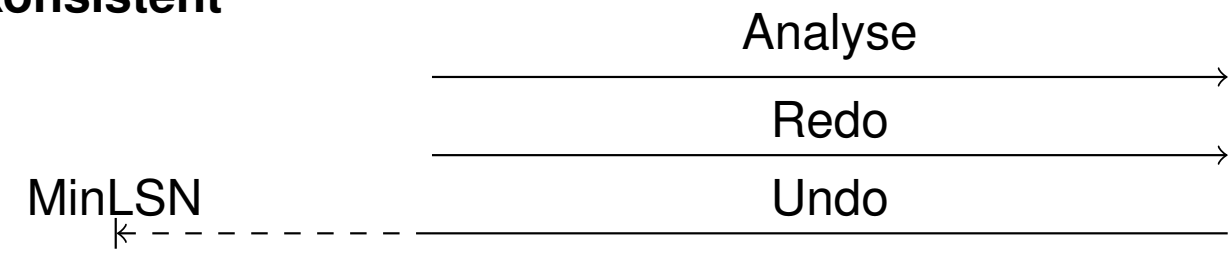

(c) **unscharf (fuzzy)**