8. Logging und Recovery[1]

- **DB-Recovery**
  - Anforderungen und Begriffe
  - Fehler- und Recovery-Arten
- **Logging-Verfahren**
  - Klassifikation und Bewertung
  - Aufbau der Log-Datei, Nutzung von LSNs
- **Abhängigkeiten zu anderen Systemkomponenten**
  - Externspeicherabbildung: Einbringstrategie
  - Zusammenspiel mit der DB-Puffer- und Sperrverwaltung
- **Commit-Behandlung** (Gruppen-, Prä-Commit)
- **Sicherungspunkte**
  Direkte und unscharfe Sicherungspunkte (*Checkpoints*)
- **Klassifikation von DB-Recovery-Verfahren**
- **Crash-Recovery**
  - Allgemeine Restart-Prozedur
  - Restart-Bespiel (Selektives Redo)
  - Einsatz von Compensation Log Records
  - Restart-Beispiel (Repeating History)
- **Transaktions-Recovery**
- **Medien-Recovery**

---

1. Härder, T., Reuter, A.**:** Principles of Transaction Oriented Database Recovery, in: ACM Computing Surveys 15:4, Dec. 1983. 287-317.

DB-Recovery

- **Beobachtung**
  Die Betriebskosten sind 3- bis 18-mal höher als der Kaufpreis von Cluster-basierten Systemen, und 1/3 bis 1/2 dieser Kosten wird für Recovery oder für Fehlervorsorge aufgewendet

- **Systemverfügbarkeit A**
  - MTTF: Mean Time To Failure
  - MTTR: Mean Time To Repair
  - A = MTTF / (MTTF + MTTR)

  - Wie erreicht man annähernd A=1,0 ?
    - MTTF --> ∞ ?
    - MTTR << MTTF !

- **Warum Recovery-Oriented Computing (ROC)?**
  - Falsche Aktionen von Operateuren sowie HW- und SW-Fehler sind Tatsachen, mit denen man fertig werden muß, und keine Probleme, die zu lösen sind[1]
  - MTTR kann direkt gemessen werden
    (MTTF von Magnetplatten ist heute 120 Jahre)
  - Verkürzung der MTTR (auf Anwendungsebene) verbessert die Benutzererfahrung, was das Systemverhalten betrifft
  - Häufige „Recovery“ kann die effektive MTTF verlängern

  ➥ ***Der Fokus liegt auf ROC!***

1. If a problem has no solution, it may not be a problem but a fact, not to be solved but to be coped with over time (Shimon Peres)

DB-Recovery (2)

- **Aufgabe des DBVS:**
  Automatische Behandlung aller erwarteten Fehler

- **Was sind erwartete Fehler?**[1]
  - DB-Operation wird zurückgewiesen, Commit wird nicht akzeptiert, . . .
  - Stromausfall, DBVS-Probleme, . . .
  - Geräte funktionieren nicht (Spur, Zylinder, Platte defekt)
  - auch beliebiges Fehlverhalten der Gerätesteuerung?
  - falsche Korrektur von Lesefehlern? . . .

- **Was sind die Besonderheiten der DBS-Fehlerbehandlung?**
  - Begrenzung von Behebung der zur Laufzeit möglichen Fehler
    (wie auch bei anderen fehlertoleranten Systemen)
  - „Reparatur" der statischen Struktur der DB

- **Allgemeine Probleme**
  - Fehlererkennung
  - Fehlereingrenzung
  - Abschätzung des Schadens
  - Durchführung der Recovery

- **Fehlermodell von zentralisierten DBVS**
  - Transaktionsfehler
  - Systemfehler
  - Gerätefehler
  - Katastrophen

1. Kommerzielle Anwendungen auf Großrechnern sind durch ihre Zuverlässigkeit gekennzeichnet. Nicht selten besteht der Code bis zu 90% aus (erprobten) Recovery-Routinen (W. G. Spruth).

DB-Recovery (3)

- **Voraussetzung:**
  Sammeln redundanter Informationen während des Normalbetriebs

- **Welcher Zielzustand soll erreicht werden?**
  - früher: beliebiger Abbruch der DB-Verarbeitung
  - Verbesserung: Sicherungspunkte bei „Langläufern”

- **Transaktionsparadigma verlangt:**
  - Alles-oder-Nichts-Eigenschaft von Transaktionen
  - Dauerhaftigkeit erfolgreicher Änderungen

- **Zielzustand nach erfolgreicher Recovery:**

  Durch die Recovery-Aktionen ist der jüngste Zustand vor Erkennen des Fehlers wiederherzustellen, der allen semantischen Integritäts-bedingungen entspricht, der also ein möglichst aktuelles, exaktes Bild der Miniwelt darstellt

  ➥ ***jüngster transaktionskonsistenter DB-Zustand***

- **In welchem Zustand befindet sich die Systemumgebung? (Betriebssystem, Anwendungssystem, andere Komponenten)**

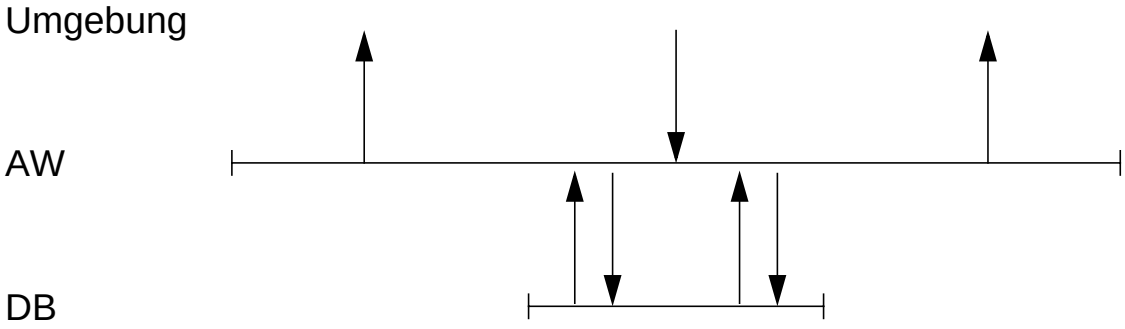

DB-Recovery (4)

- **Wie soll Recovery durchgeführt werden?**

- **Forward-Recovery**
  - Non-Stop-Paradigma (Prozeßpaare usw.)
  - Fehlerursache häufig falsche Programme, Eingabefehler u. ä.
  - durch Fehler unterbrochene TA sind zurückzusetzen

  ➥ **Forward-Recovery i. allg. nicht anwendbar**

- **Backward-Recovery**
  - setzt voraus, daß auf allen Abstraktionsebenen genau definiert ist, auf welchen Zustand die DB im Fehlerfall zurückzusetzen ist.
  - Zurücksetzen auf konsistenten Zustand und Wiederholung
  - Warum funktioniert Backward-Recovery?
    (Unterscheidung von „Bohrbugs" und „Heisenbugs")

- **"A recoverable action is 30% harder and requires 20% more code than a non-recoverable action" (J. Gray)**
  - Anweisungs- und TA-Atomarität gefordert
  - Zwei Prinzipien der Anweisungs-Atomarität möglich
    - „Do things twice"
      (vorbereitende Durchführung der Operation; wenn alles OK, erneuter Zugriff und Änderung)
    - „Do things once"
      (sofortiges Durchführen der Änderung; wenn Fehler auftritt, internes Zurücksetzen)
  - Zweites Prinzip wird häufiger genutzt (ist optimistischer und effizienter)

Recovery – Begriffsklärung

- **Grundsätzliche Vorgehensweisen**

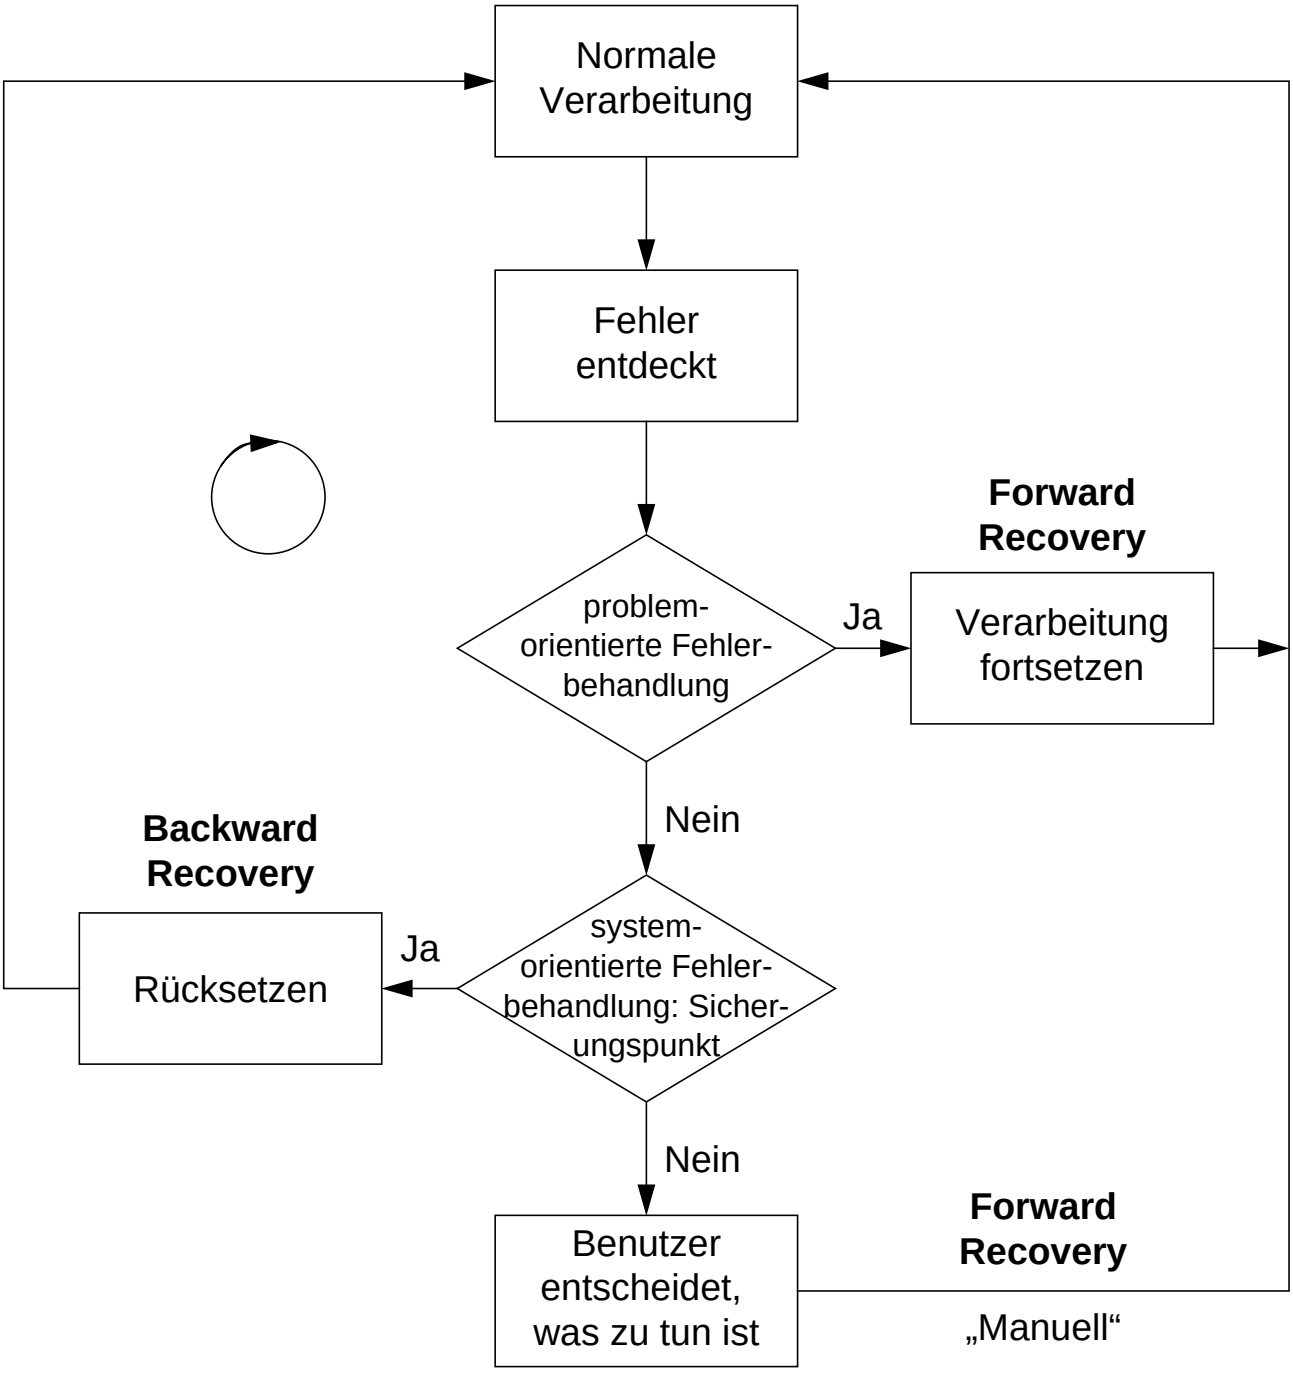

- **Was passiert, wenn**
  - nach Backward-Recovery der Fehler nicht behoben ist?
  - nach Forward-Recovery die „normale Verarbeitung“ weitergeführt bzw. wieder aufgenommen wird?

Fehlerarten

Auswirkung eines Fehlers auf	Fehlertyp	Fehlerklassifikation
eine Transaktion	- Verletzung von Systemrestriktionen • Verstoß gegen Sicherheitsbestimmungen • übermäßige Betriebsmittelanforderungen - anwendungsbedingte Fehler • z. B. falsche Operationen und Werte	Transaktionsfehler
mehrere Transaktionen	- geplante Systemschließung - Schwierigkeiten bei der Betriebsmittelvergabe • Überlast des Systems • Verklemmung mehrerer Transaktionen	
alle Transaktionen (das gesamte Systemverhalten)	- Systemzusammenbruch mit Verlust der Hauptspeicherinhalte • Hardware-Fehler • falsche Werte in kritischen Tabellen	Systemfehler
	- Zerstörung von Sekundärspeichern	Gerätefehler
	- Zerstörung des Rechenzentrums	Katastrophen

Recovery-Arten

1. **Transaktions-Recovery**
   Zurücksetzen einzelner (noch nicht abgeschlossener) TA
   im laufenden DB-Betrieb (TA-Fehler, Deadlock, etc.)[1]
   - R1: vollständiges Zurücksetzen auf BOT (TA-UNDO) bzw.
   - R0: partielles Zurücksetzen auf Rücksetzpunkt (*Savepoint*) innerhalb der Transaktion

2. **Crash-Recovery nach Systemfehler**
   Wiederherstellen des jüngsten transaktionskonsistenten DB-Zustandes:
   - R2: (partielles) REDO für erfolgreiche TA
     (Wiederholung verlorengegangener Änderungen)
   - R3: UNDO aller durch Ausfall unterbrochenen TA
     (Entfernen der Änderungen aus der permanenten DB)

3. **Medien-Recovery nach Gerätefehler** (R4)
   - Spiegelplatten
     bzw.
   - vollständiges Wiederholen (REDO) aller Änderungen auf einer Archivkopie

4. **Katastrophen-Recovery**
   - Nutzung einer aktuellen DB-Kopie in einem “entfernten” System oder
   - stark verzögerte Fortsetzung der DB-Verarbeitung mit repariertem/neuem System auf der Basis gesicherter Archivkopien (Datenverlust!)

---

1. Die verschiedenen Recovery-Verfahren werden auch mit R0 - R4 abgekürzt.

Recovery-Arten (2)

- **A Fundamental Theorem of Recovery**

  Axiom 1 (Murphy): All programs (DBMSs) are buggy.

  Theorem 1 (Law of Large Programs):
  Large programs are even buggier than their size would indicate.

  Corollary 1.1:
  A recovery-relevant program has recovery bugs.

  Theorem 2:
  If you do not run a program, it does not matter whether or not it is buggy.

  Corollary 2.1:
  If you do not run a program, it does not matter if it has recovery bugs.

  Theorem 3:
  Exposed machines should run as few programs as possible;
  the ones that are run should be as small as possible!???

  ➥ ***KISS: Keep It Simple, Stupid!***

- **Annahmen**
  (Unter welchen Voraussetzungen funktioniert die Wiederherstellung der Daten?)

  - quasi-stabiler Speicher
  - fehlerfreier DBVS-Code
  - fehlerfreie Log-Daten
  - Unabhängigkeit der Fehler

Recovery-Arten (3)

- **Pessimistische Variante von “Murphy’s Law”**

  ➥ **Was ist zu tun, wenn . . .?**

- **Nicht systematisierte Recovery-Verfahren**
  - R5-Recovery
    - Log-Daten sind fehlerhaft oder DB-Strukturen (ohne Log-Daten) sind unbrauchbar
    - kein TA-konsistenter, bestenfalls aktions- oder gerätekonsistenter Zustand erreichbar

    ➥ ***Salvation Programs, Scavenger***

  - R6-Recovery:
    Zusammenfassung aller Maßnahmen außerhalb des Systems
    - Kompensations-TA und
    - Behandlung der Auswirkungen (manuell)

- **Entwicklungsziele**

  Build a system used by millions of people that is always available -
  out less than 1 second per 100 years = 8 9’s of availability! (J. Gray: **1998 Turing Lecture**)
  - Verfügbarkeit heute (optimistisch):[1]
    - für Web-Sites: 99%
    - für gut administrierte Systeme: 99,99%
    - höchstens: 99,999%
  - Künftige Verfügbarkeit
    - bis 2010: weitere 4 9’
    - . . .

1. Despite marketing campaigns promising 99,999% availability, well-managed servers today achieve 99,9% to 99%, or 8 to 80 hours downtime per year (Armando Fox)

DB-Recovery – Systemkomponenten

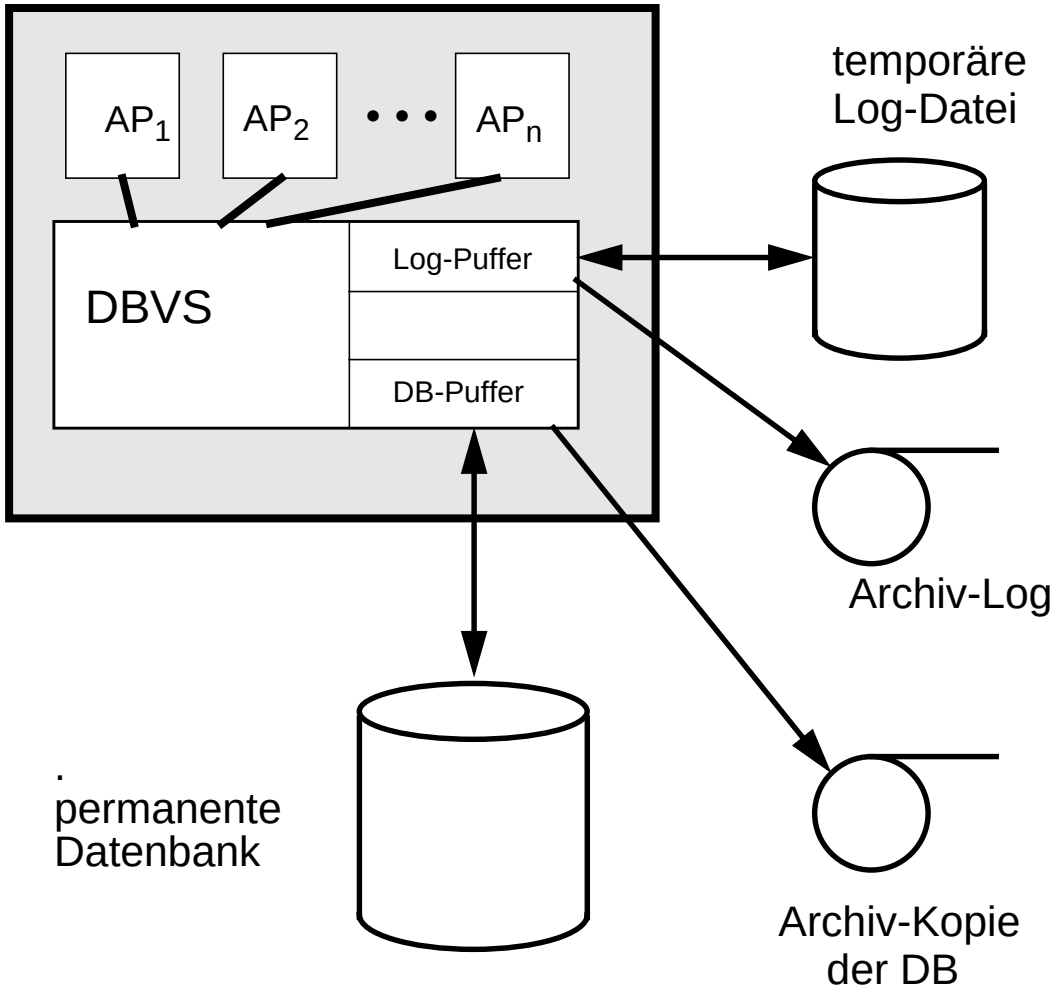

- **Pufferung von Log-Daten im Hauptspeicher** (Log-Puffer)
  Ausschreiben spätestens bei Commit
- **Einsatz der Log-Daten**

1. **Temporäre Log-Datei**

   zur Behandlung von Transaktions- und Systemfehlern

   DB + temp. Log ⇒ DB

2. **Behandlung von Gerätefehlern:**

   Archiv-Kopie + Archiv-Log ⇒ DB

Logging-Aufgaben

- **Logging**
  - Sammlung redundanter Daten bei Änderungen im Normalbetrieb (Do) als Voraussetzung für Recovery
  - Einsatz im Fehlerfall (Undo-, Redo-Recovery)

- **Do-Redo-Undo-Prinzip**

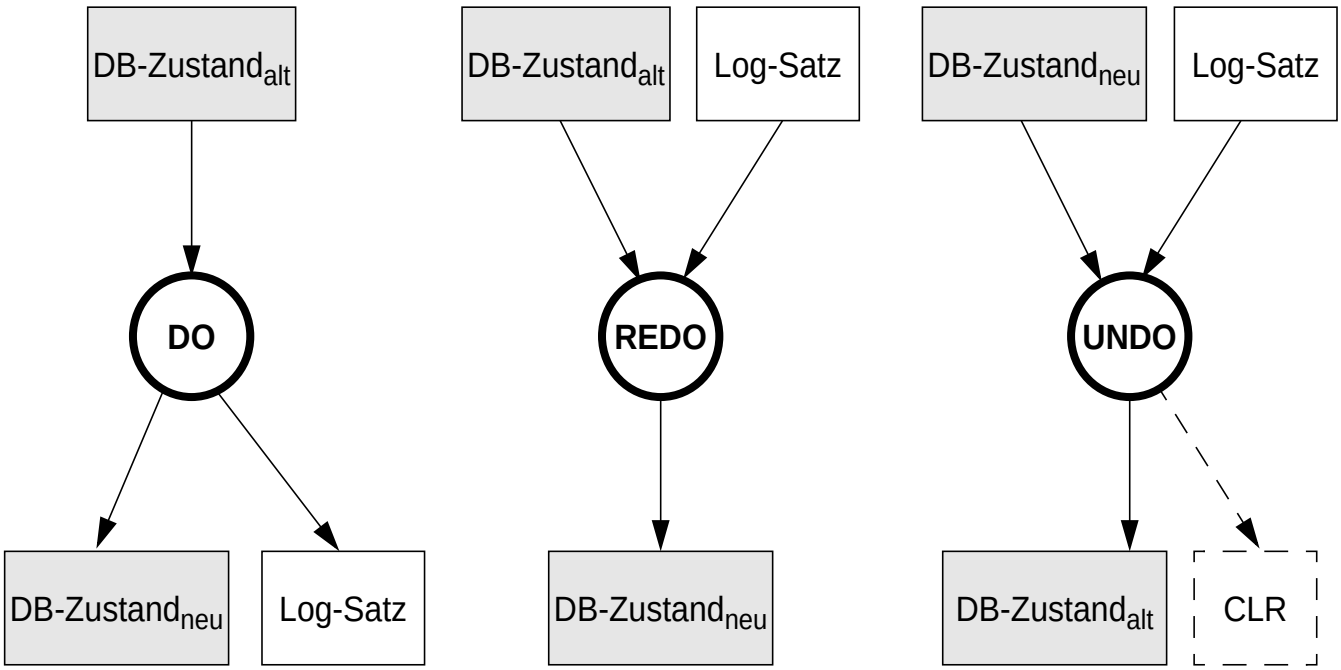

CLR = Compensation Log Record (für Crash während der Recovery)

- **Log-Granulat**
  - Welche Granulate können gewählt werden?
  - Was ist zu beachten?

Abstraktionsebenen und Logging

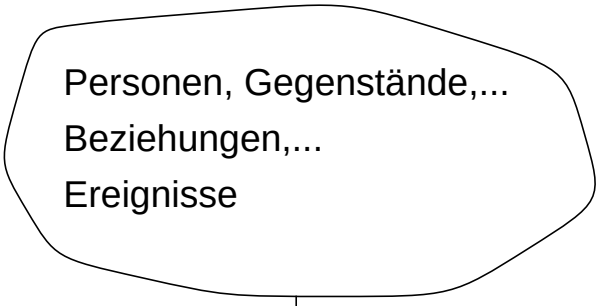

Anwendungsbereich („Miniwelt“) des Benutzers

Semantische Integritätsbedingungen

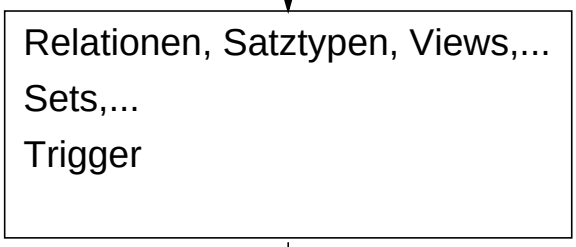

Datenmodell zur formalisierten Abbildung der Miniwelt

Modellbedingungen (Abb. der sem. I.-Bed.)

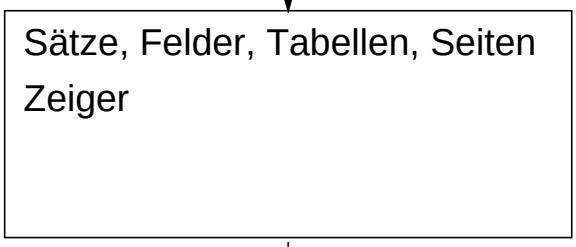

Repräsentation in einem linearen Adreßraum

Konsistenzbedingungen von Tabellen, Zeigern, usw.

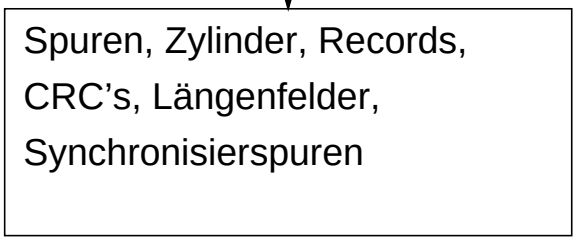

Physische Repräsentation auf externen Speichern

Paritäts-, Längenbedingungen, usw.

Logging kann auf jeder Ebene erfolgen:

Das Sammeln von ebenenspezifischer Log-Information setzt voraus, daß bei der Recovery die Konsistenzbedingungen der darunterliegenden Abbildungsschicht im DB-Zustand erfüllt sind !

➥ Wie kann ebenenspezifische Konsistenz (Aktions- oder Operationskonsistenz) im Fehlerfall garantiert werden ?

Klassifikation von Logging-Verfahren

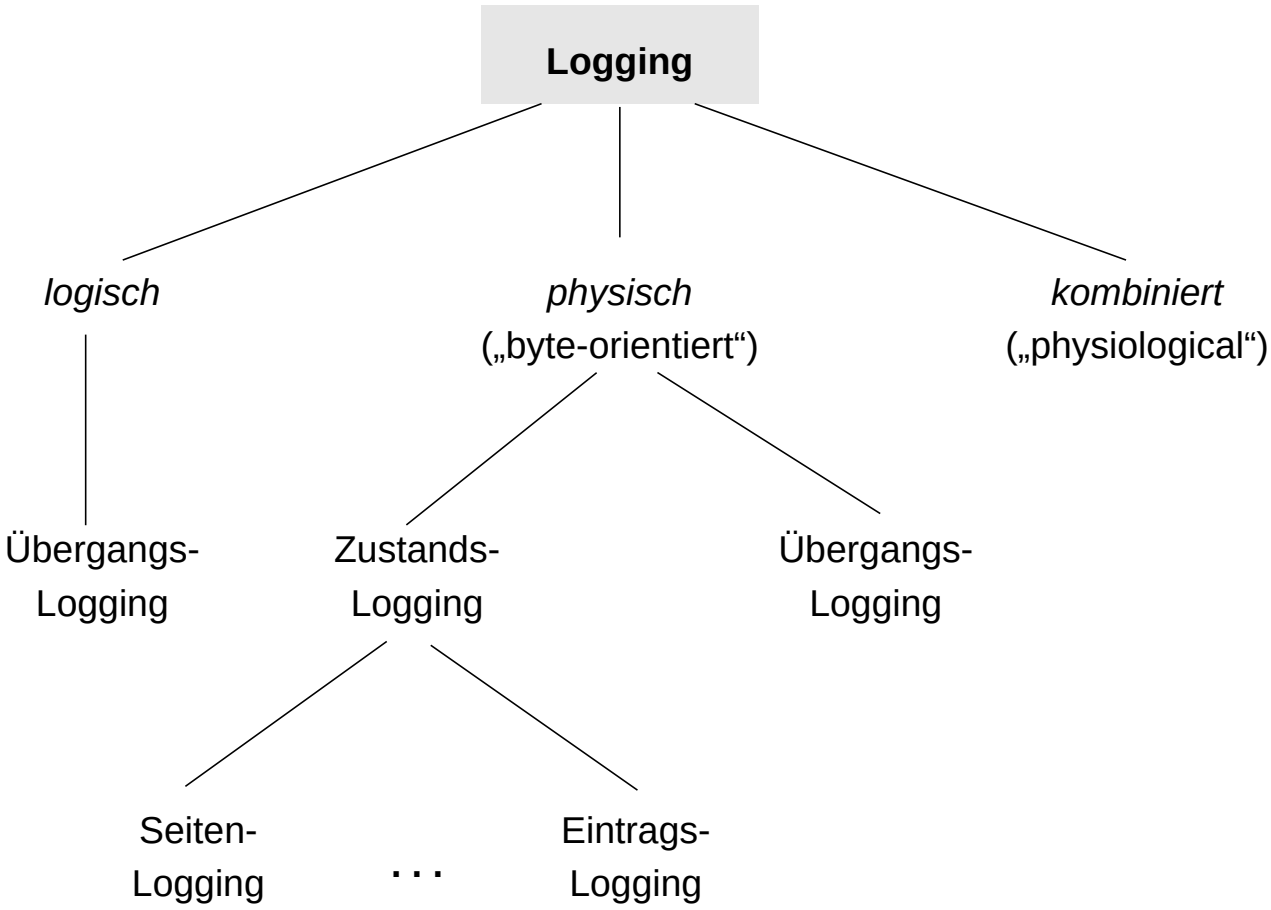

- **Logisches Logging**
  - Protokollierung der ändernden DML-Befehle mit ihren Parametern
  - Generelles Problem:
    mengenorientierte Aktualisierungsoperation (z. B. DELETE <relation>)
  - UNDO-Probleme v.a. bei nicht-relationalen Systemen
    (z. B. Löschen einer Hierarchie von Set-Ausprägungen (ERASE ALL))
  - Voraussetzung:
    Nach einem Systemausfall müssen auf der permanenten Datenbank DML-Operationen ausführbar sein, d.h. sie muß wenigstens speicherkonsistent sein (Aktionskonsistenz)

    ➥ ***verzögerte (indirekte) Einbringstrategie erforderlich***

Klassifikation von Logging-Verfahren (2)

- **Physisches Logging**
  - Log-Granulat: Seite vs. Eintrag/Satz
  - **Zustands-Logging:**
    Alte Zustände (Before-Images) und neue Zustände (After-Images) geänderter Objekte werden in die Log-Datei geschrieben
  - **Übergangs-Logging:**
    Protokollierung der Differenz zwischen Before- und After-Image
  - Physisches Logging ist bei direkten und verzögerten Einbringstrategien anwendbar

- **Probleme logischer und physischer Logging-Verfahren**
  - Logisches Logging:
    für Update-in-Place nicht anwendbar
  - Physisches, „byte-orientiertes“ Logging:
    aufwendig und unnötig starr v.a. bezüglich Lösch- und Einfügeoperationen

- **Physiologisches Logging**
  Kombination physische/logische Protokollierung:
  Physical-to-a-page, Logical-within-a-page
  - Protokollierung von elementaren Operationen innerhalb einer Seite
  - Jeder Log-Satz bezieht sich auf eine Seite
  - Technik ist mit Update-in-Place verträglich

Logging: Anwendungsbeispiel

- **Änderungen** bezüglich einer Seite A:
  1. Ein Objekt a wird in Seite A eingefügt
  2. In A wird ein bestehendes Objekt b_{alt} nach b_{neu} geändert

- **Zustandsübergänge** von A: $A_1 \overset{1.}{\rightarrow} A_2 \overset{2.}{\rightarrow} A_3$

	logisch	*physisch*
Zustände		Protokollierung der Before- und After-Images 1. A_1 und A_2 2. A_2 und A_3
Übergänge	Protokollierung der Operationen mit Parameter 1. Insert (a) 2. Update (b_{alt},b_{neu})	Differenzen-Logging 1. $A_1 \oplus A_2$ 2. $A_2 \oplus A_3$

- **Rekonstruktion von Seiten** beim Differenzen-Logging:

  A_1 als Anfangs- oder A_3 als Endzustand seien verfügbar

  Es gilt:

$A_1 \oplus (A_1 \oplus A_2) = A_2$	$A_3 \oplus (A_2 \oplus A_3) = A_2$
$A_2 \oplus (A_2 \oplus A_3) = A_3$	$A_2 \oplus (A_1 \oplus A_2) = A_1$
Redo-Recovery	Undo-Recovery

Aufwand bei physischem Zustandslogging

- **Einfachste Form der Implementierung: Seiten-Logging**

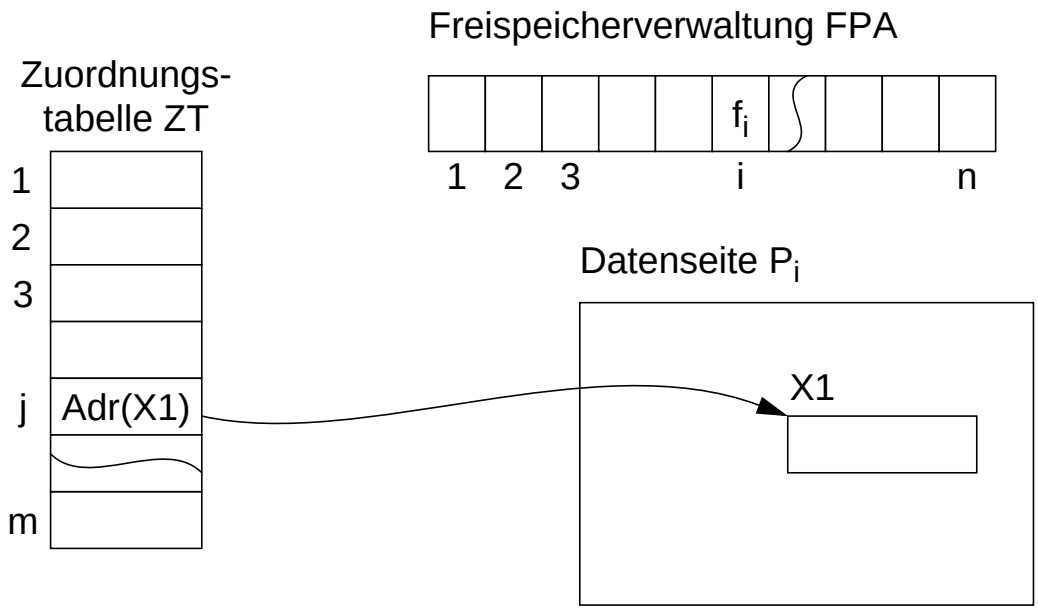

- **Operation:** STORE X-RECORD (X1)

Aufwand	Datenseite	ZT	FPA	n Zugriffspfad-seiten (Min)
normaler Betrieb (DO)	neues P_i	Adr(X1)	f_i	n DS_{neu}
UNDO-Log	altes P_i	alter Inhalt	alter Inhalt	n DS_{alt}
REDO-Log	neues P_i	Adr(X1)	f_i	n DS_{neu}

Bewertung der Logging-Verfahren

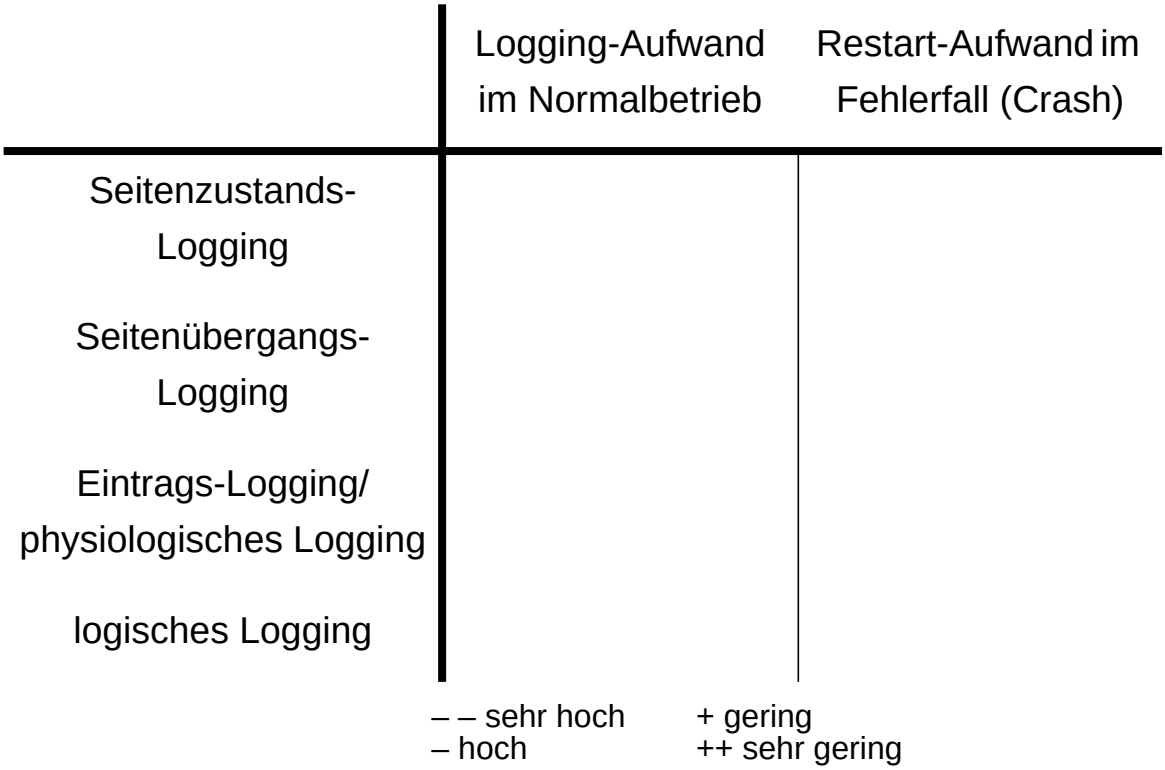

- **Vorteile von *Eintrags-Logging* gegenüber *Seiten-Logging*:**
  - geringerer Platzbedarf
  - weniger Log-E/As
  - erlaubt bessere Pufferung von Log-Daten (Gruppen-Commit)
  - unterstützt feine Synchronisationsgranulate (Seiten-Logging ➥ Synchronisation auf Seitenebene)

  ➥ **jedoch:** Recovery ist komplexer als mit Seiten-Logging

Aufbau der (temporären) Log-Datei

- **Verschiedene Satzarten erforderlich**
  - BOT-, Commit-, Abort-Satz
  - Änderungssatz (UNDO-Informationen (z. B. ‚Before-Images') und REDO-Informationen (z. B. ‚After-Images'))
  - Sicherungspunkt-Sätze

- **Protokollierung von Änderungsoperationen**
  - **Struktur der Log-Einträge**
    [LSN, TAID, PageID, Redo, Undo, PrevLSN]
  - **LSN** (Log Sequence Number)
    - eindeutige Kennung des Log-Eintrags
    - LSNs müssen monoton aufsteigend vergeben werden
    - chronologische Reihenfolge der Protokolleinträge kann dadurch ermittelt werden
  - **Transaktionskennung** TAID
    der TA, welche die Änderung durchgeführt hat
  - **PageID**
    - Kennung der Seite, auf der die Änderungsoperation vollzogen wurde
    - Wenn die Änderung mehr als eine Seite betrifft, müssen entsprechend viele Log-Einträge generiert werden
  - **Redo**
    Redo-Information gibt an, wie die Änderung nachvollzogen werden kann
  - **Undo**
    Undo-Information beschreibt, wie die Änderung rückgängig gemacht werden kann
  - **PrevLSN**
    ist ein Zeiger auf den vorhergehenden Log-Eintrag der jeweiligen TA. Diesen Eintrag benötigt man aus Effizienzgründen

Beispiel einer Log-Datei

Schritt	T_1	T_2	Log
			[LSN, TAID, 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, T2, P_A, A-=100, A+=100, #4]
16.		**Commit**	[#8, T_2, **Commit**, #7]

Aufbau der (temporären) Log-Datei (2)

- **Log ist eine sequentielle Datei**

  Schreiben neuer Protokolldaten an das aktuelle Dateiende

- Log-Daten sind für Crash-Recovery **nur begrenzte Zeit relevant**
  - Undo-Sätze für erfolgreich beendete TA werden nicht mehr benötigt
  - nach Einbringen der Seite in die DB wird Redo-Information nicht mehr benötigt
  - Redo-Information für Medien-Recovery ist im Archiv-Log zu sammeln!

- ***Ringpufferorganisation*** der Log-Datei

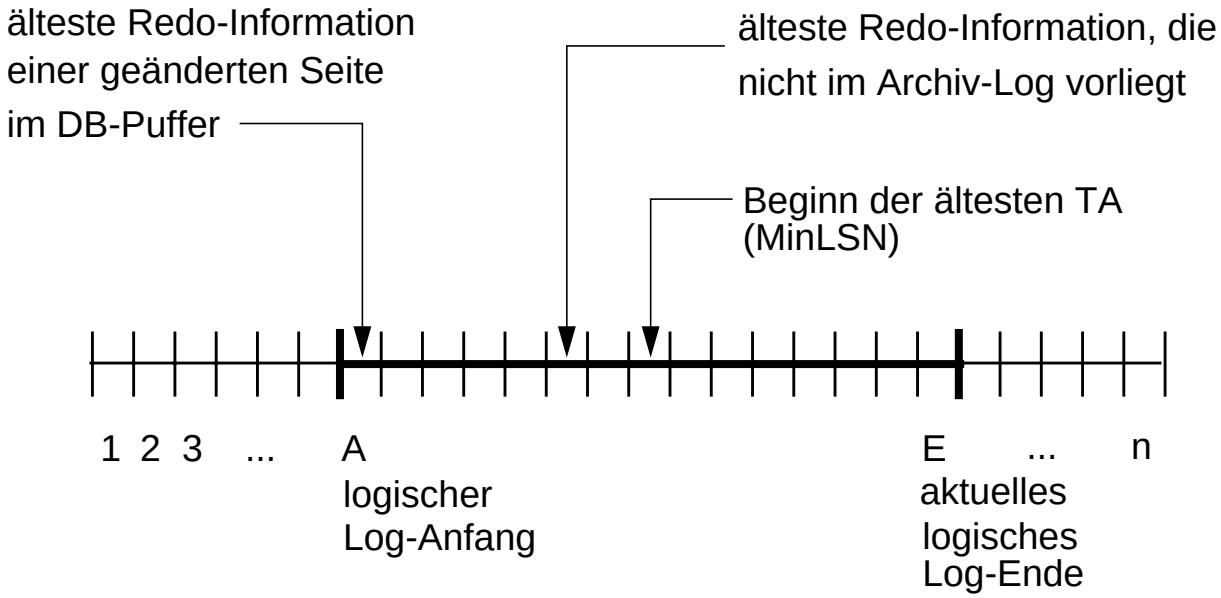

Abhängigkeiten zu anderen Systemkomponenten

- **Stark vereinfachtes Modell**

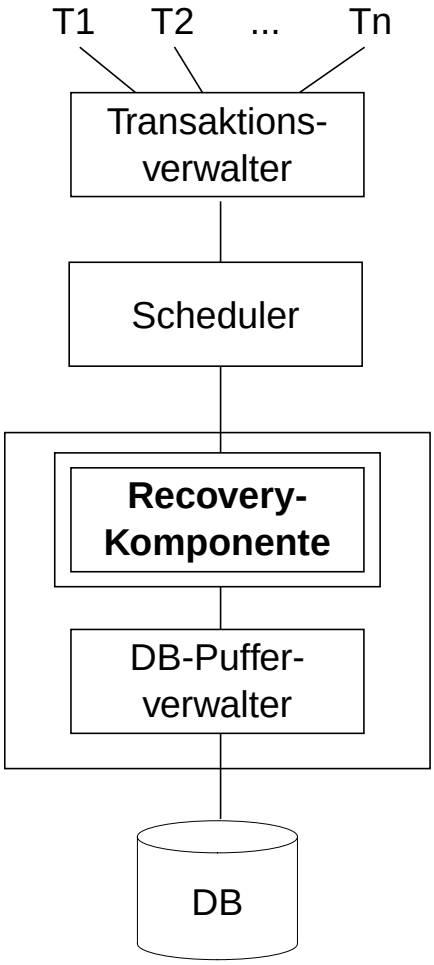

1. **Einbringstrategie für Änderungen**
   - direkt (Non-Atomic, *Update-in-Place*)
   - verzögert (Atomic, Bsp.: Schattenspeicherkonzept)
2. **DB-Pufferverwaltung**
   - Verdrängen ‚schmutziger' Seiten (Steal vs. NoSteal)
   - Ausschreibstrategie für geänderte Seiten (Force vs. NoForce)
3. **Sperrverwaltung**
   (Wahl des Sperrgranulats)

Abhängigkeiten zur Einbringstrategie

- **Direkt (*Update-in-Place*)**
  - Geänderte Seite wird immer in denselben Block auf Platte zurückgeschrieben, Schreiben ist gleichzeitig Einbringen in die permanente DB
  - ‚Atomares' Einbringen mehrerer geänderter Seiten ist nicht möglich **(Non-Atomic**)

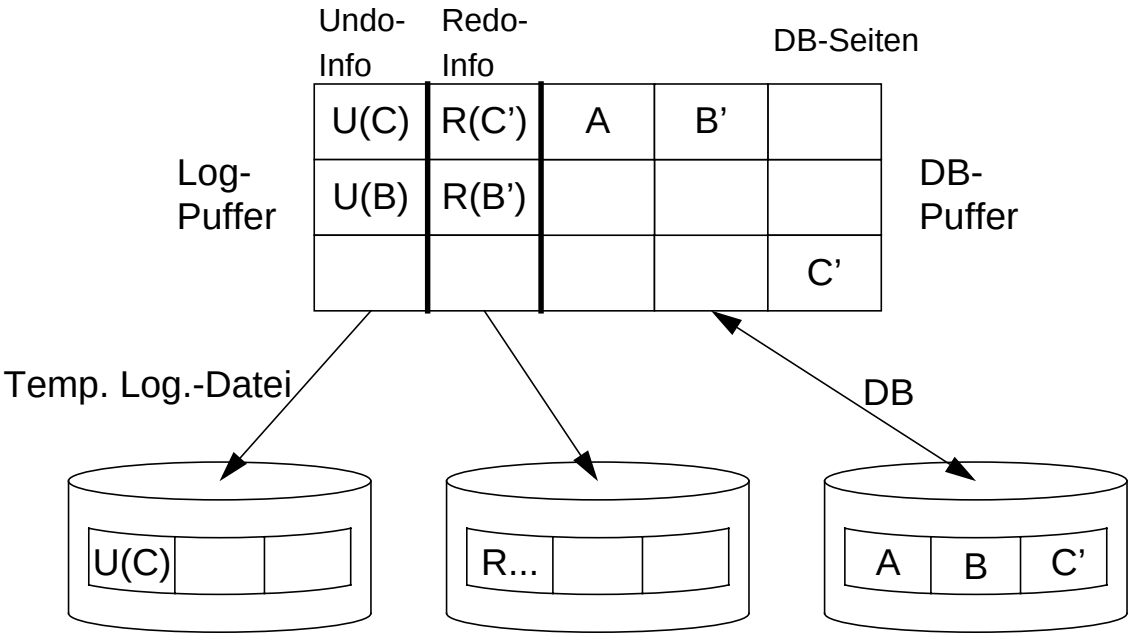

Undo- und Redo-Info typischerweise in einer sequentiellen Datei

- Es sind **zwei Prinzipien** einzuhalten (Minimalforderung):

1. **WAL-Prinzip: *Write Ahead Log* für Undo-Info**

   U(B) vor B'

2. **Ausschreiben der Redo-Info spätestens bei Commit**

   R(C') + R(B') vor Commit

Abhängigkeiten zur Einbringstrategie (2)

- **Verzögert (Atomic)** (System R, SQL/DS)
  - Geänderte Seite wird in separaten Block auf Platte geschrieben, Einbringen in die DB erfolgt später
  - Seitentabelle gibt aktuelle Adresse einer Seite an
  - Verzögertes, atomares Einbringen mehrerer Änderungen ist durch Umschalten von Seitentabellen möglich

    ➥ *aktions- oder transaktionskonsistente DB auf Platte*

    (logisches Logging anwendbar)

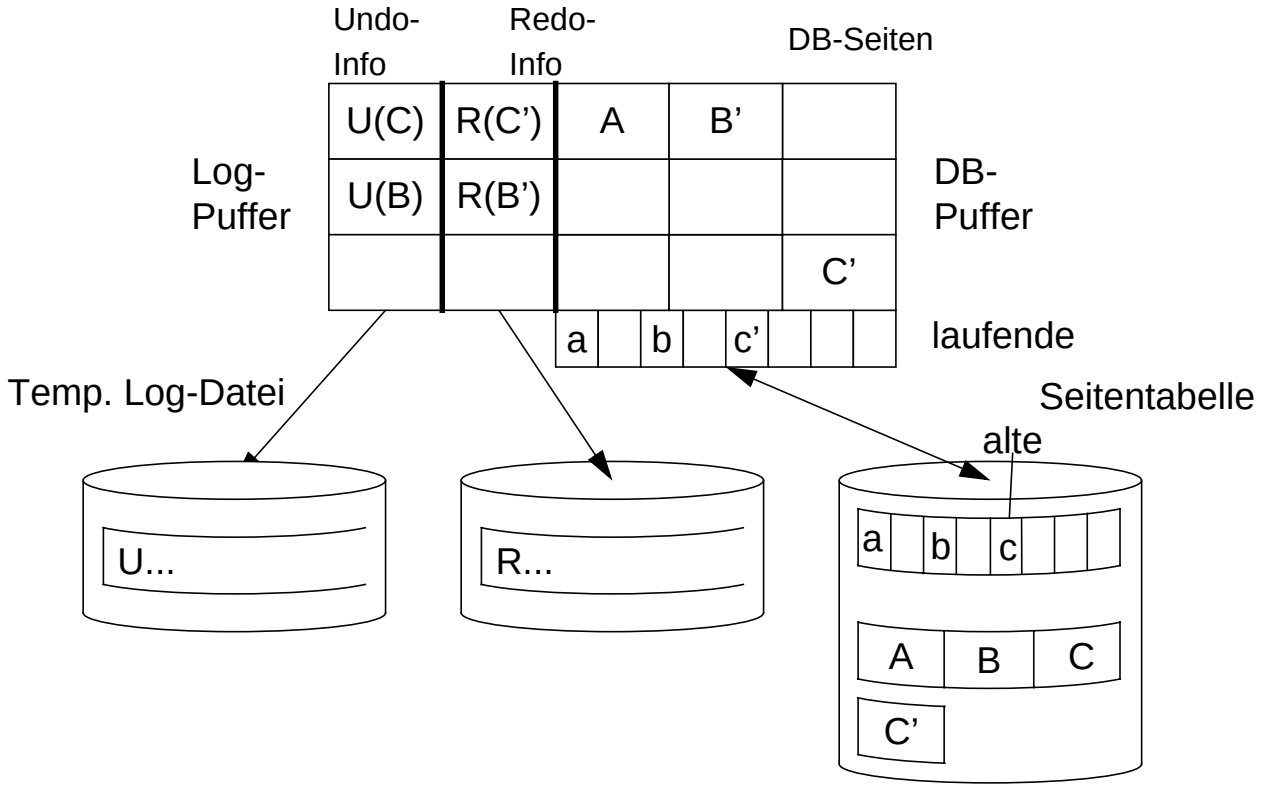

1. WAL-Prinzip bei verzögertem Einbringen

TA-bezogene Undo-Info ist vor Sicherungspunkt zu schreiben

U(C) + U(B) vor Sicherungspunkt

2. Ausschreiben der Redo-Info spätestens bei Commit

R(C') + R(B') vor Commit

Abhängigkeiten zur Ersetzungsstrategie

- **Problem: Ersetzung ‚schmutziger' Seiten**

- **Steal:**

  Geänderte Seiten können jederzeit, insbesondere vor EOT der ändernden TA, ersetzt und in die permanente DB eingebracht werden

  \+ große Flexibilität zur Seitenersetzung

  – Undo-Recovery vorzusehen
  (TA-Abbruch, Systemfehler)

  ➥ Steal erfordert Einhaltung des ***Write-Ahead-Log (WAL)-Prinzips:***

  Vor dem Einbringen einer schmutzigen Änderung müssen zugehörige Undo-Informationen (z. B. Before-Images) in die Log-Datei geschrieben werden

- **NoSteal:**
  - Seiten mit schmutzigen Änderungen dürfen nicht ersetzt werden
  - Es ist keine Undo-Recovery auf der permanenten DB vorzusehen
  - Probleme bei langen Änderungs-TA

Abhängigkeiten zur Ausschreibstrategie (EOT-Behandlung)

- **Force:**

  Alle geänderten Seiten werden spätestens bei EOT (bei Commit) in die permanente DB eingebracht (Durchschreiben)

  \+ keine Redo-Recovery nach Rechnerausfall

  – hoher Schreibaufwand

  – große DB-Puffer werden schlecht genutzt

  – Antwortzeitverlängerung für Änderungs-TA

- **NoForce:**

  \+ kein Durchschreiben der Änderungen bei EOT

  \+ Beim Commit werden lediglich Redo-Informationen in die Log-Datei geschrieben

  – Redo-Recovery nach Rechnerausfall

- **Commit-Regel:**

  Bevor das Commit einer TA ausgeführt werden kann, sind für ihre Änderungen ausreichende Redo-Informationen (z. B. *After-Images*) zu sichern

Weitere Abhängigkeiten

- **Wie wirken sich Ersetzungs- und Ausschreibstrategie auf die Recovery-Maßnahmen aus?**

	Steal	**Nosteal**
Force		
Noforce		

- **Abhängigkeit zur Sperrverwaltung**

  Log-Granulat muß kleiner oder gleich dem Sperrgranulat sein!

  Beispiel:

  Sperren auf Satzebene,

  Before- bzw. *After-Images* auf Seitenebene

  ➥ Undo (Redo) einer Änderung kann parallel durchgeführte Änderungen derselben Seite überschreiben *(lost update)*

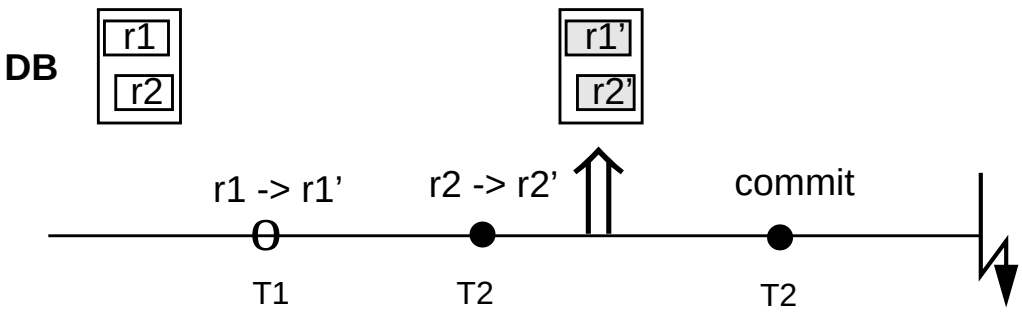

Commit-Behandlung

- **Änderungen einer TA sind vor Commit zu sichern**

- Andere TA dürfen Änderungen erst sehen, wenn Durchkommen der ändernden TA gewährleistet ist
  (Problem des rekursiven Zurücksetzens)

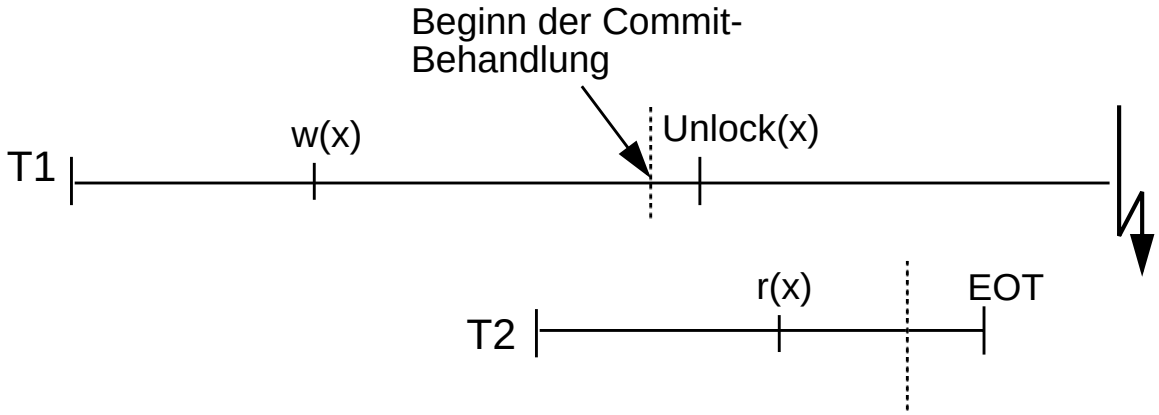

- ***Zweiphasige Commit-Bearbeitung***

  Phase 1: Wiederholbarkeit der TA sichern

  - ggf. noch Änderungen sichern
  - Commit-Satz auf Log schreiben

  Phase 2: Änderungen sichtbarmachen (Freigabe der Sperren)

  Benutzer kann nach Phase 1 vom erfolgreichen Ende der TA informiert werden (Ausgabenachricht)

- **Beispiel: Commit-Behandlung bei Force, Steal:**

  1. Before-Images auf Log schreiben
  2. Force der geänderten DB-Seiten
  3. After-Images (für Archiv-Log) und Commit-Satz schreiben

  bei NoForce lediglich 3.) für erste Commit-Phase notwendig

Gruppen-Commit

- **Log-Datei ist potentieller Leistungsengpaß**
  - pro Änderungstransaktion wenigstens 1 Log-E/A
  - max. ca. 250 sequentielle Schreibvorgänge pro Sekunde (1 Platte)

- **Gruppen-Commit:**
  gemeinsames Schreiben der Log-Daten von mehreren TA
  - Pufferung der Log-Daten in Log-Puffer (1 oder mehrere Seiten)
  - Voraussetzung: Eintrags-Logging
  - Ausschreiben des Log-Puffers erfolgt, wenn er voll ist bzw. Timer abläuft
  - nur geringe Commit-Verzögerung

- **Gruppen-Commit**
  erlaubt Reduktion auf 0.1 - 0.2 Log-E/As pro TA
  - Einsparung an CPU-Overhead für E/A reduziert CPU-Wartezeiten
  - dynamische Festsetzung des Timer-Wertes durch DBVS wünschenswert

  ➥ Durchsatzverbesserung v.a. bei Log-Engpaß oder hoher CPU-Auslastung

Vergleich verschiedener Commit-Verfahren

- **Standard-2PC:**

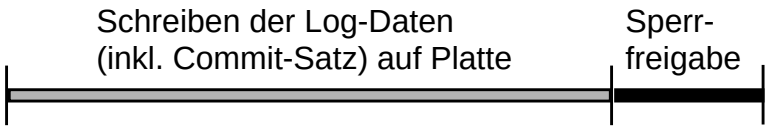

- **Gruppen-Commit:**

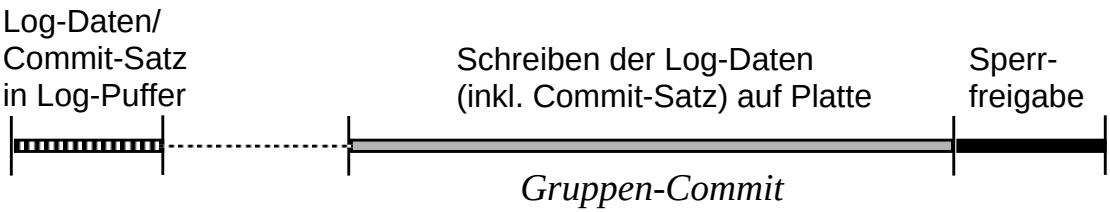

- **Weitere Optimierungsmöglichkeit: *Prä-Commit***
  - Sperren bereits freigeben, wenn Commit-Satz im Log-Puffer steht (vor Schreiben auf Log-Platte)
  - TA kann nur noch durch Systemfehler scheitern
  - In diesem Fall scheitern auch alle ‚abhängigen' TA, die ungesicherte Änderungen aufgrund der vorzeitigen Sperrfreigabe gesehen haben

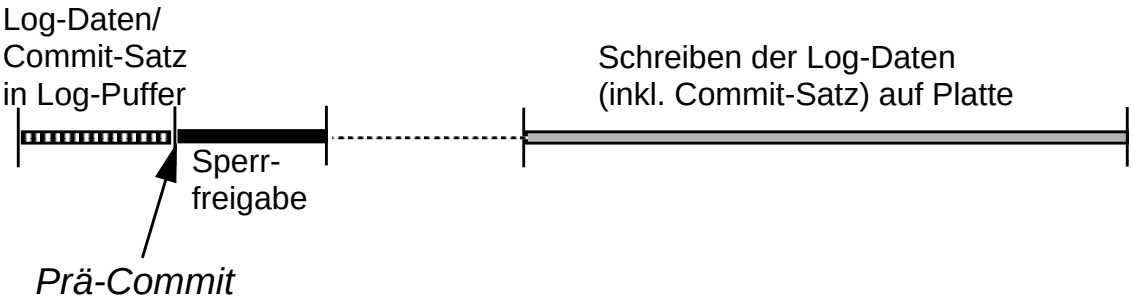

- In allen drei Verfahren wird der Benutzer erst nach Schreiben des Commit-Satzes auf Platte vom TA-Ende informiert

Sicherungspunkte (*Checkpoints*)

- **Sicherungspunkt: Maßnahme zur Begrenzung des Redo-Aufwandes nach Systemfehlern (NoForce)**

- Ohne Sicherungspunkte müßten potentiell alle Änderungen seit Start des DBVS wiederholt werden

- **Besonders kritisch: Hot-Spot-Seiten**

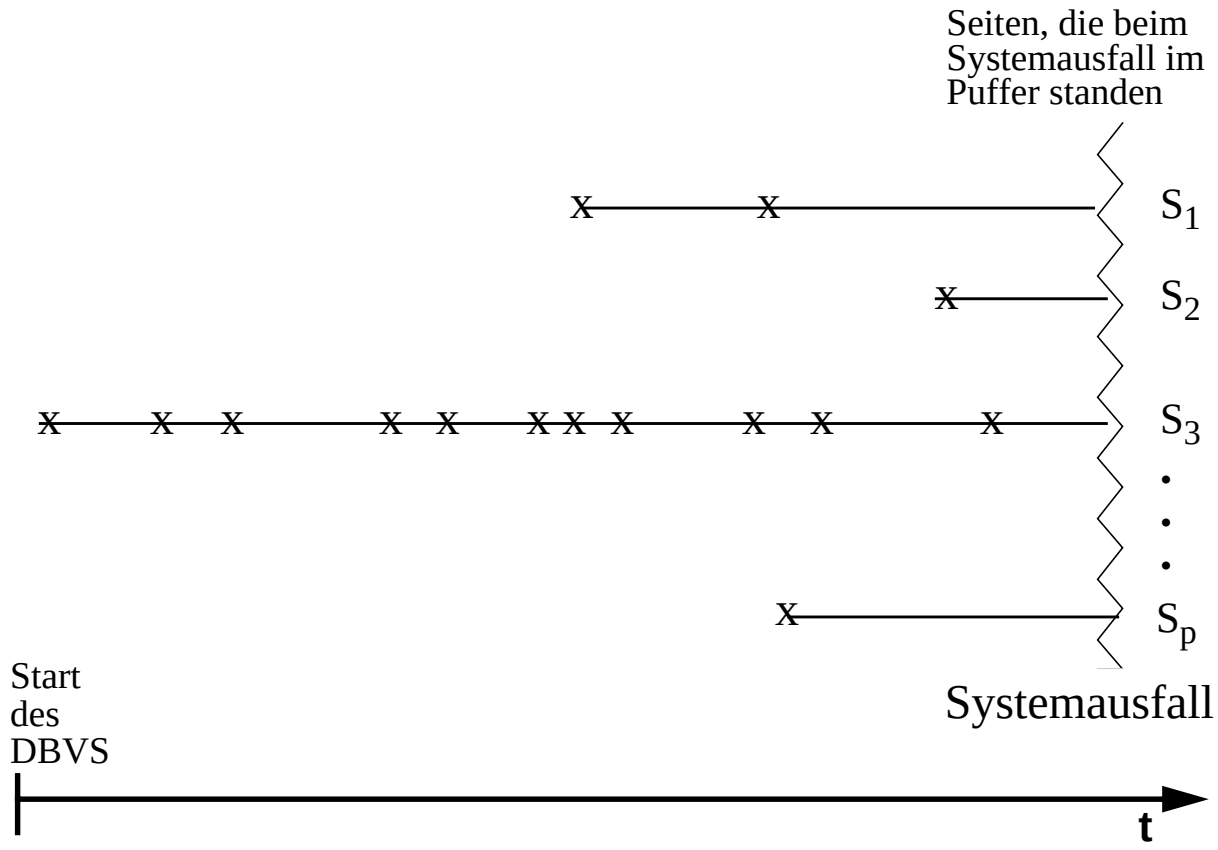

- **Log-Datei**
  - BEGIN_CHKPT-Satz
  - Sicherungspunkt-Informationen, u. a. Liste der aktiven TA
  - END_CHKPT-Satz

- Log-Adresse des letzten Sicherungspunkt-Satzes wird in spezieller Restart-Datei geführt

Arten von Sicherungspunkten

- **Direkte Sicherungspunkte**
  - Alle geänderten Seiten im DB-Puffer werden in die permanente DB eingebracht
  - Redo-Recovery beginnt bei letztem Sicherungspunkt
  - Nachteil: lange ‚Totzeit' des Systems, da während des Sicherungspunktes keine Änderungen durchgeführt werden können
  - Problem wird durch große Hauptspeicher verstärkt
  - *Transaktionskonsistente* oder *aktionskonsistente* Sicherungspunkte

- **Indirekte/Unscharfe Sicherungspunkte (Fuzzy Checkpoints)**
  - kein Hinauszwingen geänderter Seiten
  - Nur Statusinformationen (Pufferbelegung, Menge aktiver TA, offene Dateien etc.) werden in die Log-Datei geschrieben
  - sehr geringer Sicherungspunkt-Aufwand
  - Redo-Informationen vor letztem Sicherungspunkt sind i. allg. noch zu berücksichtigen
  - Sonderbehandlung von Hot-Spot-Seiten

- **Sicherungspunkte und Einbringverfahren**
  - **Atomic**: Zustand der permanenten DB beim Crash entspricht dem zum Zeitpunkt des letzten erfolgreichen Sicherungspunktes
  - **Non-Atomic**: Zustand der permanenten DB enthält alle ausgeschriebenen (eingebrachten) Änderungen bis zum Crash

Transaktionsorientierte Sicherungspunkte

- **Force kann als spezieller Sicherungspunkt-Typ aufgefaßt werden:**
  nur Seiten einer TA werden ausgeschrieben

- Sicherungspunkt bezieht sich immer auf genau eine TA
  TOC = Transaction-Oriented Checkpoint ≡ Force

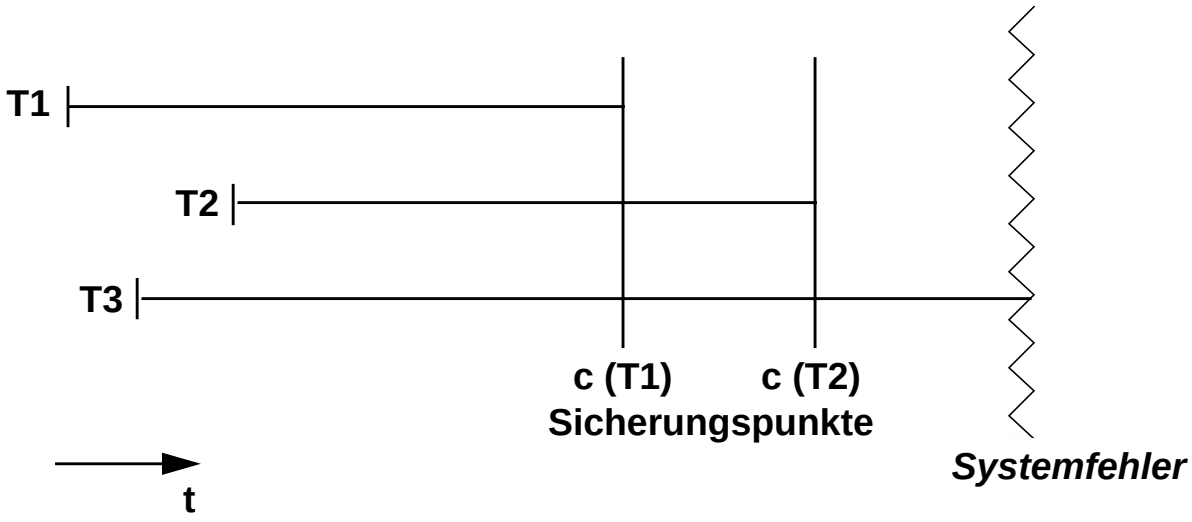

- **Eigenschaften**
  - EOT-Behandlung erzwingt das Ausschreiben aller geänderten Seiten der TA aus dem DB-Puffer
    - Übernahme aller Änderungen in die DB
    - Vermerk in Log-Datei
  - Nur Atomic ermöglicht atomares Einbringen mehrerer Seiten

  ➥ Zumindest bei direktem Einbringen der Seiten ist Undo-Recovery vorzusehen (Steal)

- **Abhängigkeit: Non-Atomic, Force => Steal**

Transaktionskonsistente Sicherungspunkte

- Sicherungspunkt bezieht sich immer auf alle TA
  TCC = Transaction-Consistent Checkpoints (logisch konsistent)

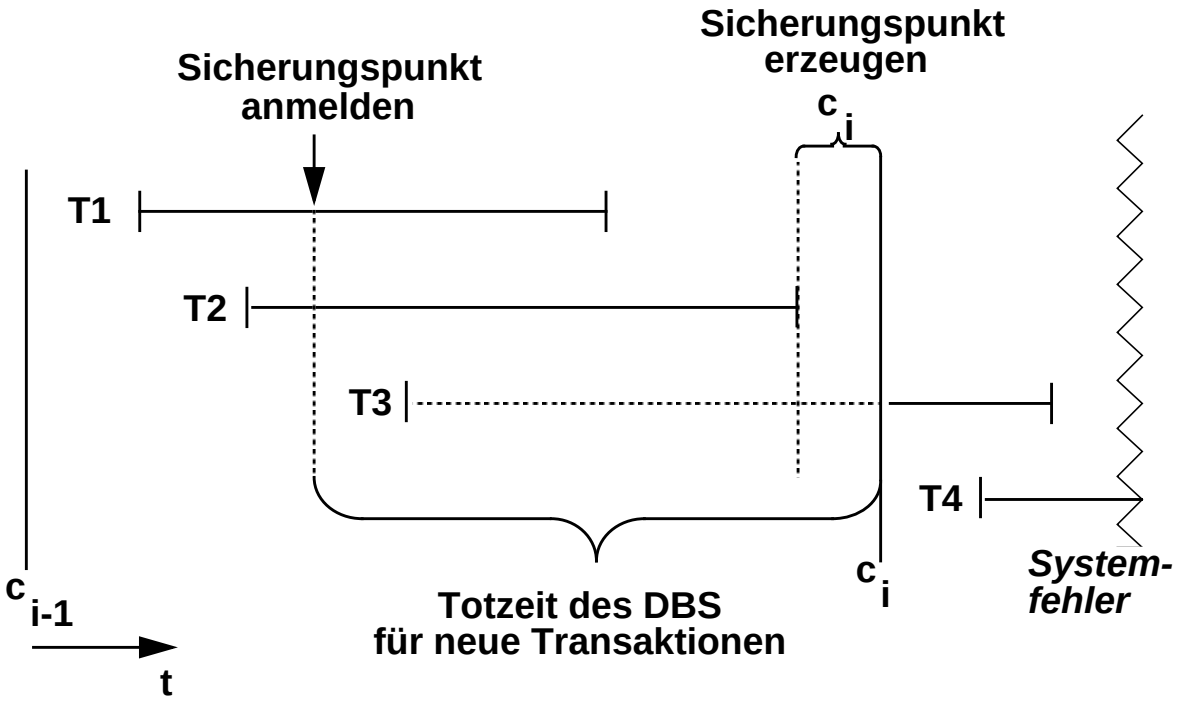

- **Eigenschaften**
  - Ausschreiben ist bis zum Ende aller aktiven Änderungs-TA zu verzögern
  - Neue Änderungs-TA müssen warten, bis Erzeugung des Sicherungspunkts beendet ist
  - **Crash-Recovery startet bei letztem Sicherungspunkt**

Aktionskonsistente Sicherungspunkte

- Sicherungspunkt bezieht sich immer auf alle TA
  ACC = Action Consistent Checkpoints (speicherkonsistent)

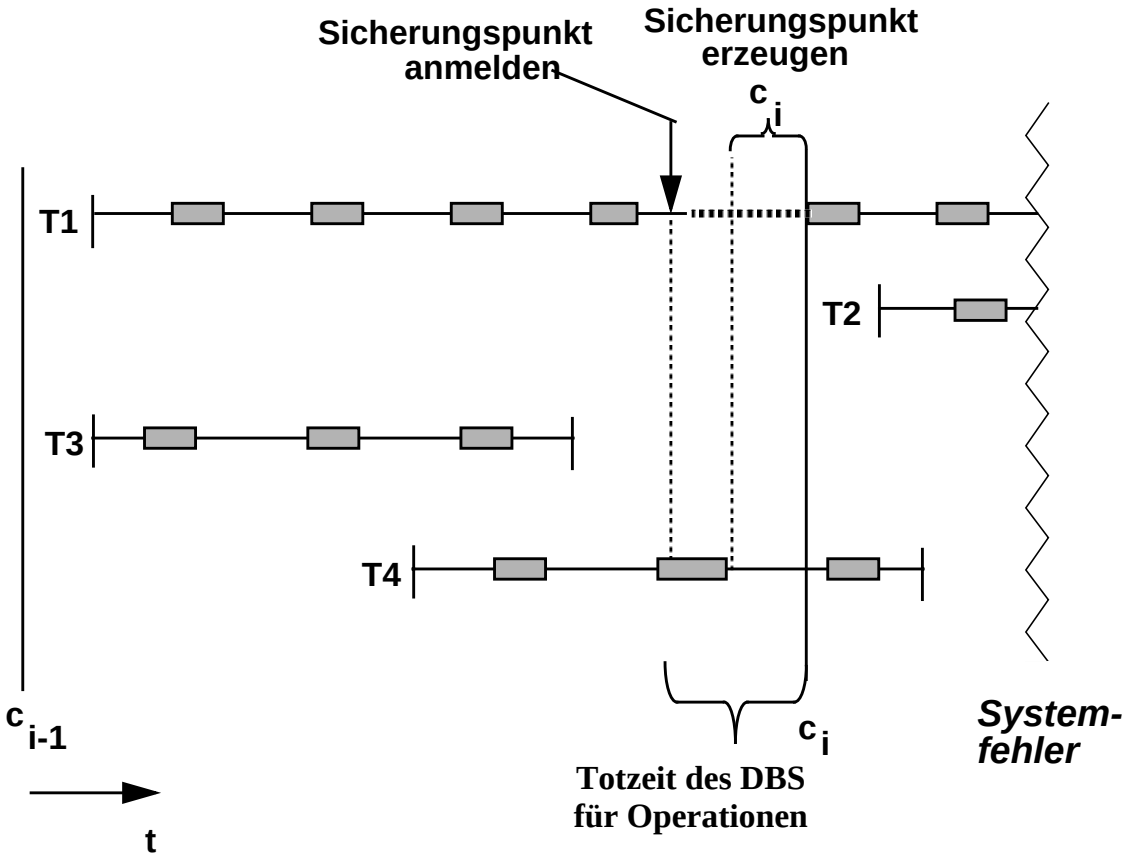

- **Eigenschaften**
  - keine Änderungsanweisungen während des Sicherungspunktes
  - geringere Totzeiten als bei TCC,
    dafür Verminderung der Qualität der Sicherungspunkte
  - Crash-Recovery wird **nicht durch letzten Sicherungspunkt begrenzt**

- **Abhängigkeit: ACC => Steal**

Unscharfe Sicherungspunkte
(Fuzzy Checkpoints)

- **DB auf Platte bleibt ‚fuzzy', nicht aktionskonsistent**

  ➥ nur bei Update-in-Place (Non-Atomic) relevant

- **Problem: Bestimmung der Log-Position,** an der **Redo-Recovery** beginnen muß
  - Pufferverwalter vermerkt sich zu jeder geänderten Seite StartLSN, d. h. Log-Satz-Adresse der ersten Änderung seit Einlesen von Platte
  - Redo-Recovery nach Crash beginnt bei MinDirtyPageLSN (= MIN(StartLSN))

- **Sicherungspunkt-Information:**
  MinDirtyPageLSN, Liste der aktiven TA und ihrer StartLSNs, . . .

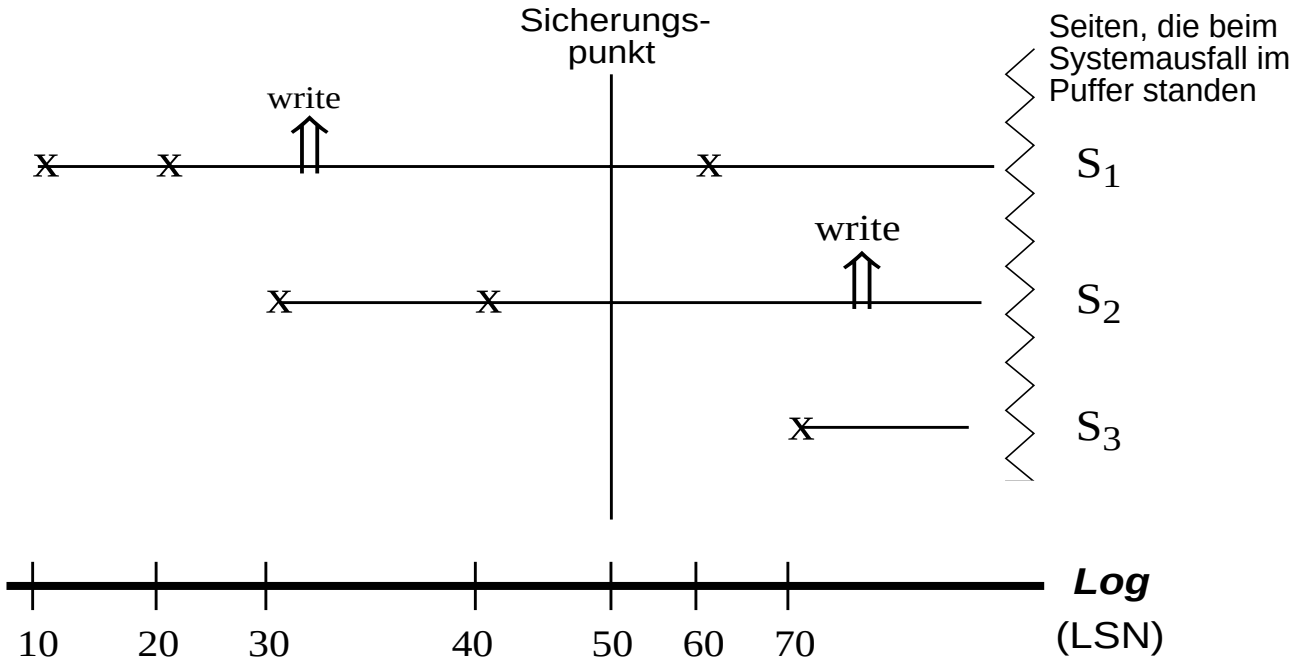

- **Geänderte Seiten werden asynchron ausgeschrieben**
  - ggf. Kopie der Seite anlegen (für Hot-Spot-Seiten)
  - Seite ausschreiben
  - StartLSN anpassen / zurücksetzen

Klassifikation von DB-Recovery-Verfahren

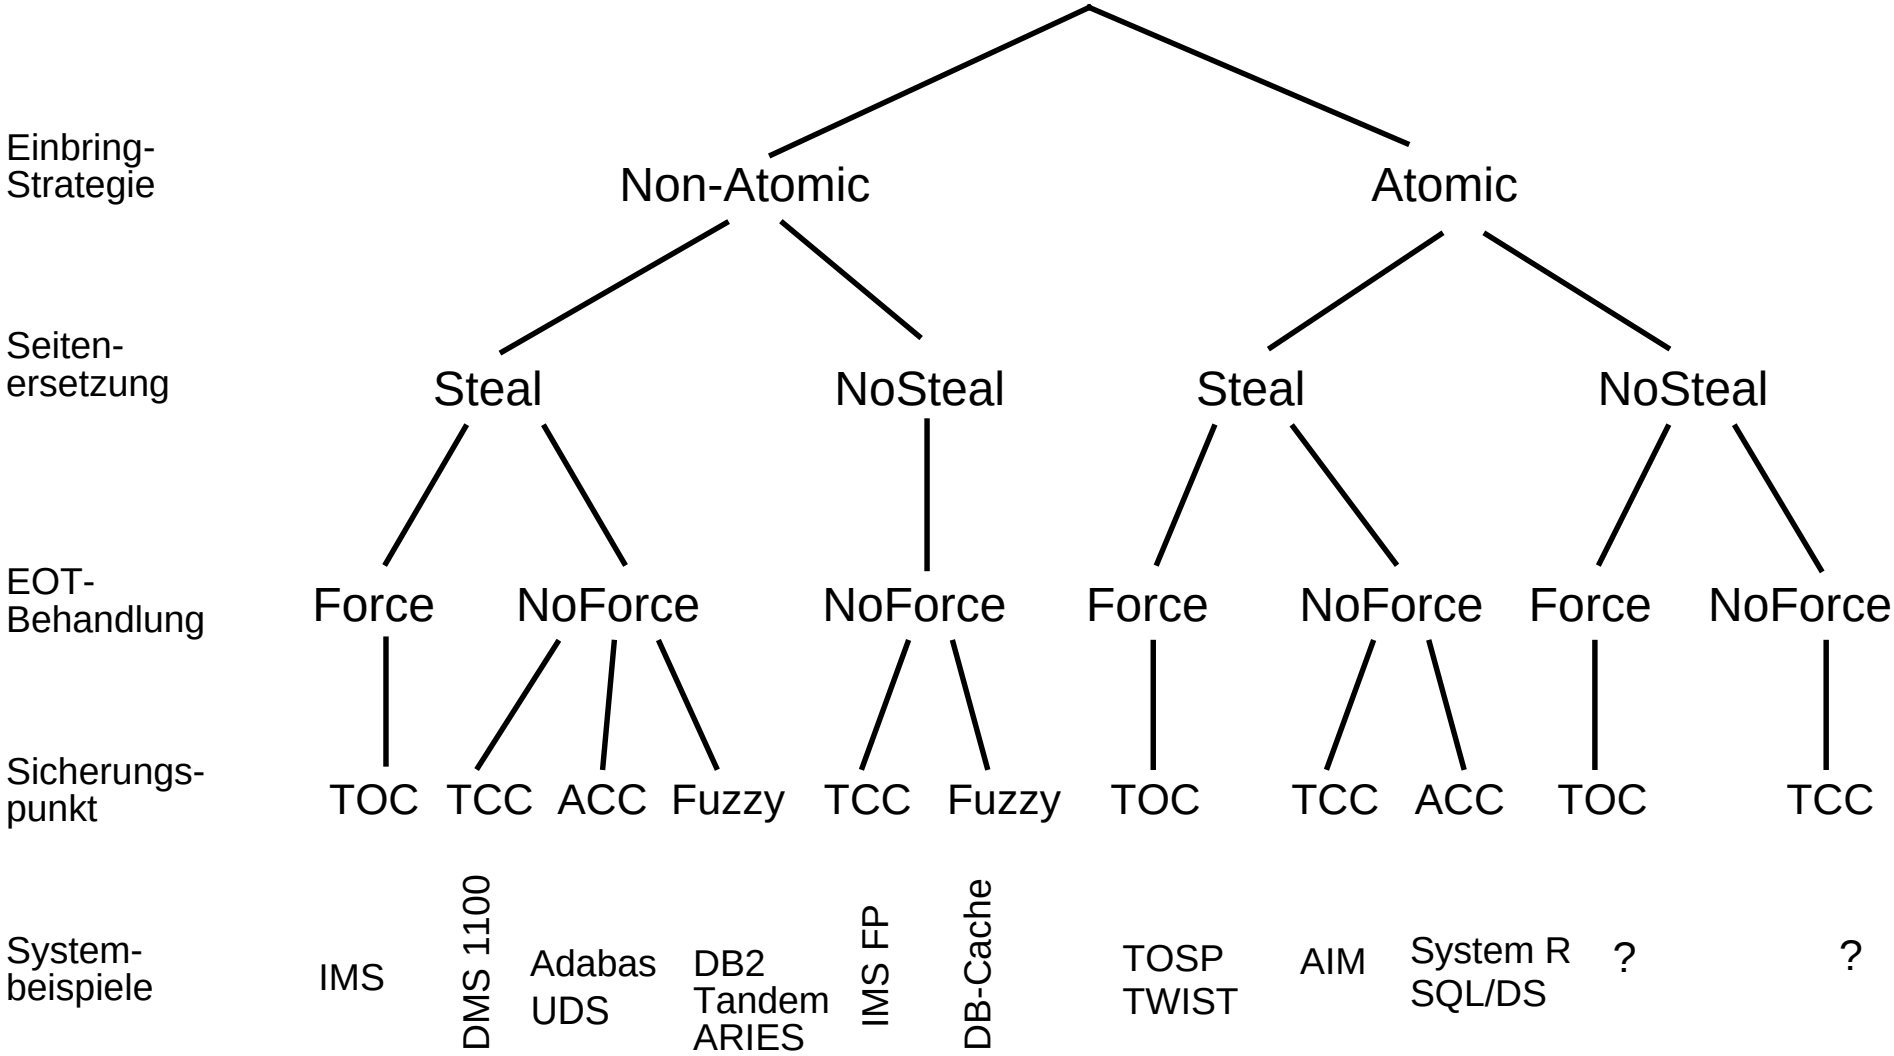

Test zur Fehlerbehandlung

Situation im Fehlerfall (Crash)	Datenseite bereits in die Datenbank eingebracht	Log-Satz bereits in die Log-Datei geschrieben	Transaktion	
			nicht beendet ggf. Zurücksetzung	abgeschlossen ggf. Wiederholung
1.	Nein	Nein		
2.	Nein	Ja		
3.	Ja	Nein		
4.	Ja	Ja		

Mögliche Antworten:

a) Tue überhaupt nichts

b) Benutze die UNDO-Information und setze zurück

c) Benutze die REDO-Information und wiederhole

d) WAL-Prinzip verhindert diese Situation

e) Zwei-Phasen-Commit-Protokoll verhindert diese Situation

Nutzung von LSNs

- **Seitenkopf von DB-Seiten enthält Seiten-LSN**
  - Die „Herausforderung“ besteht darin, beim Restart zu entscheiden, ob für die Seite Recovery-Maßnahmen anzuwenden sind oder nicht (ob man den alten oder bereits den geänderten Zustand auf dem Externspeicher vorgefunden hat)
  - Dazu wird auf jeder Seite B die LSN des jüngsten dieser Seite betreffenden Log-Eintrags L gespeichert (PageLSN (B) := LSN (L))

- **Entscheidungsprozedur:**
  Restart hat eine Redo- und eine Undo-Phase
  - **Redo *ist nur erforderlich, wenn***

    Seiten-LSN < LSN des Redo-Log-Satzes
  - **Undo *ist nur erforderlich, wenn***

    Seiten-LSN ≥ LSN des Undo-Log-Satzes

- **Vereinfachte Anwendung: Seitensperren**

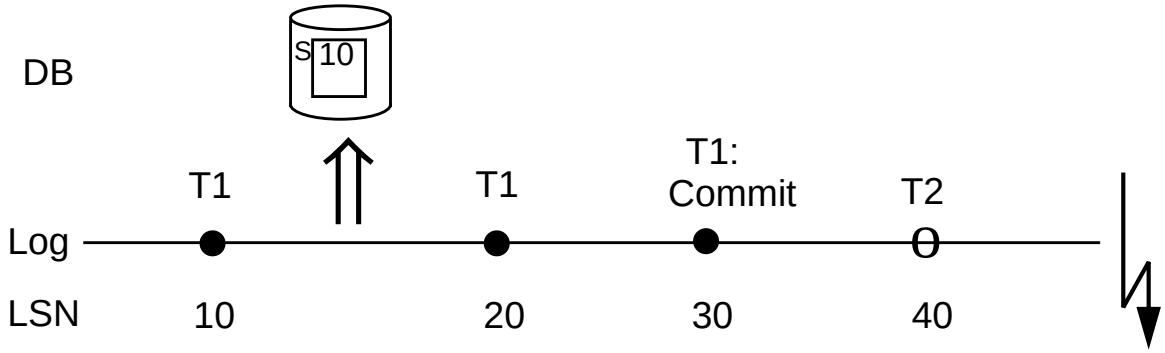

Redo von T1: S(10) =T1(10) : –
S(10) < T1(20) : Redo, S(20)

Undo von T2: S(20) < T2(40) : –

➥ Seiten-LSN wird bei Redo aktualisiert (wächst monoton)

Nutzung von LSNs (2)

- **Vereinfachte Anwendung: Seitensperren**

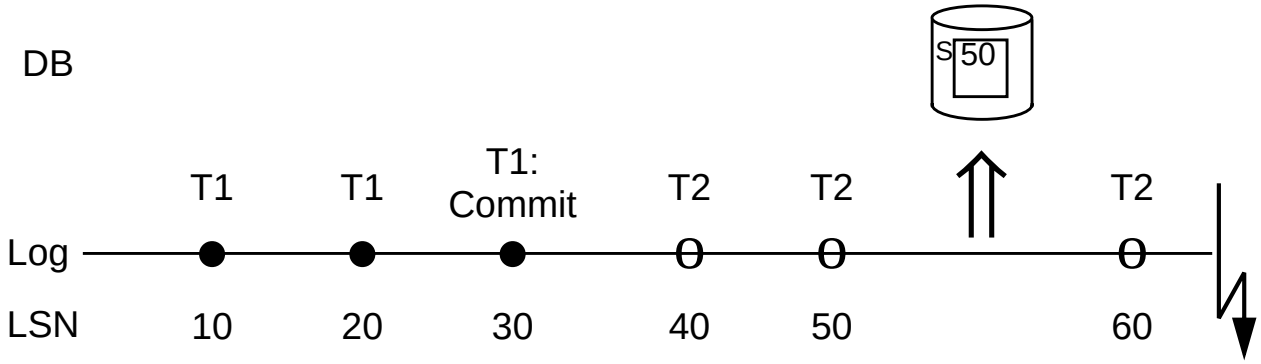

Redo von T1: S(50) > T1(10) : –

S(50) > T1(20) : –

Undo von T2: S(50) < T2(60) : –

S(50) ≥ T2(50) : Undo

S(50) ≥ T2(40) : Undo

➥ Was passiert bei Crash im Restart?

- **Undo erfolgt in LIFO-Reihenfolge**
  - Undos müssen speziell behandelt werden, so daß wiederholte Ausführung zum gleichen Ergebnis führt (Idempotenz)
  - Zustandslogging und LIFO-Reihenfolge gewährleisten Idempotenz

  ➥ Allgemeinere Lösung:
  Kompensation von Undo wird später eingeführt

Crash-Recovery

- **Ziel:** Herstellung des jüngsten transaktionskonsistenten DB-Zustandes aus permanenter DB und temporärer Log-Datei

- **Bei Update-in-Place (Non-Atomic):**
  - Zustand der permanenten DB nach Crash unvorhersehbar („chaotisch“)

    ➥ nur physische Logging-Verfahren anwendbar
  - Ein Block der permanenten DB ist entweder
    - aktuell oder
    - veraltet (NoForce) ➥ Redo oder
    - ‚schmutzig‘ (Steal) ➥ Undo

- **Bei Atomic:**
  - Permanente DB entspricht Zustand des letzten erfolgreichen Einbringens (Sicherungspunkt)
  - zumindest aktionskonsistent

    ➥ DML-Befehle ausführbar (logisches Logging)
  - **Force:** kein Redo
  - **NoForce:**

    a) transaktionskonsistentes Einbringen

    ➥ Redo, jedoch kein Undo

    b) aktionskonsistentes Einbringen

    ➥ Undo + Redo

Allgemeine Restart-Prozedur

- **Temporäre Log-Datei wird 3-mal gelesen**

1. ***Analyse-Phase*** *(vom letzten Sicherungspunkt bis zum Log-Ende):*
   Bestimmung von ***Gewinner-*** und ***Verlierer-TA*** sowie der Seiten, die von ihnen geändert wurden

2. ***Redo-Phase:***
   Vorwärtslesen des Log: Startpunkt abhängig vom Sicherungspunkt-Typ:
   Selektives Redo bei Seitensperren (redo winners) oder
   vollständiges Redo (repeating history) möglich

3. ***Undo-Phase:***
   Rücksetzen der Verlierer-TA durch Rückwärtslesen des Logs bis zum BOT-Satz der ältesten Verlierer-TA

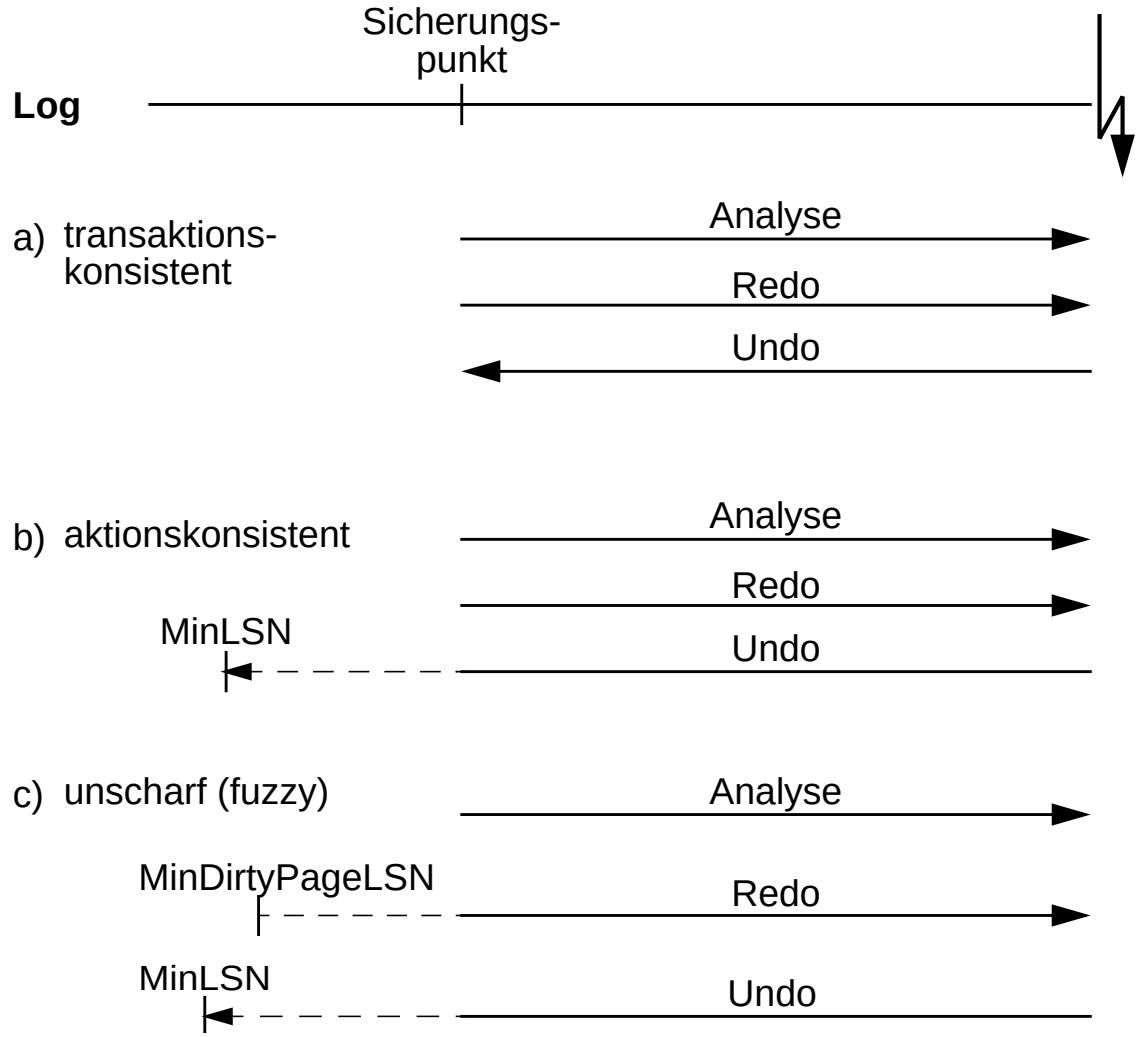

Restart-Prozedur bei Update-in-Place

- **Attribute: Non-Atomic, Steal, NoForce, Fuzzy Checkpoint**

1. ***Analyse-Phase*** *(vom letzten Sicherungspunkt bis zum Log-Ende):*

2. ***Redo-Phase:***
   Startpunkt abhängig vom Sicherungspunkt-Typ: hier MinDirtyPageLSN
   Selektives Redo: nur Wiederholung der Änderungen der Gewinner-TA

3. ***Undo-Phase:***
   Rücksetzen der Verlierer-TA bis MinLSN

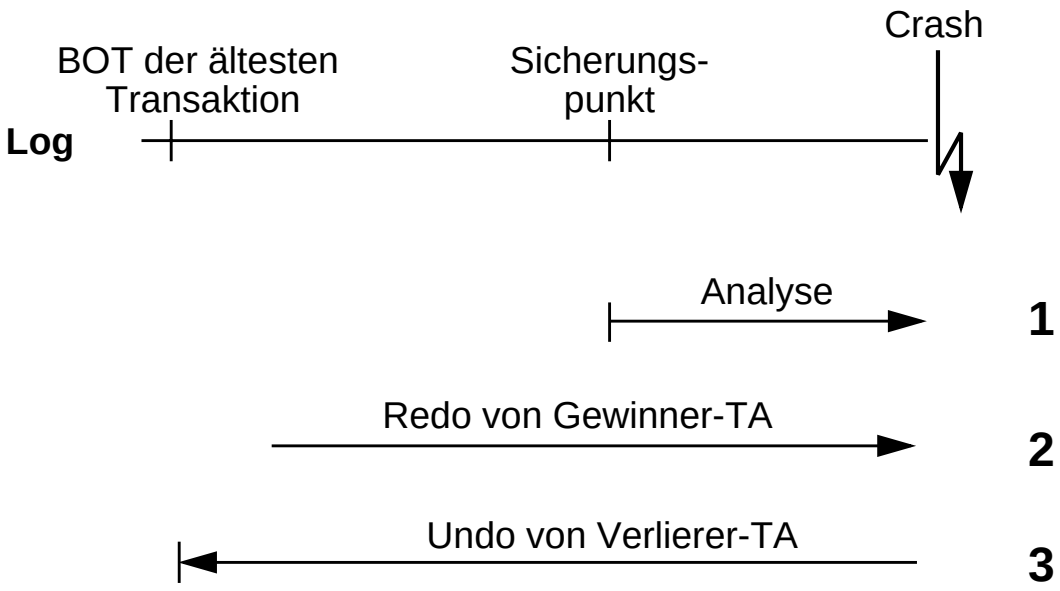

- **Aufwandsaspekte**
  - Für Schritt 2 und 3 sind betroffene DB-Seiten einzulesen
  - LSN der Seiten zeigen, ob Log-Informationen anzuwenden sind
  - Am Ende sind alle geänderten Seiten wieder auszuschreiben, bzw. es wird ein Sicherungspunkt erzeugt

Redo-Recovery

- **Physiologisches und physisches Logging:**
  Notwendigkeit einer Redo-Aktion für Log-Satz L wird über PageLSN der betroffenen Seite B angezeigt

```
if (B nicht gepuffert) then (lies B in den Hauptspeicher ein);
if     LSN (L) > PageLSN (B) then do;
            Redo (Änderung aus L);
            PageLSN (B) := LSN (L);
end;
```

- **Wiederholte Anwendung des Log-Satzes**
  - (z.B. nach mehrfachen Fehlern) erhält Korrektheit (Redo-Idempotenz
  - Wie verläuft die Recovery bei Crashs während des Restart?

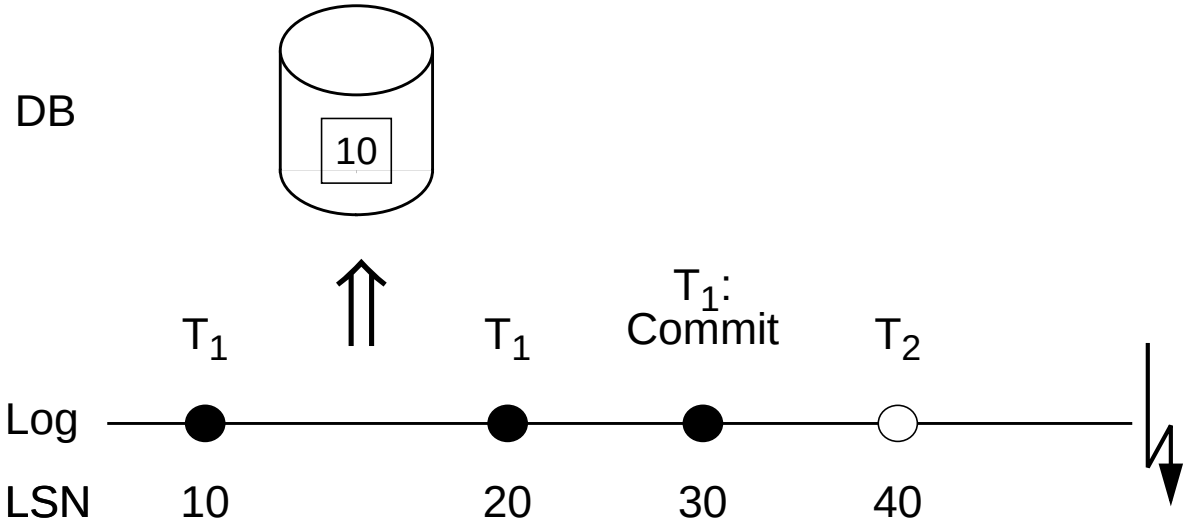

Restart – Beispiel

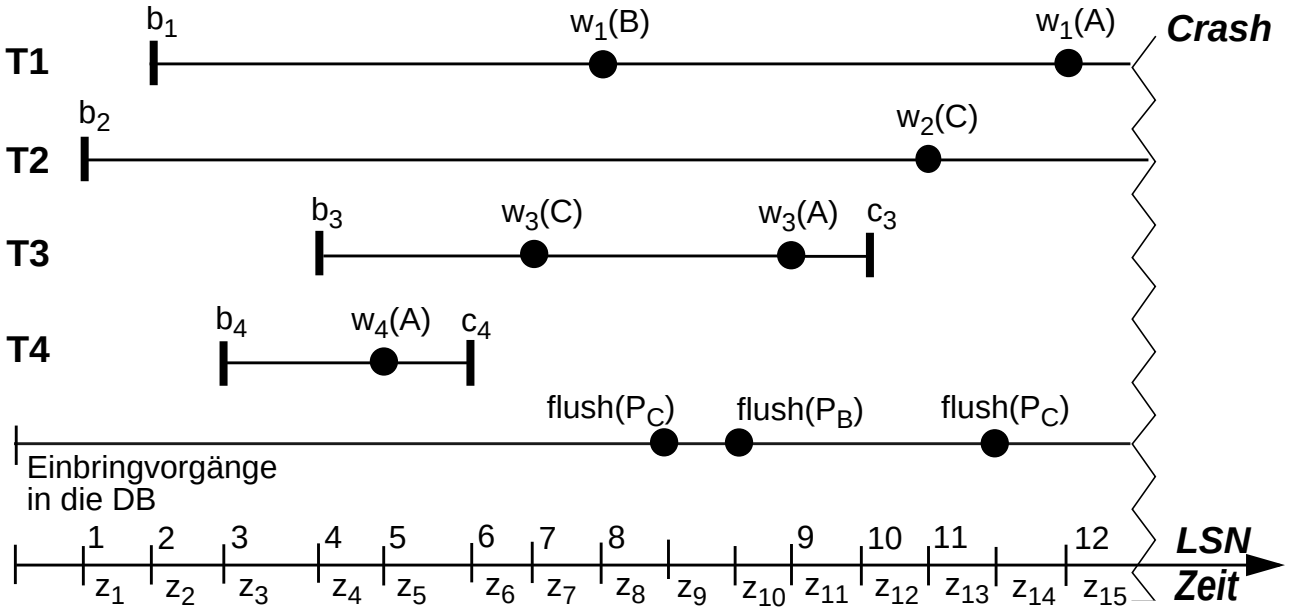

Zeit	Aktion	Änderung im DB-Puffer (Seite, LSN)	Änderung in der DB (Seite, LSN)	Log-Puffer: (LSN, TAID, Log-Info, PrevLSN)	Log-Datei: zugefügte Einträge (LSNs)
z_1	b_2			1, T_2, BOT, 0	
z_2	b_1			2, T_1, BOT, 0	
z_3	b_4			3, T_4, BOT, 0	
z_4	b_3			4, T_3, BOT, 0	
z_5	$w_4(A)$	P_A, 5		5, T_4, U/R(A), 3	
z_6	c_4			6, T_4, EOT, 5	1, 2, 3, 4, 5, 6
z_7	$w_3(C)$	P_C, 7		7, T_3, U/R(C), 4	
z_8	$w_1(B)$	P_B, 8		8, T_1, U/R(B), 2	
z_9	flush(P_C)		P_C, 7		7, 8
z_{10}	flush(P_B)		P_B, 8		
z_{11}	$w_3(A)$	P_A, 9		9, T_3, U/R(A), 7	
z_{12}	c_3			10, T_3, EOT, 9	9, 10
z_{13}	$w_2(C)$	P_C, 11		11, T_2, U/R(C), 1	
z_{14}	flush(P_C)		P_C, 11		11
z_{15}	$w_1(A)$	P_A, 12		12, T_1, U/R(A), 8	

Restart – Beispiel (2)

Annahme: Zu Beginn seien alle Seiten-LSNs 0[1]

Analyse-Phase: Gewinner-TA: T_3, T_4

Verlierer-TA: T_1, T_2

Relevante Seiten: P_A, P_B, P_C

Im Restart-Beispiel ändert nie mehr als eine TA gleichzeitig in einer Seite, was einem Einsatz von Seitensperren entspricht. Deshalb ist **Selektives Redo**, also nur das Redo der Gewinner-TA, ausreichend.

Redo-Phase: Log-Sätze für T_3 und T_4 vorwärts prüfen

TA	Seite	Seiten-LSN	Log-Satz-LSN	Aktion
T_4	P_A			
T_3	P_C			
T_3	P_A			

(Redo nur, wenn Seiten-LSN $<$ Log-Satz-LSN)

➥ Seiten-LSNs wachsen monoton

Undo-Phase: Log-Sätze für T_1 und T_2 rückwärts prüfen

TA	Seite	Seiten-LSN	Log-Satz-LSN	Aktion
T_1	P_A	9	12	Kein Undo, ohnehin nicht in Log-Datei
T_2	P_C			
T_1	P_B			

(Undo nur, wenn Seiten-LSN $\geq$ Log-Satz-LSN)

➥ Wegen der Seitensperren gibt es auf einer Seite keine Interferenz zwischen Redo- und Undo-Aktionen. Zustands-Logging sichert Undo-Idempotenz!

1. „This we know. All things are connected.” (Chief Seattle)

Probleme bei LSN-Verwendung für Undo

- **Problem 1: Rücksetzungen von TA**
  Bisherige LSN-Verwendung führt zu Problemen in der Undo-Phase bei vorherigem Rollback

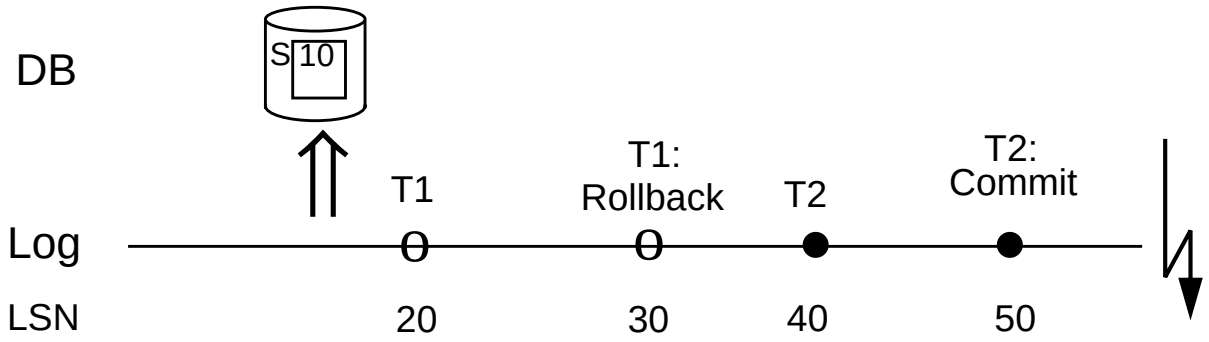

Redo von T2:

S(10) < T2(40) : Redo, S(40)

Undo von T1:

S(40) > T1(20) : Undo, Fehler

- **Bemerkung:**
  - Es wird Änderung 20 zurückgesetzt, obwohl sie gar nicht in der Seite S vorliegt
  - Zuweisung von LSN = 20 zu S verletzt Monotonieforderung für Seiten-LSNs
    (Was passiert bei Crash nach Zuweisung?)

Probleme bei LSN-Verwendung für Undo (2)

- **Problem 2: Satzsperren**
  - Ausgangszustand der Seite S

S

LSN 5
a
b
c

  - T1 und T2 ändern gleichzeitig in Seite

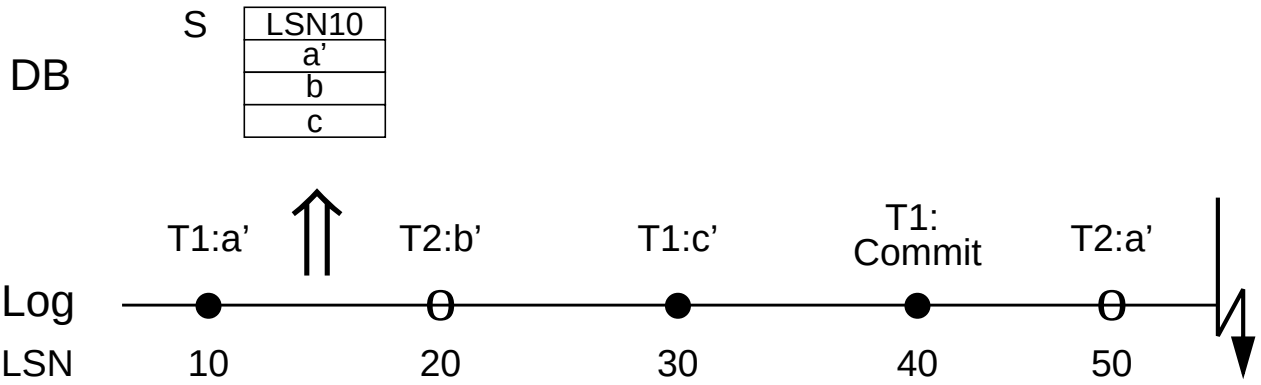

Redo von T1:

S(10) ≥ T1(10) : kein Redo

S(10) < T1(30) : Redo, S(30)

Undo von T2 (LIFO):

S(30) < T2(50) : kein Undo

S(30) > T2(20) : Undo, Fehler!

➥ **Allgemeinere Behandlung des Undo erforderlich !**

Fehlertoleranz des Restart

- **Forderung: Idempotenz des Restart**

  Undo(Undo(. . . (Undo(A)) . . .)) = Undo(A)

  Redo(Redo(. . . (Redo(A)) . . .)) = Redo(A)

  - Idempotenz der Redo-Phase wird dadurch erreicht, daß LSN des Log-Satzes, für den ein Redo tatsächlich ausgeführt wird, in die Seite eingetragen wird.
    Redo-Operationen erfordern **keine zusätzliche** Protokollierung.
  - Seiten-LSNs müssen monoton wachsen. Deshalb kann in der Undo-Phase nicht entsprechend verfahren werden.
  - Gewährleistung der Idempotenz der Undo-Phase erfordert ein neues Konzept: CLR = Compensation Log Record

- **Logging**

  - Änderungen der DB sind durch Log-Einträge abzusichern - und zwar im Normalbetrieb und beim Restart!
  - Was passiert im Fall eines Crash beim Undo?
    Aktionen 1-3 sollen zurückgesetzt werden: I’ ist CLR für I und I’’ ist CLR für I’

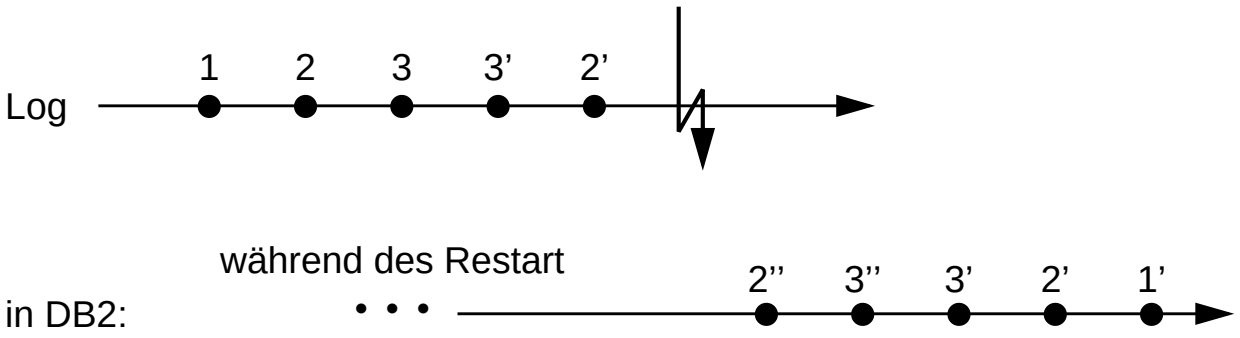

➥ Problem von kompensierenden Kompensationen!

➥ Crash bei Restart!?

Compensation Log Records (CLR)

- **Optimierte Lösung**
  - Einsatz von CLRs bei allen Undo-Operationen: Rollback und Undo-Phase
  - in der Redo-Phase: **Vollständiges Redo** von Gewinnern und Verlierern („repeating history“)

- **Schematische Darstellung der Log-Datei**

- nach Crash:

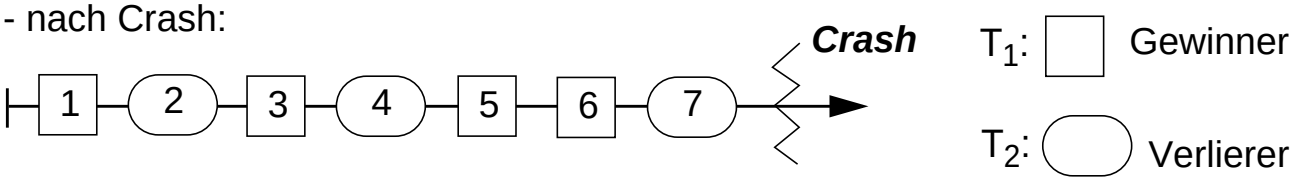

- nach vollständigem Restart:

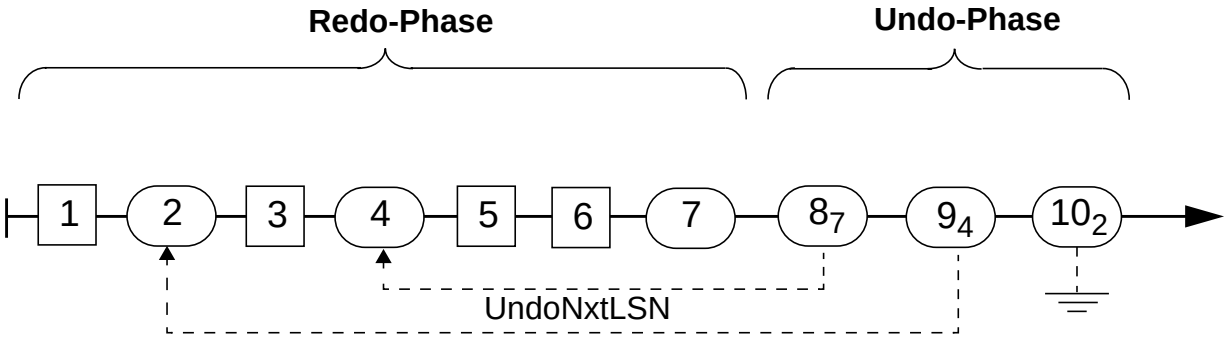

  - Die Redo-Information eines CLR entspricht der während der Undo-Phase ausgeführten Undo-Operation
  - CLR-Sätze werden bei erneutem Restart benötigt (nach Crash beim Restart). Ihre Redo-Information wird während der **Redo-Phase** angewendet. Dabei werden Seiten-LSNs geschrieben.
    ➥ **Die Redo-Phase ist idempotent!**
  - CLRs benötigen keine Undo-Information, da sie während nachfolgender Undo-Phasen übersprungen werden (UndoNxtLSN)

CLR (2)

- **Detaillierung des Beispiels**
  - Alle Änderungen betreffen Seite S
  - Zustand nach Crash 1:

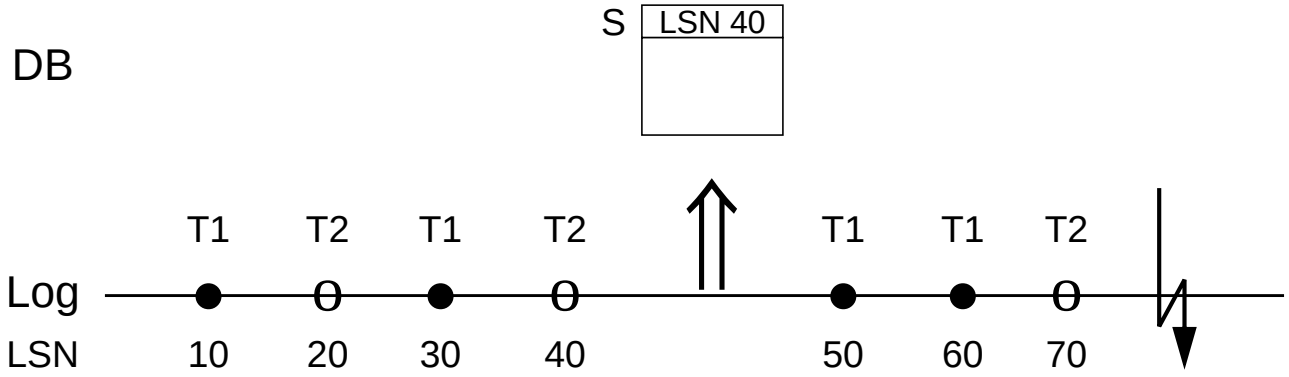

Repeating History:

S(40) >T1(10)	:	–
. . .		
S(40) ≥T2(40)	:	–
S(40) < T1(50)	:	Redo, S(50)
S(50) <T1(60)	:	Redo, S(60)
S(60) < T2(70)	:	Redo, S(70)

Undo von T2:

CLR(80)	:	Kompensieren von T2(70), S(80)

Schreiben von S in die DB (Flush S)

CLR(90)	:	Kompensieren von T2(40), S(90)

Crash

CLR (3)

- **Fortsetzung des Beispiels**
  - Zustand nach Crash 2:

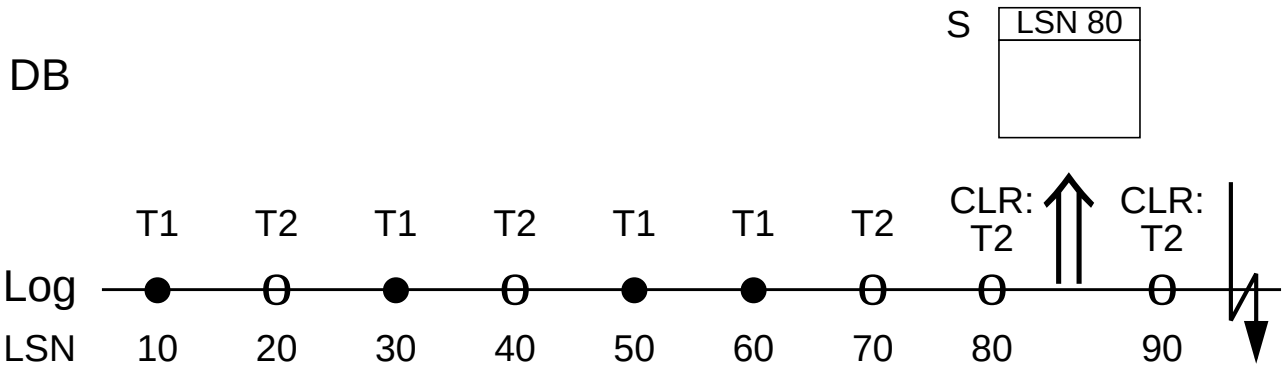

Repeating History:

S(80) >T1(10)	:	–
. . .		
S(80) > T2(70)	:	–
CLR(80)	:	–
CRL(90)	:	Kompensieren von T2(40), S(90)

Undo von T2:

CLR(100)	:	Kompensieren von T2(20), S(100)

Ende

Restart-Prozedur bei Update-in-Place

- **Attribute: Non-Atomic, Steal, NoForce, Fuzzy Checkpoint**

1. ***Analyse-Phase*** *(vom letzten Sicherungspunkt bis zum Log-Ende):*

2. ***Redo-Phase:***
   Startpunkt abhängig vom Sicherungspunkt-Typ: hier MinDirtyPageLSN
   Vollständiges Redo oder **Repeating History:** Wiederholung aller Änderungen (auch von Verlierer-TA), falls erforderlich

3. ***Undo-Phase:***
   Rücksetzen der Verlierer-TA bis MinLSN

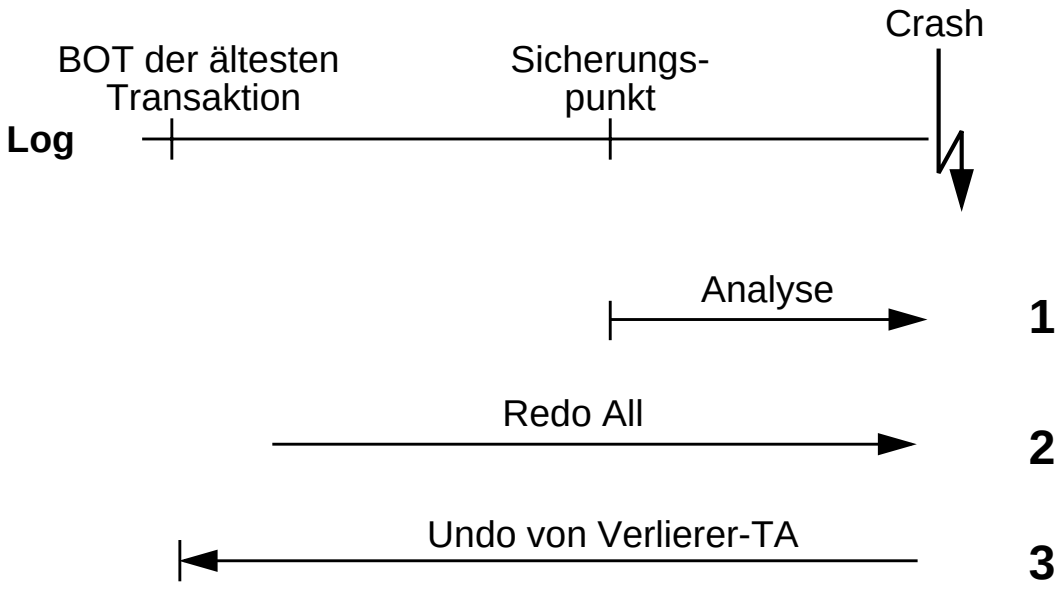

- **Umsetzung durch ARIES**[1]
  (Algorithm for Recovery and Isolation Exploiting Semantics)
  - entwickelt von C. Mohan et al. (IBM Almaden Research)
  - realisiert in einer Reihe von kommerziellen DBS

1. Mohan, C. et al.: A Transaction Recovery Method Supporting Fine-Granularity Locking and Partial Rollbacks Using Write-Ahead Logging, in ACM TODS 17:1, 1992, 94-162

Restart – Beispiel 2

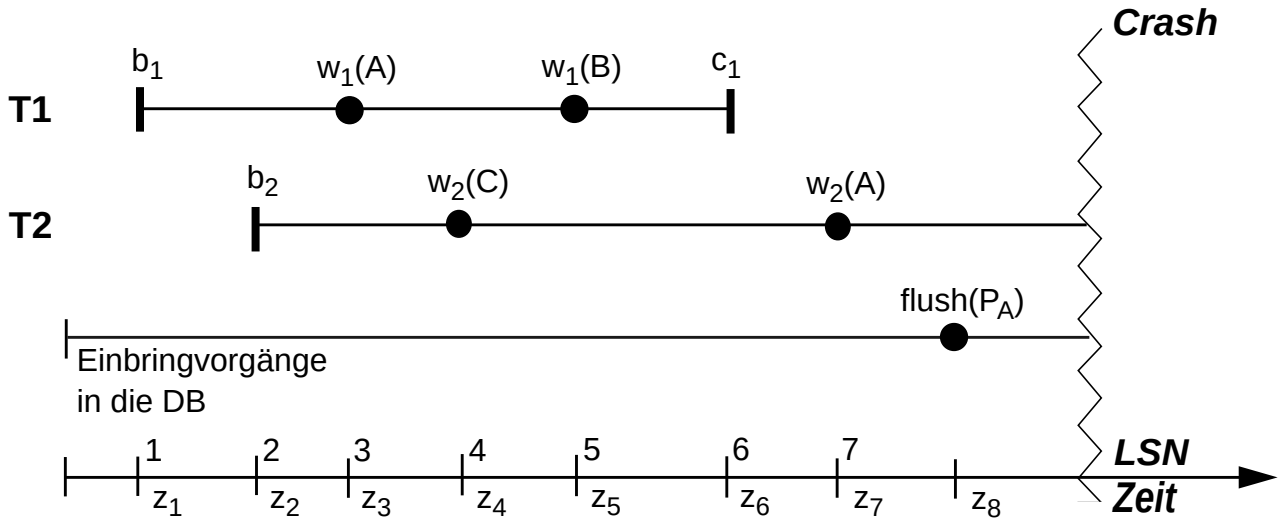

Zeit	Aktion	Änderung im DB-Puffer (Seite, LSN)	Änderung in der DB (Seite, LSN)	Log-Puffer: (LSN, TAID, Log-Info, PrevLSN)	Log-Datei: zugefügte Einträge (LSNs)
z_1	b_1			1, T_1, BOT, 0	
z_2	b_2			2, T_2, BOT, 0	
z_3	$w_1(A)$	P_A, 3		3, T_1, U/R(A), 1	
z_4	$w_2(C)$	P_C, 4		4, T_2, U/R(C), 2	
z_5	$w_1(B)$	P_B, 5		5, T_1, U/R(B), 3	
z_6	c_1			6, T_1, EOT, 5	1, 2, 3, 4, 5, 6
z_7	$w_2(A)$	P_A, 7		7, T_2, U/R(A), 4	
z_8	flush(P_A)		P_A, 7		7

Restart – Beispiel 2 (2)

Annahme: Zu Beginn seien alle Seiten-LSNs 0

Analyse-Phase : Gewinner-TA: T_1

Verlierer-TA: T_2

Relevante Seiten: P_A, P_B, P_C

Im Restart-Beispiel 2 wird **Vollständiges Redo** durchgeführt. Zur Gewährleistung der Idempotenz der Undo-Operationen wird für jede ausgeführte Undo-Operation ein CLR mit folgender Struktur angelegt:

[LSN, TAID, PageID, Redo, PrevLSN, UndoNextLSN]

Redo-Phase: Log-Sätze aller TA (T_1, T_2) vorwärts prüfen

TA	Seite	Seiten-LSN	Log-Satz-LSN	Aktion
T_1	P_A	7	3	Kein Redo
T_2	P_C	0 --> 4	4	Redo
T_1	P_B	0 --> 5	5	Redo
T_2	P_A	7	7	Kein Redo

(Redo nur, wenn Seiten-LSN < Log-Satz-LSN)

Undo-Phase: Log-Sätze der Verlierer-TA T_2 rückwärts unabhängig von Seiten-LSN prüfen.
Für jeden Log-Satz wird die zugehörige Undo-Operation durchgeführt und mit einem CLR in der Log-Datei vermerkt.

TA	Log-Satz-LSN	Aktion
T_2	7	Undo und lege CLR [8, T_2, P_A, U(A), 7, 4] an
T_2	4	Undo und lege CLR [9, T_2, P_C, U(C), 8, 2] an
T_2	2	Undo und lege CLR [10, T_2, _ , _ , 9, 0] an

Restart – Beispiel 2 (3)

Annahme: Crash während des Restart

Log-Datei nach Crash:

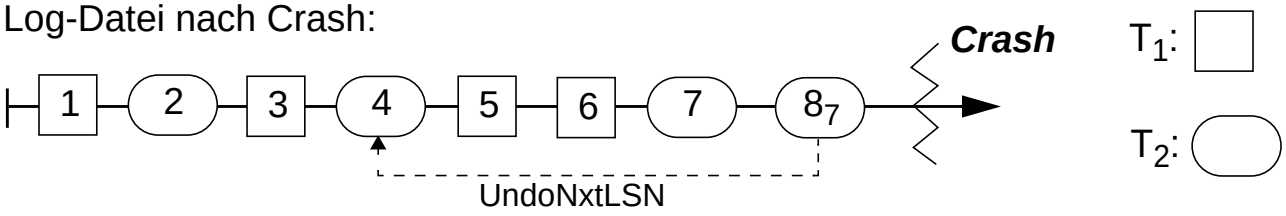

Analyse-Phase: dito

Redo-Phase: Log-Sätze aller TA (T_1, T_2) inkl. CLRs vorwärts prüfen.
Für jedes CLR wird jeweils Redo ausgeführt.

TA	Seite	Seiten-LSN	Log-Satz-LSN	Aktion
T_1	P_A	7	3	Kein Redo
T_2	P_C	4	4	Kein Redo
T_1	P_B	5	5	Kein Redo
T_2	P_A	7	7	Kein Redo
T_2	P_A			Redo: mit U(A) kompensiert

Undo-Phase: Log-Sätze der Verlierer-TA T_2 (inkl. CLRs) rückwärts unabhängig von Seiten-LSN prüfen.
Für jeden Log-Satz wird die zugehörige Undo-Operation durchgeführt und mit einem CLR in der Log-Datei vermerkt.

TA	Log-Satz-LSN	Aktion
T_2	8	UndoNxtLSN = 4, dann weiter mit 4. Log-Satz (7. Log-Satz wird übersprungen, da er bereits mit dem 8. kompensiert wurde)
T_2	4	Undo und lege CLR [9, T_2, P_C, U(C), 8, 2] an
T_2	2	Undo und lege CLR [10, T_2, _ , _ , 9, 0] an

Zurücksetzen von Transaktionen

- **Transaktions-Recovery**
  - Zurücksetzen einer TA im laufenden DB-Betrieb
  - Nutzung der PrevLSN-Kette im temporären Log
  - Schreiben von optimierten CLRs, um mehrfaches Rücksetzen bei Restart zu vermeiden

- **Erweiterung zum partiellen Zurücksetzen**
  - Voraussetzung: **transaktionsinterne Rücksetzpunkte** (*Savepoints*)

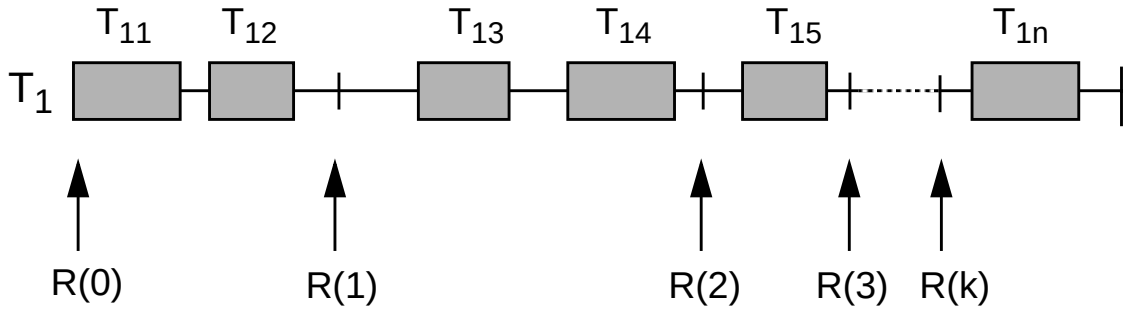

= atomarer Transaktionsschritt T_{1i}

R(i) = i-ter Rücksetzpunkt

$T_1 = (T_{11}, T_{12}, ..., T_{1n})$

  - Zusätzliche Operationen: Save R(i)

    Restore R(j)

  - Protokollierung aller Änderungen, Sperren, Cursor-Positionen usw.
  - **Undo-Operation** bis R(j) in LIFO-Reihenfolge

Zurücksetzen von Transaktionen (2)

- **Partielles Rücksetzen einer TA**

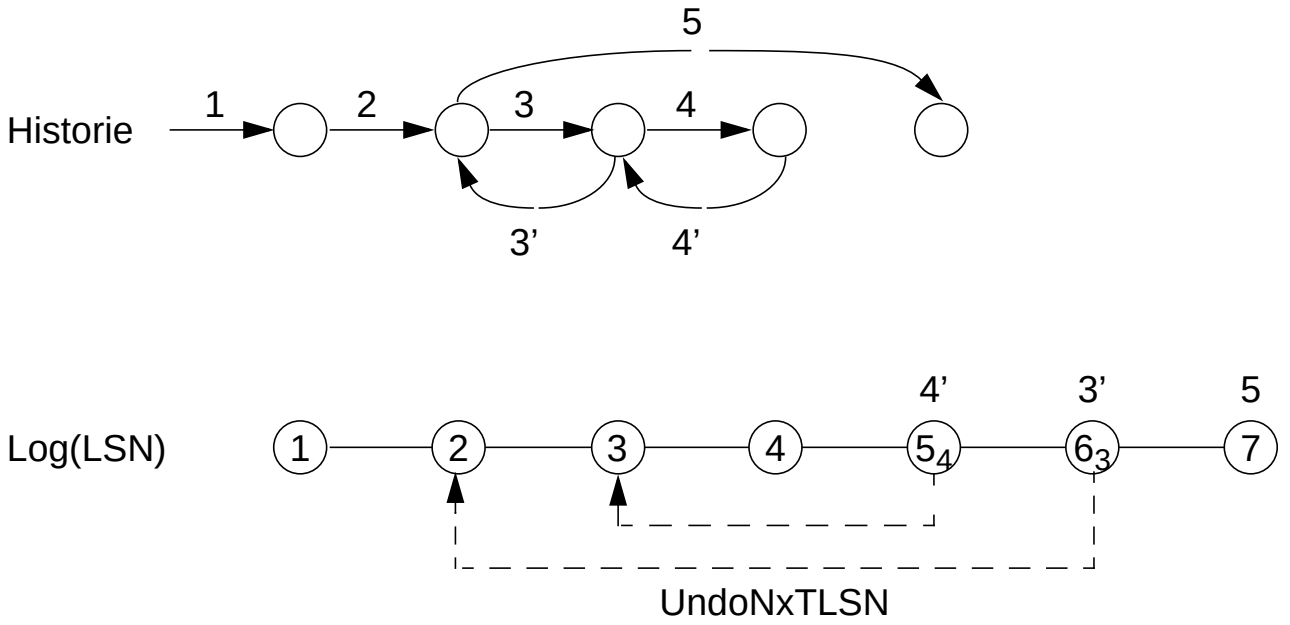

- **Rücksetzpunkte** müssen vom DBS sowie vom Laufzeitsystem der Programmiersprache unterstützt werden
  - Derzeitige Implementierungen bieten keine Unterstützung von persistenten *Savepoints*!
  - Nach Systemfehler wird TA vollständig zurückgesetzt

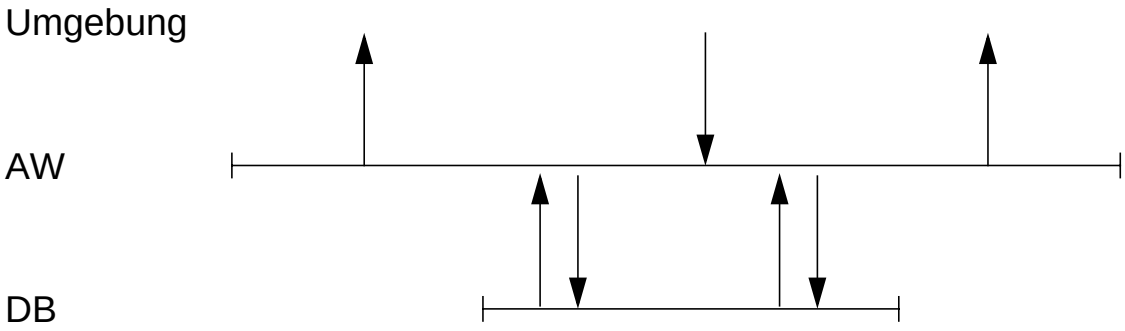

Platten-Recovery[1]

- **Spiegelplatten**
  - schnellste und einfachste Lösung
  - hohe Speicherkosten
  - Doppelfehler nicht auszuschließen

- **Alternative: Archivkopie + Archiv-Log**

- **Archivkopie + Archiv-Log sind längerfristig verfügbar zu halten (auf Band)**

  ➥ Problem von Alterungsfehlern
  - Führen von Generationen der Archivkopie
  - Duplex-Logging für Archiv-Log

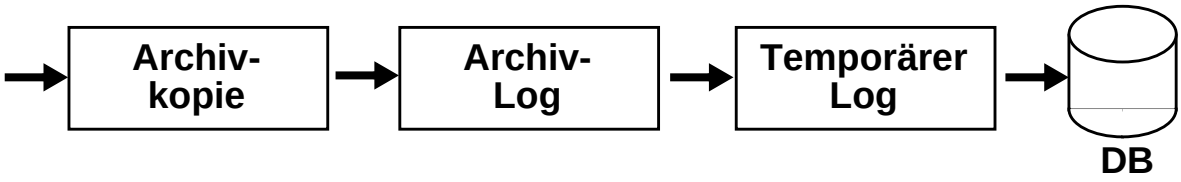

- **Ableitung von Archivdaten**
  - Sammlung sehr großer Datenvolumina als nachgelagerter Prozeß
  - Archiv-Log kann offline aus temporärer Log-Datei abgeleitet werden
  - Erstellung von Archivkopien und Archiv-Log erfolgt segmentorientiert

1. „Don’t worry, be happy.” (Bobby McFerrin)

Platten-Recovery - Ein Szenarium

- **Komponenten der Platten-Recovery**

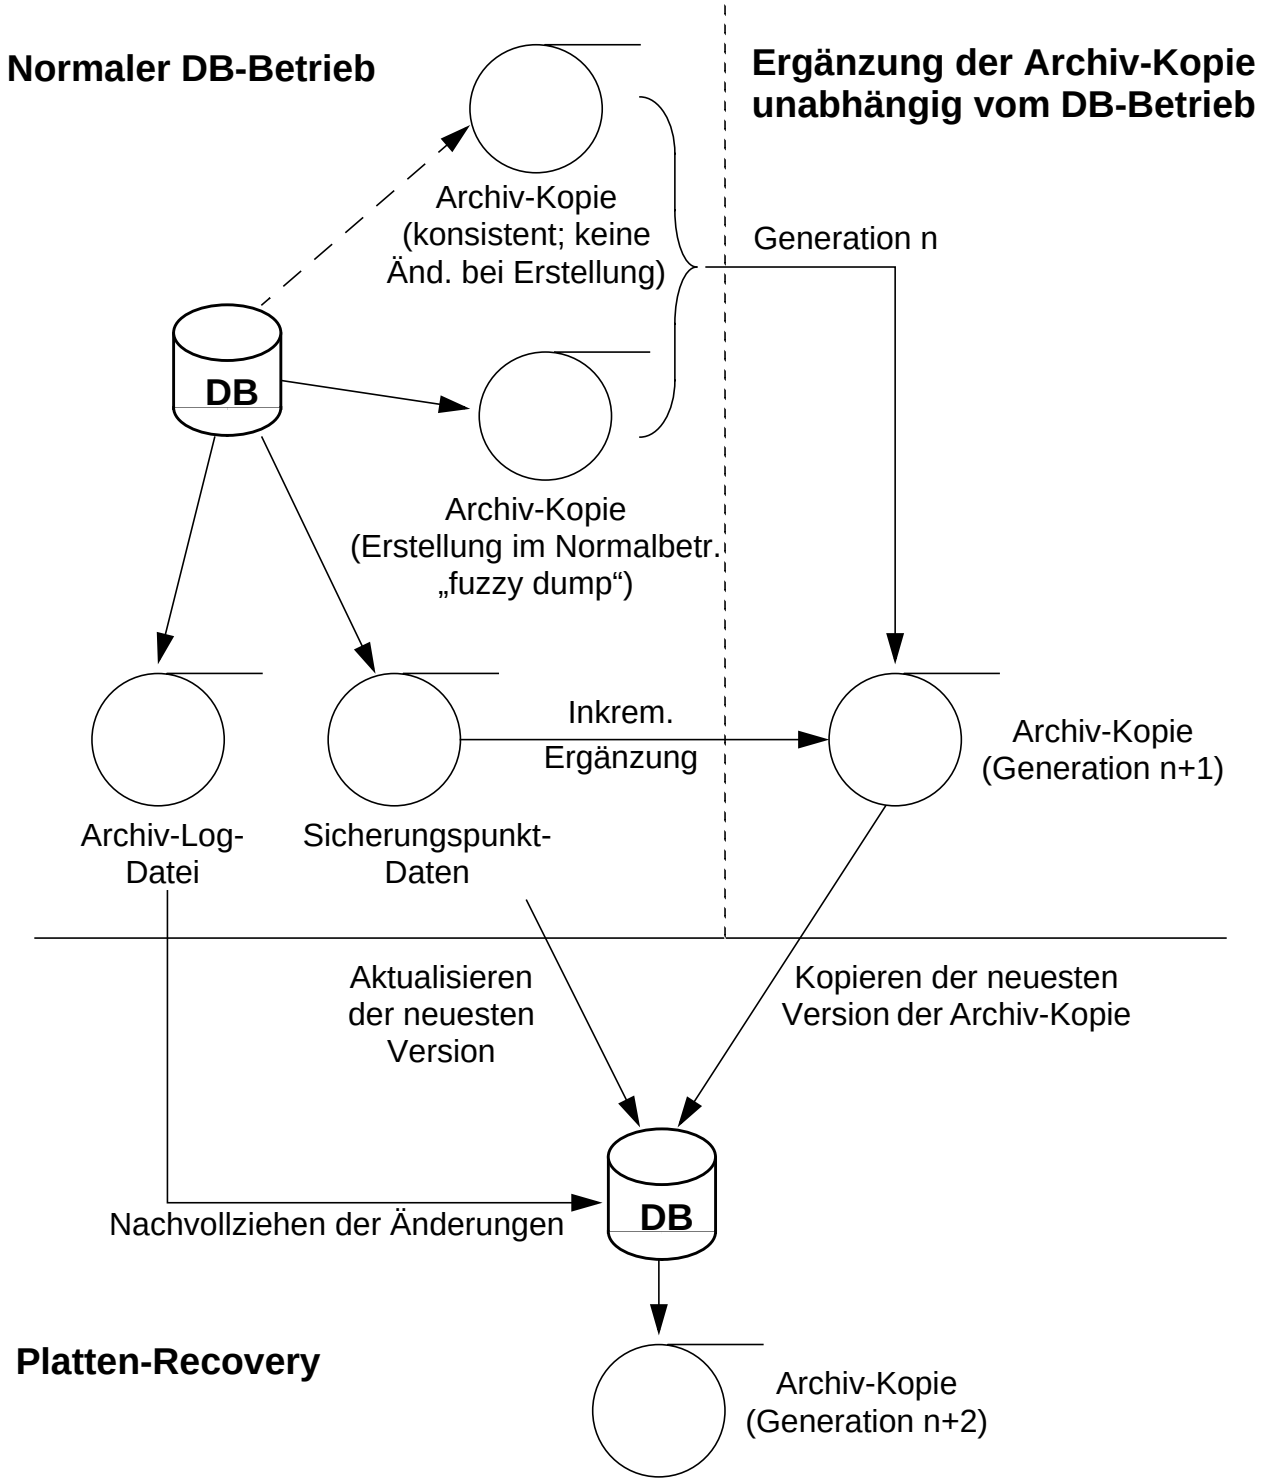

Optimierung der Erstellung der Archiv-Kopie durch inkrementelle Ergänzung mit Daten von Sicherungspunkten und ggf. Archiv-Log

Erstellung der Archivkopie

- **Anhalten des Änderungsbetriebs zur Erstellung einer DB-Kopie i. allg. nicht tolerierbar**

- **Alternativen:**

  a) Incremental Dumping

  - Ableiten neuer Generationen aus 'Urkopie'
  - nur Änderungen seit der letzten Archiv-Kopie protokollieren
  - Offline-Erstellung einer aktuelleren Kopie

  b) *Online-Erstellung einer Archivkopie*
  (parallel zum Änderungsbetrieb)

- **Unterschiedliche Konsistenzgrade:**

  b1) Fuzzy Dump

  - Kopieren der DB im laufenden Betrieb, kurze Lesesperren
  - bei Plattenfehler Archiv-Log ab Beginn der Dump-Erstellung anzuwenden

  b2) Aktionskonsistente Archivkopie
  (Voraussetzung bei logischem Operations-Logging)

  b3) Transaktionskonsistente Archivkopie
  (Voraussetzung bei logischem Transaktions-Logging)

  - Black-/White-Verfahren
  - Copy-on-Update-Verfahren

Black-/White-Verfahren[1]

- **Ziel:**
  Erzeugung transaktionskonsistenter Archiv-Kopien

- Spezieller Dumpprozeß zur Erstellung der Archiv-Kopie

- **Kennzeichnung der Seiten**
  - **Paint-Bit** pro Seite:
    - weiß: Seite wurde noch nicht überprüft
    - schwarz: Seite wurde bereits verarbeitet
  - **Modified-Bit** pro Seite zeigt an, ob eine Änderung seit Erstellung der letzten Archiv-Kopie erfolgte
  - Dumpprozeß färbt alle weißen Seiten schwarz und schreibt geänderte Seiten in Archiv-Kopie:

```
WHILE there are white pages  DO;
    lock any white page;
    IF page is modified THEN DO;
        write page to archive copy;
        clear modified bit;
    END;
    change page color;
    release page lock;
END;
```

- **Rücksetzregel**
  - Transaktionen, die sowohl weiße als auch schwarze Objekte geändert haben (’graue Transaktionen’), werden zurückgesetzt
  - ’Farbtest’ am Transaktionsende

1. C. Pu: On-the-Fly, Incremental, Consistent Reading of Entire Databases, in: Algorithmica, 1986, 271- 287

Black-/White-Verfahren: Beispiel

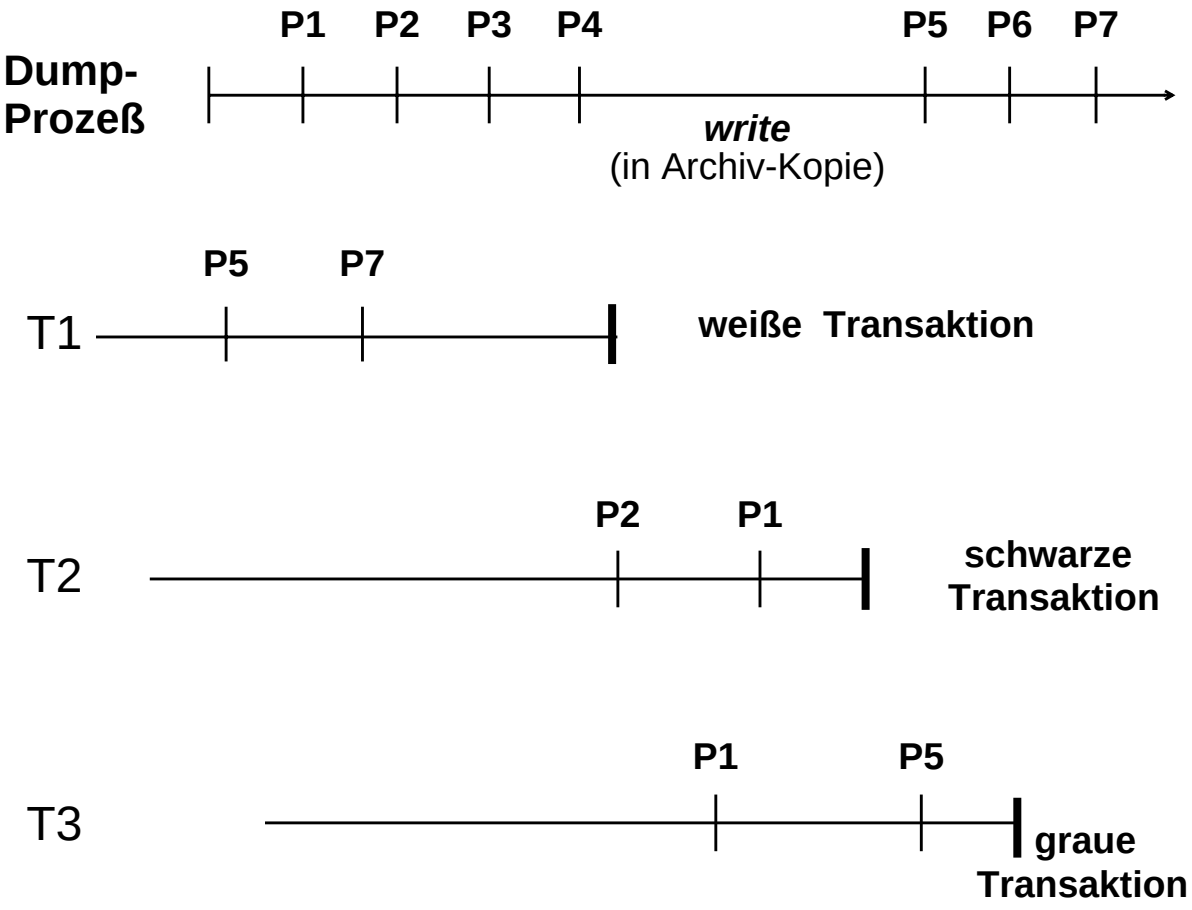

Black-/White-Verfahren:

Erweiterungen zur Vermeidung von Rücksetzungen

- **Turn-White-Strategien** (Turn gray transactions white)
  - Für graue Transaktionen werden Änderungen ’schwarzer’ Objekte nachträglich in Archiv-Kopie geschrieben
  - Problem: transitive Abhängigkeiten
  - **Alternative:** alle Änderungen schwarzer Objekte seit Dump-Beginn werden noch geschrieben (repaint all)
  - Problem: Archiv-Kopie-Erstellung kommt u.U. nie zu Ende

- **Turn-Black-Strategien**
  - Während der Erstellung einer Archiv-Kopie werden keine Zugriffe auf weiße Objekte vorgenommen
  - ggf. zu warten, bis Objekt gefärbt wird

- **Alternative: *Copy-on-Update* ("save some")**
  - Während der Erstellung einer Archiv-Kopie wird bei Änderung eines weißen Objektes Kopie mit Before-Image der Seite angelegt
  - Dump-Prozeß greift auf Before-Images zu
  - Archiv-Kopie entspricht DB-Schnappschuß bei Dump-Beginn

    ➥ wird in einigen DBS eingesetzt (DEC RDB)

Inkrementelles Dumping

- **Nur DB-Seiten, die seit der letzten Archivkopie-Erstellung geändert wurden, werden archiviert**

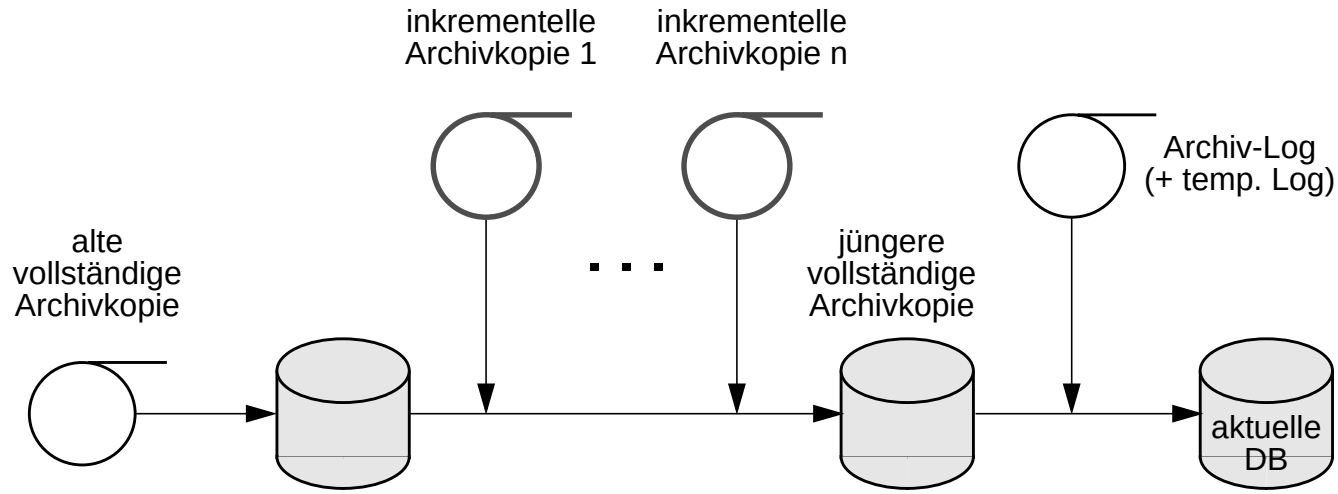

- **Erkennung geänderter Seiten**
  - Archivierungs-Bit pro Seite ➥ sehr hoher E/A-Aufwand
  - besser: Verwendung separater Datenstrukturen (Bitlisten)

- **Setzen eines Änderungsbits falls**

  (PageLSN der ungeänderten Seite) < (LSN zu Beginn des letzten Dumps)

Zusammenfassung

- **Fehlerarten:**
  Transaktions-, System-, Gerätefehler und Katastrophen

- **Breites Spektrum von Logging- und Recovery-Verfahren**
  - Logging kann auf verschiedenen Systemebenen angesiedelt werden
  - erfordert ebenenspezifische Konsistenz im Fehlerfall
  - Eintrags-Logging ist Seiten-Logging überlegen;
    in vielen DBS findet sich das **physiologische Logging**
    (flexiblere Recovery in einer DB-Seite, geringerer Platzbedarf,
    weniger E/As, Gruppen-Commit)

- **Synchronisationsgranulat muß größer oder gleich dem Log-Granulat sein**

- **Atomic-Verfahren**
  - erhalten den DB-Zustand des letzten Sicherungspunktes
  - gewährleisten demnach die gewählte Aktionskonsistenz auch bei der Recovery von einem Crash und
  - erlauben folglich logisches Logging

- **Update-in-Place-Verfahren**
  - sind i. allg. Atomic-Strategien vorzuziehen, weil sie im Normalbetrieb wesentlich billiger sind und
  - nur eine geringe Crash-Wahrscheinlichkeit zu unterstellen ist
  - Sie erfordern jedoch physisches Logging

Zusammenfassung (2)

- **Grundprinzipien bei Update-in-Place**

1. WAL-Prinzip: Write Ahead Log für Undo-Info
2. Redo-Info ist spätestens bei Commit zu schreiben

- **Grundprinzipien bei Atomic**

1. WAL-Prinzip bei verzögertem Einbringen:

   TA-bezogene Undo-Info ist vor Sicherungspunkt zu schreiben
2. Redo-Info ist spätestens bei Commit auf die Log-Datei zu schreiben

- **NoForce-Strategien**
  - sind Force-Verfahren vorzuziehen
  - erfordern den Einsatz von Sicherungspunkt-Maßnahmen zur Begrenzung des Redo-Aufwandes:

    ➥ **‚Fuzzy Checkpoints‘** erzeugen den geringsten Overhead im Normalbetrieb

- **Steal-Methoden**
  - verlangen die Einhaltung des WAL-Prinzips
  - erfordern Undo-Aktionen nach einem Rechnerausfall

- **Idempotenz des Restart**
  - Operationen der Redo-Phase, falls erforderlich, erhöhen die Seiten-LSNs; Notwendigkeit der Wiederholung kann jederzeit erkannt werden
  - Idempotenz für Undo- und Rollback-Operationen durch Einführung von CLRs; nach Crash in der Undo-Phase werden Undo-Operationen beim nachfolgenden Restart in der Redo-Phase kompensiert (Erhöhung der Seiten-LSNs, beliebig oft unterbrechbar)

- **Erstellung von Archiv-Kopien:**
  “Fuzzy Dump” oder “Copy on Update” am geeignetsten