5. Crash- und Medien-Recovery

- Crash-Recovery
  - Restart-Prozedur
  - Redo-Recovery
  - Einsatz von Compensation Log Record
  - Beispiel
- Medien-Recovery (Behandlung von Gerätefehlern)
  - Alternativen
  - Inkrementelles Dumping
  - Erstellung transaktionskonsistenter Archivkopien
- Aktuelle Vorschläge
  - Single Page Recovery
  - FineLine Recovery

Crash-Recovery

- jüngster transaktionskonsistenter DB-Zustand aus permanenter DB und (temporärer) Log-Datei herzustellen
- Idempotenz der Recovery: Fehler während Recovery müssen behandelbar sein
- bei Update-in-Place (NonATOMIC):
  - Zustand der permanenten DB nach Crash unvorhersehbar (nicht aktionskonsistent)
  - ein Block der permanenten DB ist entweder
    - aktuell oder
    - veraltet (NOFORCE) ⇒ REDO oder
    - „schmutzig“ (STEAL) ⇒ UNDO

Crash-Recovery (NonAtomic, Steal, NoForce, Fuzzy Checkpoint)

- Log-Datei wird 3-mal gelesen:

1. *Analyse-Lauf (vom letzten Checkpoint bis zum Log-Ende):*

   - Bestimmung von **Gewinner-** und **Verlierer-Transaktionen** sowie der Seiten, die von ihnen geändert wurden

2. *REDO-Lauf:* Vorwärtslesen des Logs (Startpunkt MinDirtyPageLSN)
   - Wiederholung der Änderungen von Gewinner-Transaktionen (*selektives Redo*) bzw. von allen Transaktionen (*vollständiges Redo*), sofern erforderlich (LSN-Vergleich)
   - betroffene Seiten sind einzulesen

3. *UNDO-Lauf*: Rücksetzen der Verlierer-Transaktionen
   - Rückwärtslesen des Logs bis zum BOT-Satz der ältesten Verlierer-Transaktion

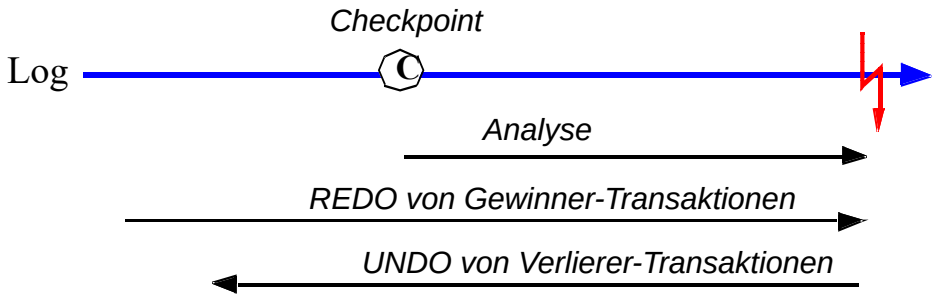

Redo-Recovery

- 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 (Idempotenz der Recovery)

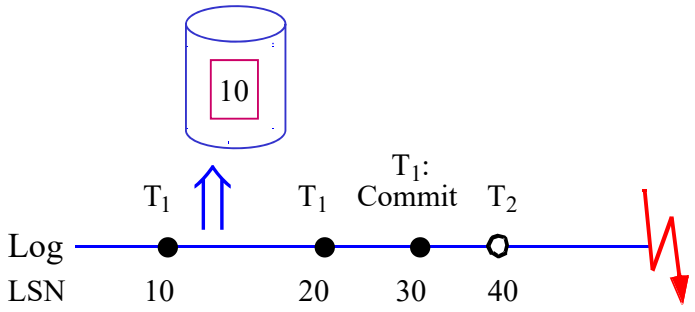

Beispiel

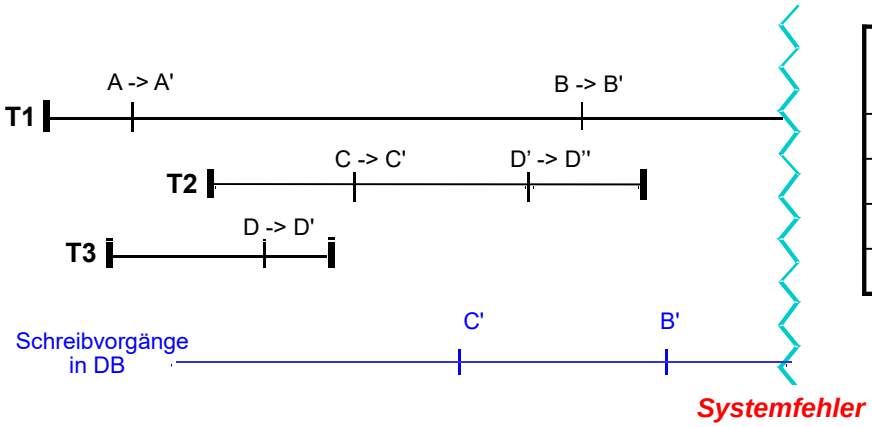

DB-Inhalt

Seite	Page-LSN
A	5
B‘	90
C‘	70
D	8

Log-Inhalt

LSN	Log-Satz
10	BOT (T1)
20	BOT (T3)
30	T1, A -> A‘
40	BOT (T2)
50	T3, D -> D‘
60	Commit (T3)
70	T2, C -> C‘
80	T2, D‘ -> D“
90	T1, B -> B‘
100	Commit (T2)

Analyselauf:

Verlierer:

Gewinner:

relevante Seiten:

Redo-Lauf:

Undo-Lauf:

Probleme bei LSN-Verwendung (für Undo)

- UNDO für Verlierer, wenn PageLSN >= LSN (Undo-Log-Satz) ???
- Problem 1: Transaktionsrücksetzungen

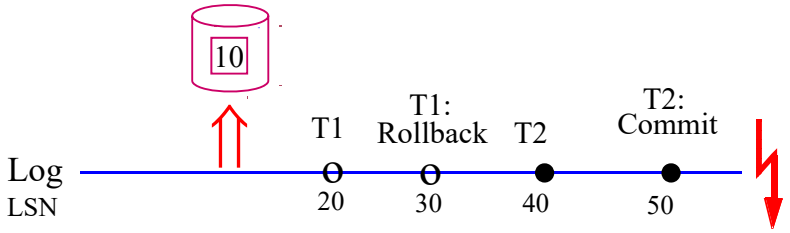

Redo-Lauf: Änderung von T2 wird wiederholt (Page-LSN := 40)
Undo-Lauf: Änderung 20 von T1 wird zurückgesetzt (da 20 < 40) -> Fehler

- Problem 2: Satzsperren

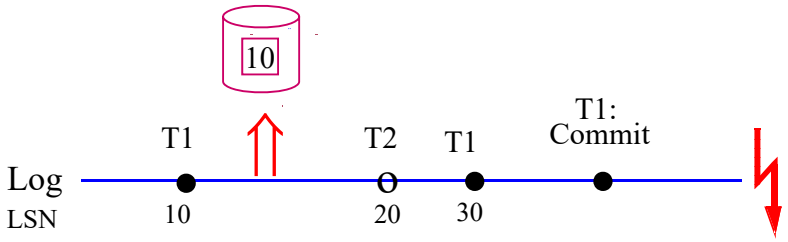

REDO von Änderung 30 (Page-LSN := 30)
UNDO von Änderung 20, obwohl nicht in der Seite vorhanden

Lösung der Probleme

- Protokollieren der Undo-Operationen durch *Compensation Log Records* (CLR)
- vollständiges Redo oder "*Repeating History*", d.h. im Redo-Lauf werden alle Änderungen (auch von Verlierer-Transaktionen) wiederholt

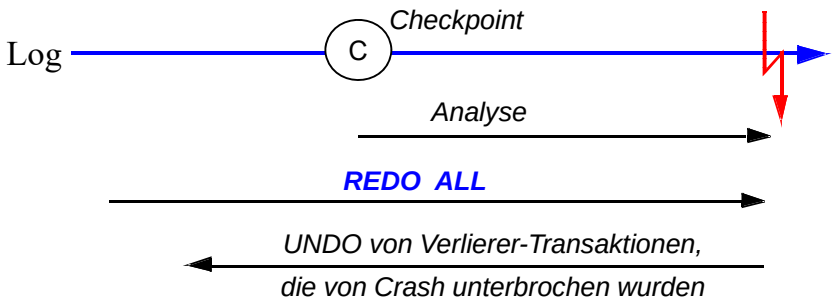

- Umsetzung durch *ARIES*-Protokoll (*Algorithm for Recovery and Isolation Exploiting Semantics)*
  - entwickelt von Mohan et al. (IBM Research)
  - realisiert in mehreren kommerziellen DBS

Compensation Log Records (CLR)

- *Compensation Log Record* (CLR) = Log-Satz einer Undo-Operation
- CLR wird geschrieben
  - für jede Seitenänderung beim Rollback im Normalbetrieb
  - für jede Undo-Operation während der Crash-Recovery
- Beispiel

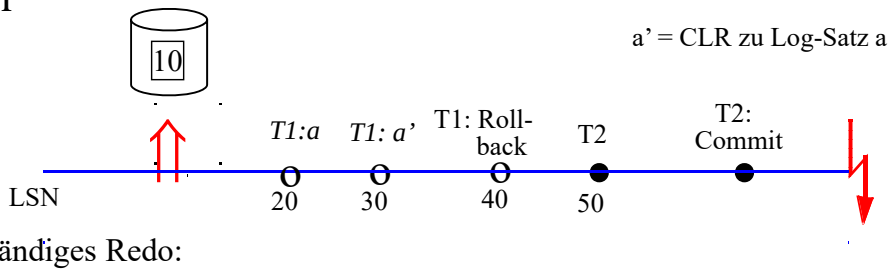

  - vollständiges Redo:

- CLR-Einsatz bei „Repeating History“ (ARIES)
  - Redo-Lauf : Wiederholung von Rollback-Operationen durch Anwendung der CLR-Sätze
  - Undo-Lauf: nur für Transaktionen, die bei Rechnerausfall aktiv waren (ohne LSN-Vergleich!)
  - Undo-Operationen wiederum zu protokollieren (CLRs)
  - PageLSN erhält LSN des CLR-Satzes

CLR (2)

- effiziente Behandlung von Crashs während Recovery
  - jeder CLR-Satz hält Rückwärtsverweis auf transaktionsspezifischen Vorgänger des Log-Satzes, für den er die UNDO-Operation repräsentiert
  - durch Crash unterbrochene Rollback-Aktion kann dort fortfahren, wo sie beim Crash-Zeitpunkt angekommen war (keine Kompensation und erneute Durchführung)

CLR-Einsatz (ARIES)

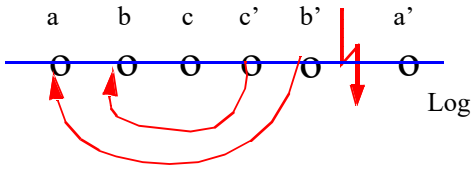

- Rücksetzen während des UNDO-Laufes erfolgt ohne LSN-Vergleich
  - alle noch nicht bearbeiteten UNDO-Sätze von Verlierer-Transaktionen werden angewendet
  - erforderlich, da Redo-Lauf auch Änderungen von Verlierer-Transaktionen wiederholt hatte ('Repeating History')
  - kein UNDO von CLR-Sätzen

Beispiel

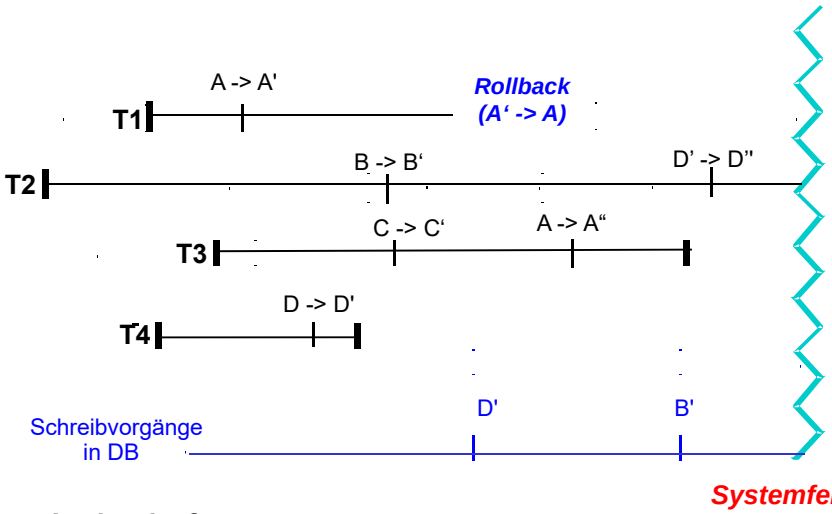

DB-Inhalt

Seite	Page-LSN
A	5
B'	60
C	10
D'	40

Log-Inhalt

LSN	Log-Satz
	...
20	BOT (T3)
30	T1, A -> A'
40	T4, D -> D'
50	Commit (T4)
60	T2, B -> B'
70	T3, C -> C'
80	T1, A' – A (CLR)
90	Rollback (T1)
100	T3, A -> A"
110	Commit (T3)
120	T2, D' -> D"

Analyselauf:
- Verlierer-Transaktionen: T1, T2; davon T2 noch aktiv zum Crash-Zeitpunkt
- Gewinner: T3, T4
- relevante Seiten: A, D, B, C

Vollständiges Redo:

Redo (	PageLSN(
Redo (	PageLSN(
Redo (	PageLSN(
Redo (	PageLSN(

Undo-Lauf: nur T2 betroffen

Recovery für Externspeicher (Magnetplatten)

- Spiegelplatten
  - schnellste und einfachste Lösung
  - hohe Speicherkosten
  - Doppelfehler nicht auszuschließen
- Disk-Arrays (RAID-5)
  - geringere Speicherkosten als Spiegelplatten, jedoch auch geringere Fehlertoleranz
  - langsamerer Zugriff für einzelne Blöcke, dafür Unterstützung von E/A-Parallelität
- Alternative: Archivkopie + Archiv-Log
  - Archivkopie + Archiv-Log sind längerfristig verfügbar zu halten (z.B. auf Band)
  - Führen von Generationen der Archivkopie
  - Duplex-Logging für Archiv-Log

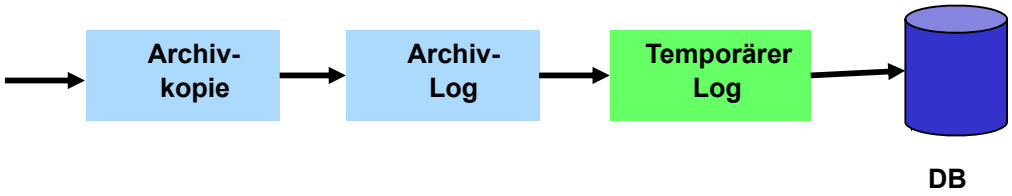

- Archiv-Log offline aus (temporärer) Log-Datei ableitbar
- Erstellung von Archivkopien und Archiv-Log erfolgt segmentorientiert

Erstellung der Archivkopie (Dump)

- Unterbrechung des Änderungsbetriebs zur Erstellung einer DB-Kopie i.a. nicht tolerierbar
- Alternativen:
  - **Incremental Dumping**
    - Ableiten neuer Generationen aus 'Urkopie'
    - nur Änderungen seit der letzten Archivkopie werden protokolliert
    - Offline-Erstellung einer aktuelleren Kopie
  - **Online-Erstellung einer vollständigen Archivkopie (parallel zum Änderungsbetrieb)**
- Unterschiedliche Konsistenzgrade:
  - **Fuzzy Dump**
    - Kopieren der DB im laufenden Betrieb, kurze Lesesperren
    - bei Plattenfehler Archiv-Log ab Beginn der Dump-Erstellung anzuwenden
  - **Aktionskonsistente Archivkopie** (Voraussetzung bei logischem Operations-Logging)
  - **Transaktionskonsistente Archivkopie** (Voraussetzung bei logischem Transaktions-Logging)
    - Black-/White-Verfahren
    - Copy-on-Update-Verfahren

Inkrementelles Dumping

- nur seit der letzten Archivkopie-Erstellung geänderte DB-Seiten werden archiviert

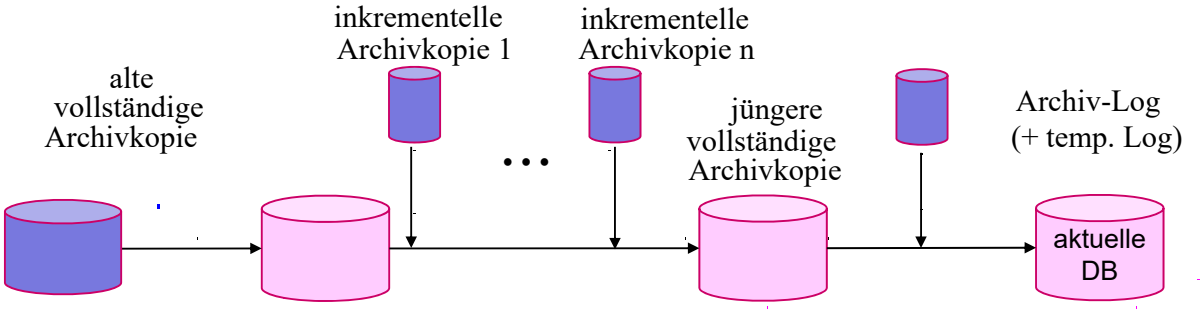

- Erkennung geänderter Seiten
  - Archivierungs-Bit pro Seite -> alle Seiten für Dump-Erstellung zu lesen
  - sehr hoher E/A-Aufwand
- besser: Verwendung separater Datenstrukturen (Bitlisten)
  - Änderungsbit zeigt Notwendigkeit, Seite in den nächsten Dump zu schreiben
  - Setzen des Änderungsbits falls
    (PageLSN der ungeänderten Seite) < (LSN zu Beginn des letzten Dumps)

Black-/White-Verfahren

- Erzeugung transaktionskonsistenter Archivkopien
- 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 Archivkopie erfolgte (inkrementelles Dumping)
- spezieller Schreibprozess zur Erstellung der Archivkopie
  - färbt alle weißen Seiten schwarz und schreibt geänderte Seiten in Archivkopie:

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

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

Black-/White-Verfahren: Beispiel

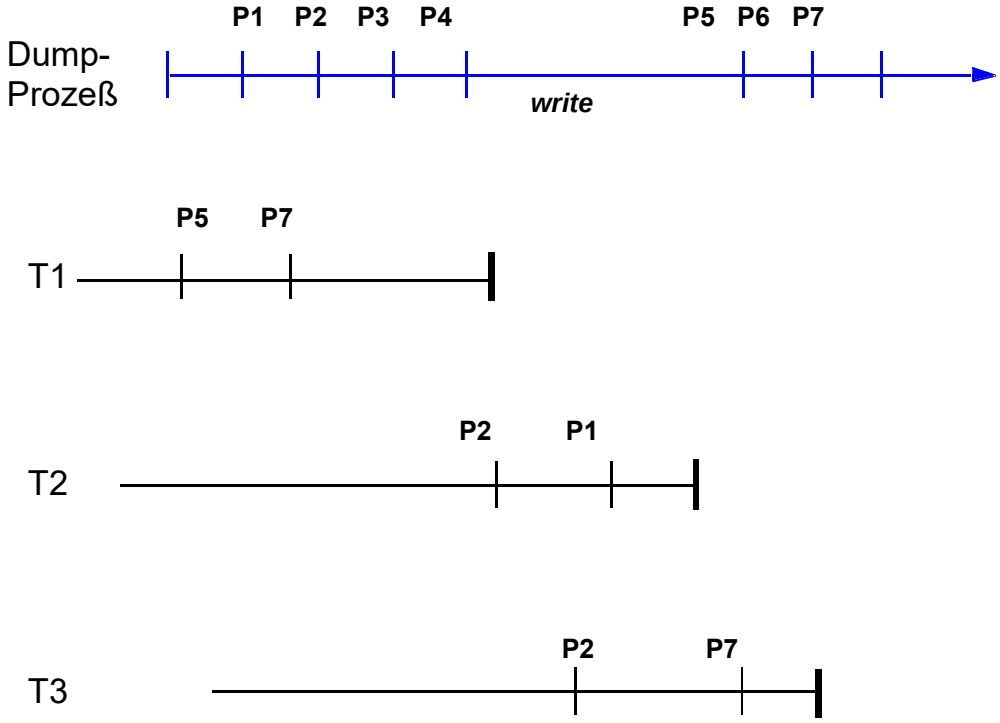

Black-White-Verfahren: Copy on Update

- Rücksetzung von Transaktionen zu umgehen
- Beste Lösung: Copy on Update ("save some")
  - es werden nur schwarze Transaktionen zugelassen, d.h. Dump beinhaltet keine Änderung seit Dump-Beginn
  - während Dump-Prozeß wird bei Änderung eines weißen Objektes Kopie mit Before-Image der Seite angelegt
  - Dump-Prozess greift auf Before-Images zu
  - Archivkopie entspricht DB-Schnappschuss bei Dump-Beginn
- Merkmale
  - transaktionskonsistenter Dump
  - keine Rücksetzungen / Blockierungen von Transaktionen
  - geringer Speicheraufwand für Before-Images
  - Ähnlichkeit zu Mehrversionen-Synchronisation mit Dump als langer Lese-Transaktion

Single Page Recovery*

- häufiger Spezialfall der Medien-Recovery
  - nur eine Seite bzw. einzelne Seiten fehlerhaft
  - komplette Medien-Recovery dauert zu lange
  - dedizierte Unterstützung wünschenswert
- neue Fehlerkategorie?

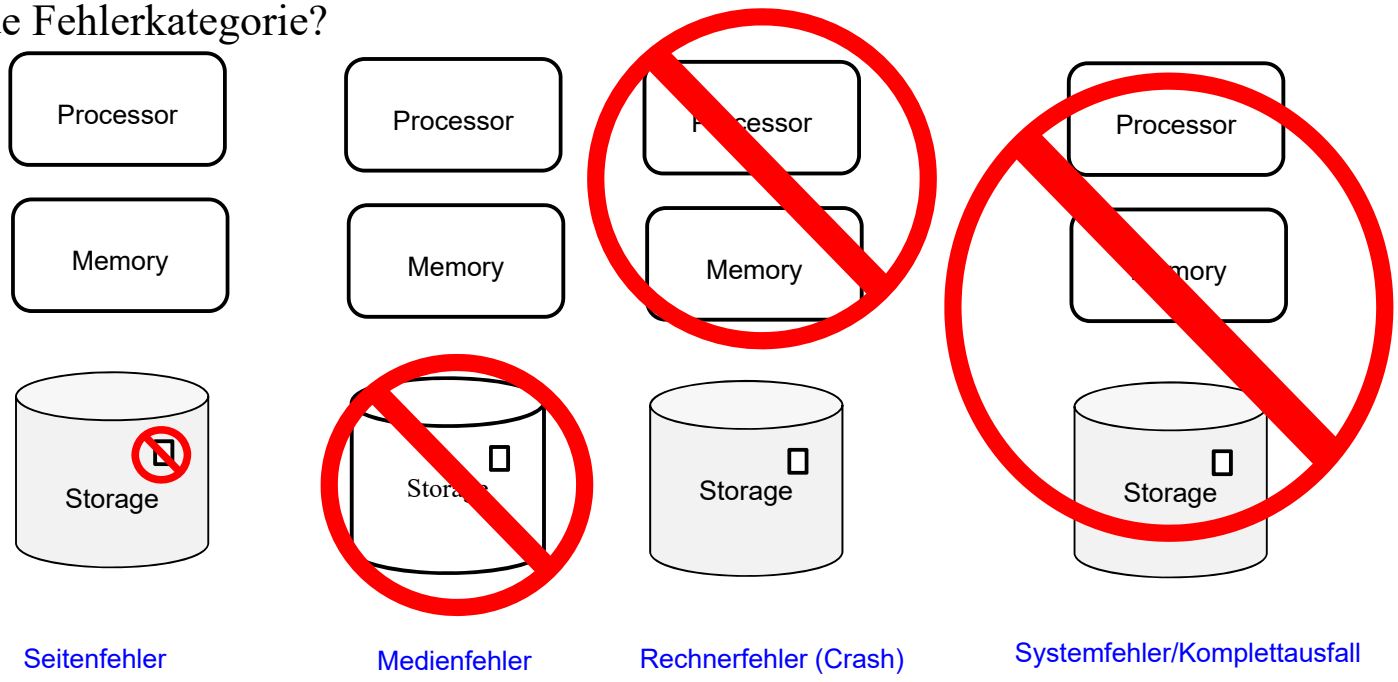

*G. Graefe, H.A. Kuno: *Definition, Detection, and Recovery of Single-Page Failures, a Fourth Class of Database Failures*. PVLDB 5(7): (2012)

Single Page Recovery (2)

- Beschleunigung durch
  - Rückwärts-Verkettung von Log-Sätzen pro Seite
  - Einsatz eines sog. *Page Recovery Indexes* mit Verweis auf letzte Seitenkopie (in vollständiger oder inkrementeller Archivkopie) sowie den letzten Log-Eintrag der Seite auf Log-Datei
- Seiten-Recovery
  - Einspielen der letzten Seitenkopie
  - Durchgang aller Log-Sätze von letzten bis zu erstem seit der Kopieerstellung
  - Anwendung der Redo-Sätze in umgekehrter Reihenfolge

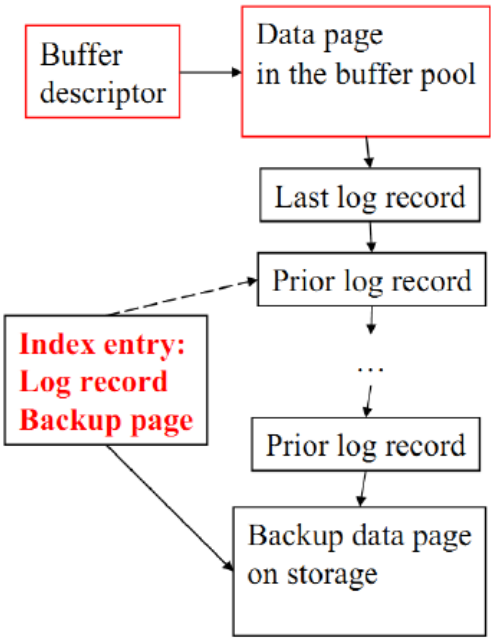

FineLine Recovery

- Verallgemeinerung der Ideen von Single-Page Recovery
- optimiert für (near) In-Memory DBS
  - persistente Speicherung der DB-Objekte innerhalb Log selbst
  - DB-Seiten/Objekte müssen selten eingelesen werden, werden dann analog zu Single-Page Revovery aus Log erzeugt („fetch“)
- nur Redo-Logging (ähnlich Media-Recovery)
  - Log-Daten werden transaktionsweise (gebündelt) an das Ende des Logs geschrieben („append“)
  - Partitionierung/Indexierung der Log-Daten zum schnellen Lesen/Rekonstruien der Daten

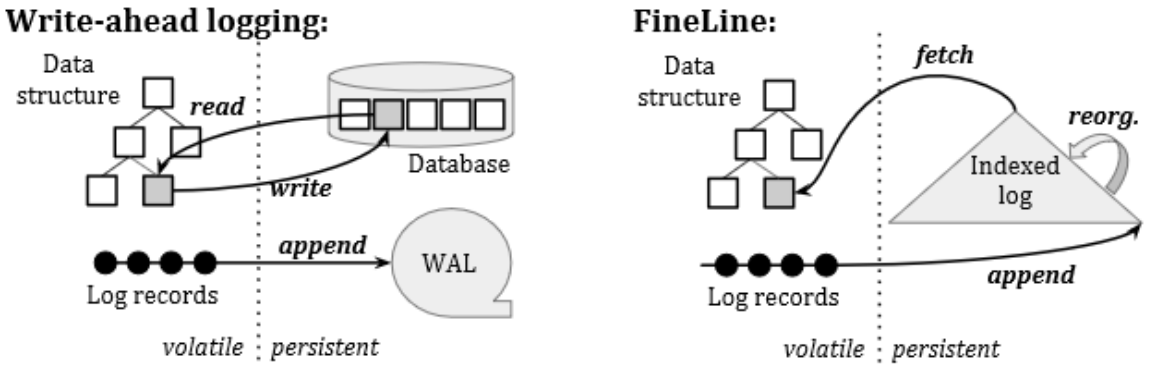

C. Sauer, G. Graefe, T. Härder: *FineLine: log-structured transactional storage and recovery*. PVLDB 2018

Zusammenfassung

- Crash-Recovery
  - Analyse-, Redo-, Undo-Lauf auf temporärer Log-Datei
  - Redo über Vergleich PageLSN mit LSN der Log-Sätze
  - Notwendigkeit von Compensation Log Records
  - vollständiges Redo (ARIES) unterstützt Satzsperren
  - Idempotenz: Crashs während Recovery können behandelt werden
- Erstellung von Archivkopien der DB (Dumping)
  - inkrementelle vs. vollständige Dumps
  - "Fuzzy Dumps" vs. aktions/transaktionskonsistente Dumps
  - transaktionskonsistente Archivkopie durch "Copy on Update"
- schnelle Rekonstruktion einzelner Seiten wünschenswert