

DATENBANKANWENDUNG

Wintersemester 2013/2014

Holger Schwarz
Universität Stuttgart, IPVS
holger.schwarz@ipvs.uni-stuttgart.de

Beginn: 23.10.2013
Mittwochs: 11.45 – 15.15 Uhr, Raum 46-268 (Pause 13.00 – 13.30)
Donnerstags: 10.00 – 11.30 Uhr, Raum 46-268
11.45 – 13.15 Uhr, Raum 46-260

<http://www.lgis.informatik.uni-kl.de/cms/courses/datenbankanwendung/>

9. Logging und Recovery¹

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



■ **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-Bespiel (Repeating History)

■ **Transaktions-Recovery**

■ **Die Zehn Gebote**

■ **Medien-Recovery**

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

■ Systemverfügbarkeit A (availability)²

- MTTF: Mean Time To Failure, MTTR: Mean Time To Repair

$$A = \text{MTTF} / (\text{MTTF} + \text{MTTR})$$

■ Warum ROC?

- Falsche Operateur-Aktionen sowie HW- und SW-Fehler sind Tatsachen, mit denen man fertig werden muss, und keine Probleme, die zu lösen sind³
- Lange Systemausfälle sind sehr sichtbar (siehe Ebay-Ausfall von 280 min.)!
- MTTR soll minimiert und kann direkt gemessen werden (MTTF von qualitativ guten Magnetplatten ist heute 120 Jahre)
- Verkürzung der MTTR (auf Anwendungsebene) verbessert die Benutzererfahrung, was das Systemverhalten betrifft
- Schnelle und häufige „Recovery“ (auf systeminternen Ebenen / in Komponenten) kann die effektive MTTF verlängern (Verjüngungseffekt!)

⇒ Der Fokus liegt auf ROC!⁴

2. **The myth of the nines:** Availability is sometimes described in units of nines, as in "five nines", or 99.999%. Having a computer system's availability of 99.999% means the system is highly available, delivering its service to the user 99.999% of the time it is needed.
3. 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)
4. **Beobachtung: Welche Konsequenzen sind aus ROC zu ziehen?** Die System- einschl. Betriebskosten von DB-Systemen sind 3- bis 18-mal höher als der HW-Kaufpreis (Cluster-basierte Systeme) und 1/3 bis 1/2 dieser Kosten wird für Recovery oder für Fehlervorsorge aufgewendet



Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery

■ Es geht hier nicht um Korrektheitsbeweise!

- Behandlung **unbeabsichtigter** Fehler
- Annahme: **Unabhängigkeit ihres Auftretens**
- Verbesserung von Robustheit, Zuverlässigkeit, Verfügbarkeit, ... des Systems

↳ **Verlässliche Systeme** verlangen wesentlich mehr Dienstgarantien und Recovery bei schwierigeren Fehlerfällen (beabsichtigte, abhängige Fehler; Viren- oder Hackerangriffe; Denial-of-Service-Attacken; Sabotage, ...)

■ Viele Fragen

- Wie kann ein System für ROC entworfen werden (designed for recovery)?
- Wie können Fehler identifiziert und klassifiziert werden (zur Auswahl der effektivsten Recovery-Strategie)?
- Wie kann der Erfolg gemessen werden?
- Wie erreicht man annähernd $A = 1,0$?
 - **MTTF $\rightarrow \infty$?**
 - **MTTR \ll MTTF !**



Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery

■ Was ist bei ROC im DB-Kontext zu optimieren?

- Einsatz effektiver und effizienter Logging-Verfahren
- **Schneller Wiederanlauf** (Restart), um hohe Verfügbarkeit zu erreichen
- **Geringer Overhead** während des Normalbetriebs
- **Hohe Transaktionsparallelität** im Normalbetrieb
- Korrektheit (und Einfachheit) trotz der **Komplexität des DB-Betriebs und vieler subtiler Abhängigkeiten** zwischen DBMS-Komponenten
- State of the Art, siehe Vortrag von G. Weikum*

* G. Weikum: **Database Recovery – Heisenbugs, Houdini's Tricks, and the Paranoia of Science.**
<http://www.docstoc.com/docs/4200129/Database-Recovery-?-Heisenbugs-Houdini?s-Tricks-and-the-Paranoia>



■ Aufgabe des DBMS

- Automatische Behandlung aller **erwarteten** Fehler

■ Was sind erwartete Fehler?⁵

- DB-Operation wird zurückgewiesen, Commit wird nicht akzeptiert, . . .
- Stromausfall, DBMS-Probleme, . . .
- Geräte funktionieren nicht (Spur, Zylinder, Platte defekt)
- beliebiges Fehlverhalten der Gerätesteuerung?
- falsche Korrektur von Lesefehlern? . . .

■ Was sind die Besonderheiten der DBS-Fehlerbehandlung?

- Begrenzung und 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 DBMS

- Transaktionsfehler
- Systemfehler
- Gerätefehler
- Katastrophen

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

Grundlagen der DB-Recovery (2)

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



■ 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 wieder herzustellen, der **allen semantischen Integritätsbedingungen** 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 Komponente)

Umgebung

AW

DB



Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery

- **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“)

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery

■ Prinzipien der DB-Recovery


- 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)

■ **J. Gray: “A recoverable action is 30% harder and requires 20% more code than a non-recoverable action”**



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?

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



Fehlerarten

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



Auswirkung eines Fehlers auf	Fehlertyp	Fehlerklassifikation
eine Transaktion	<ul style="list-style-type: none"> • Verletzung von Systemrestriktionen <ul style="list-style-type: none"> - Verstoß gegen Sicherheitsbestimmungen - übermäßige Betriebsmittelanforderungen • anwendungsbedingte Fehler <ul style="list-style-type: none"> - z.B. falsche Operationen und Werte- 	Transaktionsfehler
mehrere Transaktionen	<ul style="list-style-type: none"> • geplante Systemschließung • Schwierigkeiten bei der Betriebsmittelvergabe <ul style="list-style-type: none"> - Überlast des Systems - Verklemmung mehrerer Transaktionen 	
Alle Transaktionen (das gesamte Systemverhalten)	<ul style="list-style-type: none"> • Crash mit Verlust der Hauptspeicherinhalte <ul style="list-style-type: none"> - Hardware-Fehler - falsche Werte in kritischen Tabellen • Zerstörung von Sekundärspeichern • Zerstörung des Rechenzentrums 	Systemfehler (Crash) Gerätefehler Katastrophen

1. Transaktions-Recovery

Zurücksetzen einzelner (noch nicht abgeschlossener) TA im laufenden DB-Betrieb (TA-Fehler, Deadlock usw.)⁶

R1: vollständiges Zurücksetzen auf BOT (TA-Undo)

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!)

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

■ A Fundamental Theorem of Recovery



- **Axiom 1 (Murphy)**

All programs (DBMSs) are buggy.

- **Theorem 1 (Law of Large Programs)**

Large programs are even bugger 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 whether or not 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 DBMS-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)

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



Recovery-Arten (4)

■ **Entwicklungsziele⁷**

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):**
 - für Web-Sites: 99%
 - für gut administrierte Systeme: 99,99% (~1 Min/Woche, ~50 Min/Jahr)
 - zSeries-Plattform („zero downtime“ von IBM): 5 9', allerdings nicht für das Gesamtsystem
- **Künftige Verfügbarkeit**
 - bis wann? --> weitere 4 9' (im Vergleich zur zSeries)
 - . . .

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte


Crash-Recovery

TA-Recovery

Medien-
Recovery

7. Jim Gray: We have added three 9s in 45 years (starting with 90%), or about 15 years per order-of-magnitude improvement in availability. We should aim for five more 9s: an expectation of one second outage in a century. This is an extreme goal, but it seems achievable if hardware is very cheap and bandwidth is very high. One can replicate the services in many places, use transactions to manage the data consistency, use design diversity to avoid common mode failures, and quickly repair nodes when they fail. Again, this is not something you will be able to test: so achieving this goal will require careful analysis and proof.

DB-Recovery - Systemkomponenten



■ Permanente (oder materialisierte) DB

Zustand der DB inkl. Verwaltungsdaten (Katalog, Adresstabellen usw.) auf nicht-flüchtigem Speicher. Beim initialen Laden des DBMS oder nach einem Crash ist ausschließlich dieser Zustand verfügbar.

■ 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

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery


TA-Recovery

Medien-
Recovery



■ Konsistenz der Transaktionsverarbeitung

- Bei COMMIT müssen alle Constraints erfüllt sein
- Zentrale Spezifikation/Überwachung im DBS: „*system enforced integrity*“



BOT: Begin of Transaction

EOT (Commit): End of Transaction

O_{ij}: DB-Operation; Lese- und Schreiboperationen auf DB-Daten

⇒ **C von ACID sichert dem Programmierer zu, dass vor BOT und nach EOT der DB-Zustand alle Constraints des DB-Schemas erfüllt!**

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery

■ Verfeinerung des Konsistenzbegriffes

- Transaktionsatomarität impliziert **Transaktionskonsistenz**: nur Änderungen erfolgreicher Transaktionen sind in der DB enthalten
- Anweisungsatomarität impliziert **DML-Operationskonsistenz**⁸: DML-Operation hält schichtenspezifische Konsistenz des Datensystems ein
- DML-Operationen setzen sich aus Aktionen zusammen: **Aktionskonsistenz** und **Geräte-/ Dateikonsistenz** sind wiederum Voraussetzung, dass DML- Operationen und Aktionen überhaupt auf den Daten abgewickelt werden können

⇒ **Konsistenz einer Schicht setzt schichtenspezifische Konsistenz aller darunter liegenden Schichten voraus!**


8. „Golden Rule“ nach C. J. Date: No update operation must ever be allowed to leave any relation or view (relvar) in a state that violates its own predicate. Likewise no update transaction must ever be allowed to leave the database in a state that violates its own predicate.

Vorsorge für den Fehlerfall

■ 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?

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



Erhaltung der DB-Konsistenz (2)

■ Welche Konsistenzart garantiert jede Schicht nach erfolgreichem Abschluss einer schichtenspezifischen Operation?

- Speichersystem → Geräte-/Dateikonsistenz (einzelne Seite)
Jede Seite muss physisch unversehrt, d. h. lesbar oder schreibbar sein
- Zugriffssystem → Aktionskonsistenz (mehrere Seiten)
Sätze und Zugriffspfade müssen für Aktionen „in sich konsistent“ sein, d. h. beispielsweise: „Alle Zeiger müssen stimmen!“
- Datensystem → DML-Operationskonsistenz (oft viele Seiten)
- Datenbank → Transaktionskonsistenz
Alle Constraints des DB-Schemas müssen erfüllt sein!

Systemhierarchie + DB-Konsistenz

Transaktionskonsistenz

TAP Gehaltserhöhung

DML-Operationskonsistenz


Update Pers Set ... Where Q

Aktionskonsistenz

Update Index_{Pers}(Pnr) Using 4711

Geräte-/Dateikonsistenz

Read Page / Write Page



Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



Logging: Anwendungsbeispiel

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

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

	<i>logisch</i>	<i>physisch</i>
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: $A \oplus '0' = A$; $A \oplus A = '0'$

$$\begin{array}{l}
 A_1 \oplus (A_1 \oplus A_2) = A_2 \quad A_3 \oplus (A_2 \oplus A_3) = A_2 \\
 A_2 \oplus (A_2 \oplus A_3) = A_3 \quad A_2 \oplus (A_1 \oplus A_2) = A_1
 \end{array}$$

Redo-Recovery

Undo-Recovery

Grundlagen

Logging

Abhängigkeiten

Commit


Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery





■ Logisches Logging

- Protokollierung der ändernden DB-Operationen oder gar der TA-Programme mit ihren Parametern
 - Generelles Problem
mengenorientierte Aktualisierungsoperation (z. B. DELETE <relation>)
 - Undo-Probleme vor allem bei nicht-relationalen Systemen (z. B. Löschen einer Hierarchie von Set-Ausprägungen (ERASE ALL))
 - **Voraussetzung**
Nach einem Crash müssen auf der permanenten Datenbank DB-Operationen ausführbar sein, d. h., sie muss wenigstens logisch konsistent sein (Operationskonsistenz, TA-Konsistenz)
- ⇒ **verzögerte (indirekte) Einbringstrategie erforderlich**

Klassifikation von Logging-Verfahren (2)

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery

■ **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

■ **Synthese: 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



Aufwand bei physischem Zustands-Logging

■ Einfachste Form der Implementierung: Seiten-Logging



■ Operation: STORE X-RECORD (X1)

Aufwand	Datenseite	ZT	FPA	n Zugriffspfadseiten (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}

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



Bewertung der Logging-Verfahren

Logging-Verfahren	Logging-Aufwand im Normalbetrieb	Restart-Aufwand im Fehlerfall (Crash)
Seitenzustands-Logging		
Seitenübergangs-Logging		
Physiologisches Logging		
Aktions-Logging (Einträge)		
DML-Operations-Logging		
Logging von TA- Programmparametern		

- - sehr hoch - hoch + gering ++ sehr gering

■ **Vorteile von physiologischem Logging / Aktions-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

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



DB-Konsistenz und Logging

Log-Granulat

Systemhierarchie + DB-Konsistenz im Fehlerfall

SQL-Operationshierarchie

- Grundlagen
- Logging**
- Abhängigkeiten
- Commit
- Sicherungs-punkte
- Crash-Recovery
- TA-Recovery
- Medien-Recovery

TA-Programm-parameter

TA-Konsistenz

DML-Operation

API-Konsistenz

Tabellen, Sichten, ...

Aktion (Eintrag)

Aktions-konsistenz

elementare Aktion

Sätze, Felder, ...

EAC


Seite

Datei-konsistenz

Seiten, ...

Archiv-Datei/
Archiv-Log

zerstörtes
Gerät



DB-Konsistenz und Logging (2)

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery

■ DB-Konsistenz im Fehlerfall

- DB-Zustand bei Crash = materialisierte (permanente) DB zum Zeitpunkt des Crashes
- Eine bestimmte Konsistenz der materialisierten DB bedeutet, dass
 - **alle Effekte** von Operationen der entsprechenden Abstraktionsebene **vollständig** in die DB eingebracht sind
 - **keine Effekte** von **unvollständigen** Operationen die DB erreicht haben
 - die Log-Informationen auf den DB-Zustand angewendet werden können
- Wenn eine Einbringoperation beim Crash unterbrochen wurde, ist der Block i. Allg. unvollständig geschrieben!
 - ⇒ **Nur beim Seiten-Logging ruft ein unvollständig geschriebener Block keine Medien-Recovery hervor!**

■ Auswahl eines Logging-Verfahrens

Wenn im Fehlerfall (Crash) die DB folgende Konsistenz aufweist:

- Dateikonsistenz → Seiten-Logging (physisch)
- Konsistenz elementarer Aktionen (EAC) → Physiologisches Logging
- Aktionskonsistenz (für interne Operationen) → Aktions-Logging (logisch)
- API-Konsistenz → DML-Op.-Logging (logisch, SQL-Ops)
- TA-Konsistenz → TA-Programmparameter-Logging (logisch)
- ⇒ **Der umgekehrte Schluss ist nicht zwingend!**

■ Garantie einer bestimmten Konsistenz

- Wenn bei Crash die Konsistenz einer Abstraktionsebene garantiert wird, können **Logging-Verfahren niedrigerer Konsistenzebene** gewählt werden
- Dieser Fall tritt üblicherweise nicht auf, da die Gewährleistungskosten für die Konsistenz mit der Abstraktionsebene steigen!



■ Verschiedene Satzarten erforderlich

- BOT-, Commit-, Abort-Satz
- Änderungssatz (Undo-Informationen (z. B. ‚Before-Images‘) und Redo-Informationen (z. B. ‚After-Images‘))
- Sicherungspunktsätze

■ 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

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery

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, T ₂ , P _A , A-=100, A+=100, #4]
16.		Commit	[#8, T ₂ , Commit , #7]

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



Aufbau der (temporären) Log-Datei (2)

- **Log ist eine sequentielle Datei**

Schreiben neuer Protokolldaten an das aktuelle Dateieende

- **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**

älteste Redo-Information
einer geänderten Seite
im DB-Puffer

älteste Redo-Information,
die nicht im Archiv-Log vorliegt

Beginn der ältesten TA
(MinLSN)



Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte


Crash-Recovery

TA-Recovery

Medien-
Recovery



■ Stark vereinfachtes Modell



■ Einbringstrategie für Änderungen

- direkt (Non-Atomic, *Update-in-Place*), Änderungen können **jederzeit** in die permanente DB eingebracht werden
- verzögert (Atomic, Bsp.: Schattenspeicherkonzept), Änderungen werden **ausschließlich** durch Erzeugen eines Sicherungspunktes eingebracht (Caveat: Schreiben <> Einbringen)

■ DB-Pufferverwaltung

- **Ersetzungsstrategie** für ‚schmutzige‘ Seiten (Steal vs. NoSteal), bezieht sich ausschließlich auf das Verdrängen aus dem DB-Puffer
- **Commit-Behandlung** für geänderte Seiten (Force vs. NoForce), bezieht sich ausschließlich auf das Einbringen von Änderungen (in die permanente DB)

■ Sperrverwaltung (Wahl des Sperrgranulats)

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



Klassen von Historien

- **Definition: Eine Historie H heißt rücksetzbar, falls immer** die schreibende TA (T_j) vor der lesenden TA (T_i) ihr Commit ausführt:

$$c_j <_H c_i$$

- **Definition: Eine Historie vermeidet kaskadierendes Rücksetzen, wenn**

$$c_j <_H r_i[A]$$

gilt, wann immer T_i ein von T_j geändertes Datum liest.

- **Definition: Eine Historie H ist strikt,** wenn für je zwei TA T_i und T_j gilt:


Wenn

$$w_j[A] <_H o_i[A] \quad (\text{mit } o_i = r_i \text{ oder } o_i = w_i),$$

dann muss gelten:

$$c_j <_H o_i[A] \quad \text{oder} \quad a_j <_H o_i[A]$$

- **Beziehungen zwischen den Klassen**



Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



Abhängigkeiten zur Einbringstrategie


■ Nicht-atomares Einbringen (Non-Atomic, Update-in-Place)

- Geänderte Seite wird immer in denselben Block auf Platte zurückgeschrieben
- Schreiben ist dadurch gleichzeitig Einbringen in die permanente DB (direktes Einbringen)
- Atomares Einbringen mehrerer geänderter Seiten ist nicht möglich

Szenario bezieht sich auf eine Transaktion T:

DB-Zustand vor BOT: {A, B, C} und nach EOT: {A, B', C}

Welche Aufgaben fallen an bei Rollback(T), Commit (T) und Restart?



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)

■ Atomares Einbringen (Atomic)

- Geänderte Seite wird in separaten Block auf Platte geschrieben, Einbringen in die DB erfolgt beim nächsten Sicherungspunkt (verzögertes Einbringen)
 - Laufende Seitentabelle gibt aktuelle Adresse einer Seite an
 - Atomares Einbringen mehrerer geänderter Seiten ist durch Umschalten von Seitentabellen möglich
- ⇒ *aktions- oder transaktionskonsistente DB auf Externspeicher (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, aus dem DB-Puffer verdrängt und

- bei **Non-Atomic** in die permanente DB eingebracht werden
- bei **Atomic** auf einen persistenten Speicher geschrieben werden

- + große Flexibilität bei Seitenersetzung
- + effektivere Puffernutzung bei langen TA mit vielen Änderungen
- Undo-Recovery erforderlich bei TA-Abbruch, Systemfehler usw.

⇒ 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**

- + keine Undo-Recovery auf der permanenten DB
- Seiten mit schmutzigen Änderungen dürfen nicht ersetzt werden

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte


Crash-Recovery

TA-Recovery


Medien-
Recovery

Steal / NoSteal - Beispiele

■ Beispiel: Einbringstrategie Non-Atomic



■ Beispiel: Einbringstrategie Atomic



Abhängigkeiten zur Ausschreibungsstrategie (EOT-Behandlung)

■ Force

Alle geänderten Seiten werden spätestens bei EOT (bei Commit) in die permanente DB eingebracht (Durchschreiben). Müssen sie vorher aus dem DB-Puffer verdrängt werden, werden sie

- bei **Non-Atomic** direkt in die permanente DB eingebracht
- bei **Atomic** auf einen persistenten Speicher geschrieben und von dort bei Commit in die permanente DB eingebracht

- + keine Redo-Recovery nach Rechnerausfall
- hoher Schreibaufwand bei Commit
- große DB-Puffer werden schlecht genutzt
- Antwortzeitverlängerung für Änderungs-TA

■ NoForce

Es besteht während oder am Ende der Transaktion kein Zwang, geänderte Seiten in die permanente DB einzubringen. Werden sie aus dem DB-Puffer verdrängt, werden sie

- bei **Non-Atomic** direkt in die permanente DB eingebracht
- bei **Atomic** auf einen persistenten Speicher geschrieben und von dort beim nächsten Sicherungspunkt in die permanente DB eingebracht

- + 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

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte


Crash-Recovery

TA-Recovery

Medien-
Recovery

Force/NoForce - Beispiele

■ Beispiel: Einbringstrategie Non-Atomic



■ Beispiel: Einbringstrategie Atomic

Force impliziert Einbringen, d.h. Erstellen eines transaktionsorientierten Sicherungspunktes



Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



persistenter
Speicher

Weitere Abhängigkeiten

- Wie wirken sich Ersetzungs- und Ausschreibungsstrategie 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**)



Test zur Fehlerbehandlung

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



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


■ Mögliche Antworten

- Tue überhaupt nichts
- Benutze die Undo-Information und setze zurück
- Benutze die Redo-Information und wiederhole
- WAL-Prinzip verhindert diese Situation
- Zwei-Phasen-Commit-Protokoll verhindert diese Situation

Commit-Behandlung

■ Änderungen einer TA

- sind vor Commit zu sichern
- für andere TA erst sichtbar, wenn Durchkommen der ändernden TA gewährleistet ist
- sonst: 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 sichtbar machen (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

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery

- **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 (eine oder mehrere Seiten)
 - Voraussetzung: physiologisches Logging oder Aktions-Logging
 - Ausschreiben des Log-Puffers erfolgt, wenn er voll ist bzw. Timer abläuft
 - nur geringe Commit-Verzögerung
 - **Gruppen-Commit erlaubt deutliche Reduktion der Log-E/As pro TA**
 - Einsparung an CPU-Overhead für E/A reduziert CPU-Wartezeiten
 - dynamische Festsetzung des Timer-Wertes durch DBMS wünschenswert
- ⇒ **Durchsatzverbesserung v.a. bei Log-Engpass oder hoher CPU-Auslastung**

Vergleich verschiedener Commit-Verfahren

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery


Medien-
Recovery



■ 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 (Crash)
- Ohne Sicherungspunkte müssten potentiell alle Änderungen seit Start des DBMS wiederholt werden
- besonders kritisch: **Hot-Spot-Seiten**



■ Repräsentation in der Log-Datei

- BEGIN_CHKPT-Satz
- Sicherungspunktinformationen, u. a. Liste der aktiven TA
- END_CHKPT-Satz

■ Log-Adresse des letzten Sicherungspunktsatzes wird in spezieller Restart-Datei geführt

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



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 usw.) werden in die Log-Datei geschrieben
- sehr geringer Sicherungspunktaufwand
- 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

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery


TA-Recovery

Medien-
Recovery

Transaktionsorientierte Sicherungspunkte

■ Force kann als spezieller Sicherungspunkttyp aufgefasst werden

- Nur die Seiten der TA, die Commit durchführt, werden ausgeschrieben
- Sicherungspunkt bezieht sich immer auf genau eine TA
- TOC = Transaction-Oriented Checkpoint \equiv Force



■ Eigenschaften

- EOT-Behandlung erzwingt das Ausschreiben aller geänderten Seiten der TA aus dem DB-Puffer
- bei atomarer Einbringstrategie:
 - DB-Zustand zum Sicherungszeitpunkt bleibt bis zum nächsten erhalten
 - Unter welcher Bedingung bleibt die DB stets **transaktionskonsistent**?

⇒ Zumindest bei nicht-atomarem Einbringen der Seiten ist Undo-Recovery vorzusehen (Steal)

■ Abhängigkeit: Non-Atomic, Force => Steal

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery


Medien-
Recovery



Transaktionskonsistente Sicherungspunkte

■ Direkter Sicherungspunkt

- 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 (Firewall)**
- bei atomarer Einbringstrategie:
 - DB-Zustand zum Sicherungszeitpunkt bleibt bis zum nächsten erhalten und
 - ist stets transaktionskonsistent

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery


Medien-
Recovery



Aktionskonsistente Sicherungspunkte

■ Direkter Sicherungspunkt

- Sicherungspunkt bezieht sich immer auf alle TA
- ACC = Action Consistent Checkpoints (aktions- oder operationskonsistent)




■ 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**
- bei atomarer Einbringstrategie:
 - DB-Zustand zum Sicherungszeitpunkt bleibt bis zum nächsten erhalten
 - Crash-Recovery vom letzten Sicherungspunkt aus: R2 vorwärts und R3 rückwärts; Reihenfolge von R2- und R3-Recovery ist unerheblich

■ 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
 - DB-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** (= $\text{MIN}(\text{StartLSN})$)
- **Sicherungspunktinformation**
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

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



**Einbring-
Strategie**


**Seiten-
ersetzung**

**EOT-
Behandlung**

**Sicherungs-
punkt**

**System-
beispiele**

Klassifikation von DB-Recovery-Verfahren



■ 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, d.h. 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

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte


Crash-Recovery

TA-Recovery

Medien-
Recovery

Nutzung von LSNs (2)

- Vereinfachte Anwendung: Seitensperren werden vorausgesetzt!



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

⇒ Seiten LSN wird bei Redo aktualisiert (wächst monoton)

Undo von T2: $S(20) < T2(40) :$ -, **OK!**

⇒ Wegen Seitensperren gilt im Recovery-Fall immer:
 LSN für Undo (S) > LSN für Redo (S)

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery


TA-Recovery

Medien-
Recovery



Nutzung von LSNs (3)

- Vereinfachte Anwendung⁹: Seitensperren werden vorausgesetzt



Redo von T1:	$S(50) > T1(10) :$	-
	$S(50) > T1(20) :$	-
Undo von T2:	$S(50) < T2(60) :$	-
	$S(50) \geq T2(50) :$	Undo
	$S(50) \geq T2(40) :$	Undo

⇒ Was passiert bei Crash im Restart?

9. In der graphischen Darstellung wird immer der persistente Zustand der DB (Seiten) und des Log (LSNs) gezeigt

■ Undo erfolgt in LIFO-Reihenfolge

- Undo muss speziell behandelt werden, so dass wiederholte Ausführung zum gleichen Ergebnis führt (**Idempotenz**)
- Was passiert, wenn nach Aktion ($S(50) \geq T2(50) : \text{Undo}$) und Einbringen der Seite S (flush (S)) ein Crash passiert?
- Zustands-Logging und LIFO-Reihenfolge gewährleisten Idempotenz!
⇒ **Aber bei Übergangslogging? Manchmal allgemeinere Lösung erforderlich: Kompensation von Undo wird später eingeführt**

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
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 und physiologische 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 operationskonsistent (z. B. aktionskonsistent)
⇒ interne Operationen (Aktionen) oder gar DML-Befehle ausführbar (logisches Logging)
- **Force:** ⇒ kein Redo
- **NoForce:**
 - transaktionskonsistentes Einbringen ⇒ Redo, jedoch kein Undo
 - aktionskonsistentes oder API-konsistentes Einbringen ⇒ Undo + Redo

Allgemeine Restart-Prozedur

■ Temporäre Log-Datei wird 3-mal gelesen

- **Analyse-Phase** (vom letzten Sicherungspunkt bis zum Log-Ende):
Bestimmung von **Gewinner-** und **Verlierer-TA** sowie der Seiten, die von ihnen geändert wurden
- **Redo-Phase**
Vorwärtslesen des Log: Startpunkt abhängig vom Sicherungspunkttyp: **Selektives Redo** bei Seitensperren (redo winners) oder **Repeating History** (vollständiges Redo) möglich
- **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 Sicherungspunkttyp: 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

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



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 Crashes während des Restart



- Was passiert bei Crash im Restart nach T1(20) : Redo, S(20), wenn
 - Seite S eingebracht war (flush(S))
 - Seite S noch nicht eingebracht war?

Restart - Beispiel

Grundlagen

Logging

Abhängigkeiten


Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



Restart – Beispiel (2)

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery

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 (3)

- **Annahme:** Zu Beginn seien alle Seiten-LSNs auf Null gesetzt
- **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**

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



Restart – Beispiel (4)

- **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_A			

Undo nur, wenn $\text{Seiten-LSN} \geq \text{Log-Satz-LSN}$

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

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery




Probleme bei LSN-Verwendung für Undo

Wiederholung der bisherigen Annahmen

- Selektives Redo (ist kosteneffektiv!)
- Einsatz von Seitensperren (wenn erforderlich, Redo immer vor Undo in einer Seite)
- Zustands-Logging

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: Satzsperrren

- Ausgangszustand der Seite S

S	LSN 5
	a
	b
	c

- T1 und T2 ändern gleichzeitig in Seite S



Redo von T1:

$S(10) \geq T1(10)$: 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


$$\text{Undo}(\text{Undo}(\dots(\text{Undo}(A))\dots)) = \text{Undo}(A)$$

$$\text{Redo}(\text{Redo}(\dots(\text{Redo}(A))\dots)) = \text{Redo}(A)$$

- 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 CLR bei allen Undo-Operationen: Rollback und Undo-Phase
- in der Redo-Phase: **Repeating History** von Gewinnern und Verlierern (vollständiges Redo)

■ 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!
- CLR benötigen keine Undo-Information, da sie während nachfolgender Undo-Phasen übersprungen werden (UndoNxtLSN)

CLR (2)

■ Detaillierung des Beispiels

- T1 Gewinner, T2 Verlierer
- Alle Änderungen betreffen Seite S; es müssen also **Satzsperr**en vorliegen
- Zustand nach Crash 1:



Repeating History

$S(40) > T1(10) : -$

...

$S(40) \geq T2(40) : -$

$S(40) < T1(50) : \text{Redo, } S(50)$

$S(50) < T1(60) : \text{Redo, } S(60)$

$S(60) < T2(70) : \text{Redo, } S(70)$

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 2

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery


Medien-
Recovery



CLR (3)

Fortsetzung des Beispiels

- Zustand nach Crash 2:



Repeating History

$S(80) > T1(10) : -$

...

$S(80) > T2(70) : -$

CLR(80) : -

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

Undo von T2

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

erfolgreiches Ende!

⇒ Repeating History bei Einsatz von CLR's ist auch sicher bei Satzsperrern!

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery


Medien-
Recovery



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 Sicherungspunkttyp: hier MinDirtyPageLSN
Repeating History: Wiederholung aller Änderungen in der DB (ggf. im DB-Puffer, auch die von Verlierer-TA), falls erforderlich
3. **Undo-Phase**
Rücksetzen der Verlierer-TA bis MinLSN




- **Umsetzung durch ARIES¹¹** (Algorithm for Recovery and Isolation Exploiting Semantics)

- entwickelt von C. Mohan et al. (IBM Almaden Research)
- realisiert in einer Reihe von kommerziellen DBS

11. C. Mohan, Donald J. Haderle, Bruce G. Lindsay, Hamid Pirahesh, Peter M. Schwarz: ARIES: A Transaction Recovery Method Supporting Fine-Granularity Locking and Partial Rollbacks Using Write-Ahead Logging, in: ACM Transactions on Database Systems 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 auf Null gesetzt
- **Analyse-Phase:** Gewinner-TA: T_1 ; Verlierer-TA: T_2 ; Relevante Seiten: P_A, P_B, P_C

Im Restart-Beispiel 2 wird **Repeating History** 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	Redo
T_1	P_B	0	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 sind rückwärts unabhängig von Seiten-LSN zu 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. CLR's 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. CLR's) sind rückwärts unabhängig von Seiten-LSN zu 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

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungspunkte

Crash-Recovery

TA-Recovery

Medien-Recovery




Zurücksetzen von Transaktionen

■ Transaktions-Recovery

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

■ Erweiterung zum partiellen Zurücksetzen innerhalb einer TA (R0)

- Voraussetzung: **transaktionsinterne Rücksetzpunkte** (*Savepoints*)



= atomarer Transaktionsschritt T_{1i}

$R(i)$ = i -ter Rücksetzpunkt

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

- Zusätzliche Operationen: Save $R(i)$
Restore $R(j)$
- Protokollierung aller Änderungen, Sperrungen, Cursor-Positionen, usw.
- **Undo-Operation** bis $R(j)$ in LIFO-Reihenfolge

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery


TA-Recovery

Medien-
Recovery



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

Umgebung

AW

DB



Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery

Allgemeine Regeln

- I. Recovery mit Übergangs-Logging setzt einen konsistenten DB-Zustand (bezüglich der protokollierten Operationen) zum Zeitpunkt der Recovery-Aktionen voraus.
- II. Das Sperrgranulat muss mindestens so groß wie das Log-Granulat sein.
- III. Nicht-atomare Einbringstrategien erfordern beim Restart erst Redo- bzw. Redo-All-(R2) und dann Undo-Recovery (R3). Bei atomaren Einbringstrategien ist dagegen die Reihenfolge von Undo- und Redo-Recovery unerheblich.

Regeln für Undo-Recovery

- IV. Zustands-Logging erfordert ein WAL-Verfahren (wenn Seiten vor Commit in die DB eingebracht werden).
- V. Für nicht-atomare Einbringstrategien ist Übergangs-Logging bei Redo- und Undo- Recovery generell nicht anwendbar.
- VI. Wenn das Log-Granulat kleiner als die Transporteinheit (Blockgröße) des Systems ist, kann ein Systemfehler Medien-Recovery (R4) erfordern.
- VII. Partielles Zurücksetzen innerhalb einer TA (R0) verletzt potenziell das 2PL-Protokoll (Programmierdisziplin erforderlich).

Regeln für Redo-Recovery

- VIII. Log-Information für Redo-Recovery muss unabhängig von den Maßnahmen für Undo-Recovery gesammelt werden.
- IX. Log-Information für Redo-Zwecke muss spätestens in Phase 1 von Commit geschrieben werden.
- X. Um die Wiederholbarkeit der Ergebnisse aller Transaktionen bei der Redo-Recovery mit logischem Übergangs-Logging zu garantieren, müssen ihre Änderungen transaktionsweise (im Einbenutzer-Modus) im der ursprünglichen Commit-Reihenfolge nachvollzogen werden.

■ 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

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery


Medien-
Recovery



Medien-Recovery – Ein Szenarium

Komponenten der Medien-Recovery

Normaler DB-Betrieb



Medien-Recovery

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

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



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 Medienfehler Archiv-Log ab Beginn der Dump-Erstellung anzuwenden
 - b2) Aktions- oder operationskonsistente Archivkopie**
(Voraussetzung bei Aktions- oder Operations-Logging)
 - b3) Transaktionskonsistente Archivkopie**
(Voraussetzung bei logischem Transaktions-Logging)
 - Black-/White-Verfahren
 - Copy-on-Update-Verfahren

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



■ Spezieller Dump-Prozess zur Erstellung der Archiv-Kopie

⇒ Erzeugung transaktionskonsistenter Archiv-Kopien

■ 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
- Dump-Prozess 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

Black-/White-Verfahren (2)

■ Beispiel



Annahme

- Integritätsbedingung in DB: $O1 = O5$ (in P1 und P5)
- DB bei t_1 : $O1 = 1$ in P1 und $O5 = 1$ in P5
- T3: $O1 = O1 + 1$ und $O5 = O5 + 1$
- nach t_5 :

DB:

AK:

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. 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)

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte


Crash-Recovery

TA-Recovery

Medien-
Recovery

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)

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery



- **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
 - Physiologisches Logging/Aktions-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 oder physiologisches Logging

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery

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 Sicherungspunktmaßnahmen 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 durch Einführung von CLR; 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 besten geeignet

Grundlagen

Logging

Abhängigkeiten

Commit

Sicherungs-
punkte

Crash-Recovery

TA-Recovery

Medien-
Recovery