Ludwig Maximilians Universität München
Institut für Informatik
Lehr- und Forschungseinheit für Datenbanksysteme

Skript zur Vorlesung

Datenbanksysteme II

Sommersemester 2006

Kapitel 3: Logging & Recovery

Vorlesung: Christian Böhm
Übungen: Elke Achtert, Peter Kunath, Alexey Pryakhin

http://www.dbs.informatik.uni-muenchen.de/Lehre/DBSII

Inhalt

Inhalt

Transaktions-Recovery

Transaktionsfehler

- Lokaler Fehler einer noch nicht festgeschriebenen TA, z.B. durch
  - Fehler im Anwendungsprogramm
  - Expliziter Abbruch der TA durch den Benutzer (`ROLLBACK`)
  - Verletzung von Integritätsbedingungen oder Zugriffsrechten
  - Rücksetzung aufgrund von Synchronisationskonflikten

- Behandlung durch **Rücksetzen**
  - *Lokales UNDO*: der ursprüngliche DB-Zustand wie zu BOT wird wiederhergestellt, d.h. Rücksetzen aller Aktionen, die diese TA ausgeführt hat
  - Transaktionsfehler treten relativ häufig auf
    → Behebung innerhalb von Millisekunden notwendig

Crash Recovery

Systemfehler

- Fehler mit Hauptspeicherverlust, d.h. permanente Speicher sind *nicht* betroffen, z.B. durch
  - Stromausfall
  - Ausfall der CPU
  - Absturz des Betriebssystems, …

- Behandlung durch **Crash Recovery** (Warmstart)
  - *Globales UNDO*: Rücksetzen aller noch nicht abgeschlossenen TAs, die bereits in die DB eingebracht wurden
  - *Globales REDO*: Nachführen aller bereits abgeschlossenen TAs, die noch nicht in die DB eingebracht wurden
  - Systemfehler treten i.d.R. im Intervall von Tagen auf
    → Recoverydauer einige Minuten

Geräte-Recovery

Medienfehler

- Fehler mit Hintergrundspeicherverlust, d.h. Verlust von permanenten Daten, z.B. durch
  - Plattencrash
  - Brand, Wasserschaden, …
  - Fehler in Systemprogrammen, die zu einem Datenverlust führen

- Behandlung durch **Geräte-Recovery** (Kaltstart)
  - Aufsetzen auf einem früheren, gesicherten DB-Zustand (Archivkopie)
  - *Globales REDO:* Nachführen aller TAs, die nach dem Erzeugen der Sicherheitskopie abgeschlossenen wurden
  - Medienfehler treten eher selten auf (mehrere Jahre)
    → Recoverydauer einige Stunden / Tage
  - Wichtig: regelmäßige Sicherungskopien der DB notwendig

Systemkomponenten der DB-Recovery

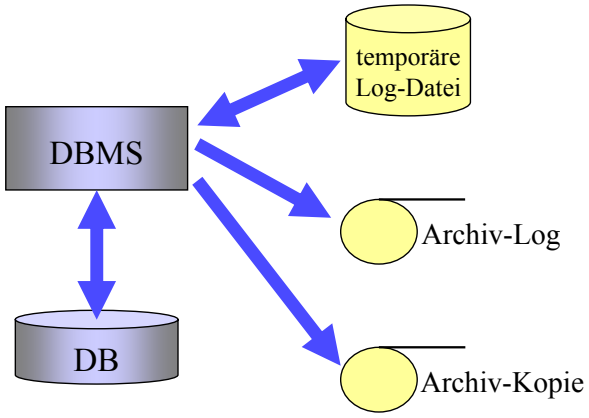

- Behandlung von Transaktions- und Systemfehlern

  DB + temporäre Log-Datei → DB

- Behandlung von Medienfehlern

  Archiv-Kopie + Archiv-Log → DB

Inhalt

1. Recovery-Arten
2. Logging-Techniken
3. Abhängigkeiten zu anderen Systemkomponenten
4. Sicherungspunkte

Aufgaben des Logging

- Für jede Änderungsoperation auf der Datenbank im Normalbetrieb (**DO**) benötigt man Protokolleinträge für
  - **REDO**: Information zum Nachvollziehen der Änderungen erfolgreicher TAs
  - **UNDO**: Information zum Zurücknehmen der Änderungen unvollständiger TAs

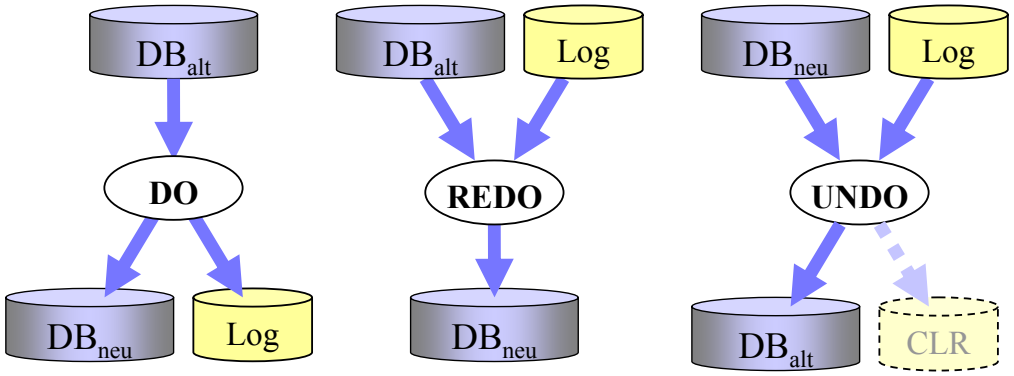

CLR = Compensation Log Record (zur Behandlung von Fehlern während der Recovery)

Klassifikation von Logging-Verfahren

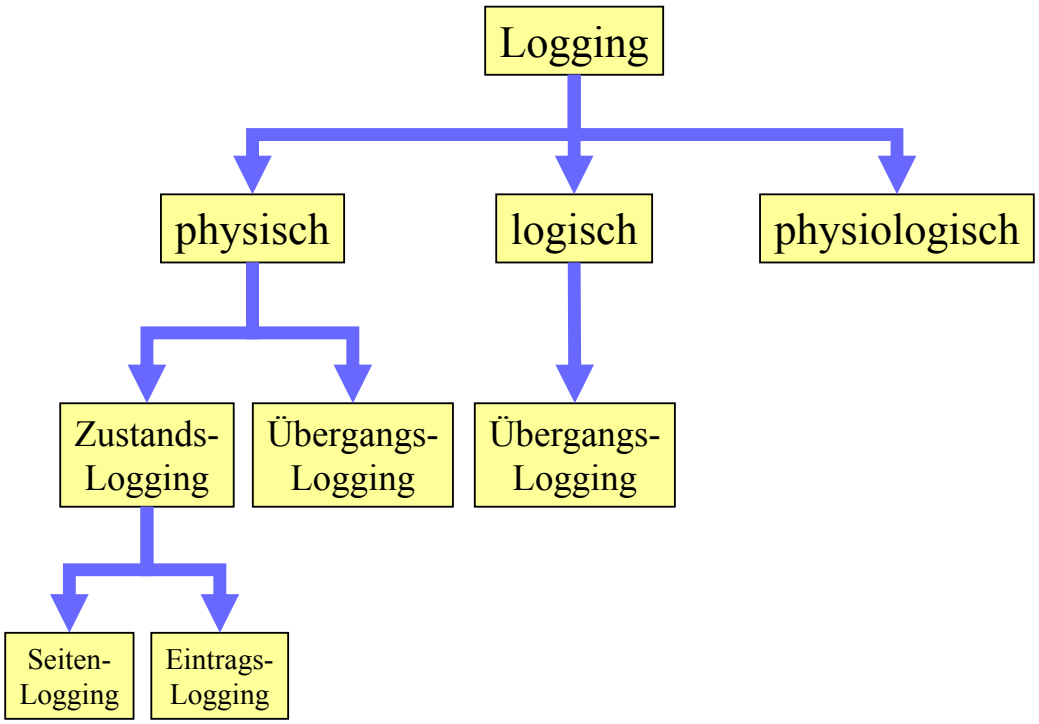

Physisches Logging (1)

- Protokoll auf der Ebene der physischen Objekte (Seiten, Datensätze, Indexeinträge)
- **Zustandslogging**
  - Protokollierung der Werte vor und nach jeder Änderung:
  - Alte Zustände *BFIM* (Before-Images) und neue Zustände *AFIM* (After-Images) der geänderten Objekte werden in die Log-Datei geschrieben
- **Zustandslogging auf Seitenebene**
  - vollständige Kopien von Seiten werden protokolliert
  - Recovery sehr einfach und schnell, da Seiten einfach zurückkopiert werden
  - sehr großer Logumfang und hohe I/O-Kosten auch bei nur kleinen Änderungen
  - Seitenlogging impliziert Seitensperren → hohe Konfliktrate bei Synchronisation

Physisches Logging (2)

- **Zustandslogging auf Eintragsebene**
  - statt ganzer Seiten werden nur tatsächlich geänderte Einträge protokolliert
  - kleinere Sperrgranulate als Seiten möglich
  - Protokollgröße reduziert sich typischerweise um mindestens eine Größenordnung
  - Log-Einträge werden in Puffer gesammelt → wesentlich weniger Plattenzugriffe
  - Recovery ist aufwändiger: zu ändernde Datenbankseiten müssen vollständig in den Hauptspeicher geladen werden, um die Log-Einträge anwenden zu können

Physisches Logging (3)

- **Übergangslogging**
  - Protokollierung der Zustandsdifferenz zwischen *BFIM* und *AFIM*
  - Aus *BFIM* muss *AFIM* berechenbar sein (u.u.)
  - Realisierbar durch *XOR*-Operation ⊕ (eXclusive-OR):

	Zustands-Logging	**Übergangs-Logging**
DO Änderung $A_{alt} \rightarrow A_{neu}$	Protokollierung von $BFIM = A_{alt}$, $AFIM = A_{neu}$	Protokollierung von $D = A_{alt} \oplus A_{neu}$
REDO (in DB liegt A_{alt})	Überschreibe A_{alt} mit *AFIM*	$A_{neu} = A_{alt} \oplus D$
UNDO (in DB liegt A_{neu})	Überschreibe A_{neu} mit *BFIM*	$A_{alt} = A_{neu} \oplus D$

XOR:
$0 \oplus 0 = 0$
$0 \oplus 1 = 1$
$1 \oplus 0 = 1$
$1 \oplus 1 = 0$

Logisches Logging (1)

- Spezielle Form des Übergangs-Logging: nicht physische Zustandsänderungen protokollieren, sondern Änderungs-operationen mit ihren aktuellen Parametern
- **Vorteil**: Protokoll auf hoher Abstraktionsebene ermöglicht kurze Log-Einträge
- **Probleme für *REDO***
  Änderungen umfassen typischerweise mehrere Seiten (Tabelle, Indexe)
  - Atomares Einbringen der Mehrfachänderungen schwierig.
  - Logische Änderungen sind aufwändiger durchzuführen als physische Änderungen

Logisches Logging (2)

- **Probleme für *UNDO***
  Mengenorientierte Änderungen können sehr aufwändige Protokolleinträge verursachen:
  - Bsp. `DELETE FROM Products WHERE Group = 'G1'`
    => *UNDO* erfordert viele Einfügungen, falls Produktgruppe G1 umfangreich ist
  - Bsp. `UPDATE Products SET Group = 'G2' WHERE Group = 'G1'`
    => *UNDO* muss alte und neue Produkte der Gruppe G2 unterscheiden

Physiologisches Logging

- Kombination von physischem und logischem Logging:
  Protokollierung von *elementaren Operationen innerhalb einer Seite*
- **Physical-to-a-page**
  - Protokollierungseinheiten sind geänderte Seiten
  - gut verträglich mit Pufferverwaltung und direktem (atomarem) Einbringen
- **Logical-within-a-page**
  - logische Protokollierung der Änderungen auf einer Seite
- **Bewertung**
  - Log-Einträge beziehen sich nicht auf mehrere Seiten wie bei logischem Logging
  - Dadurch einfachere Recovery als bei logischem Logging
  - Log-Datei ist länger als bei logischem Logging aber kürzer als bei physischem Logging
  - Flexibler als physisches Logging wegen variabler Objektpositionen auf Seiten.

Aufbau der Log-Datei (1)

- **Art der Protokolleinträge**
  - Beginn, Commit und Rollback von Transaktionen
  - Änderungen des DB-Zustandes durch Transaktionen
  - Sicherungspunkte (Checkpoints)
- **Struktur der Log-Einträge für Änderungen**
  (LSN, TA-Id, Page-Id, REDO, UNDO, PrevLSN)
  - *LSN* (*Log Sequence Number*): eindeutige Kennung des Log-Eintrags in chronologischer Reihenfolge
  - *TA-Id*: eindeutige Kennung der TA, die die Änderung durchgeführt hat
  - *Page-Id* : Kennung der Seite auf der die Änderungsoperation vollzogen wurde (ein Eintrag pro geänderter Seite)
  - *REDO*: gibt an, wie die Änderung nachvollzogen werden kann
  - *UNDO*: beschreibt, wie die Änderung rückgängig gemacht werden kann
  - *PrevLSN*: Zeiger auf vorhergehenden Log-Eintrag der jeweiligen TA (Effizienzgründe)

Aufbau der 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 beendetet TA werden nicht mehr benötigt
  - Nach Einbringen der Seite in die DB wird *REDO*-Information nicht mehr benötigt
- REDO-Information für **Geräte-Recovery** ist im Archiv-Log zu sammeln

Aufbau der Log-Datei (3)

- **Ringpuffer-Organisation** der Log-Datei

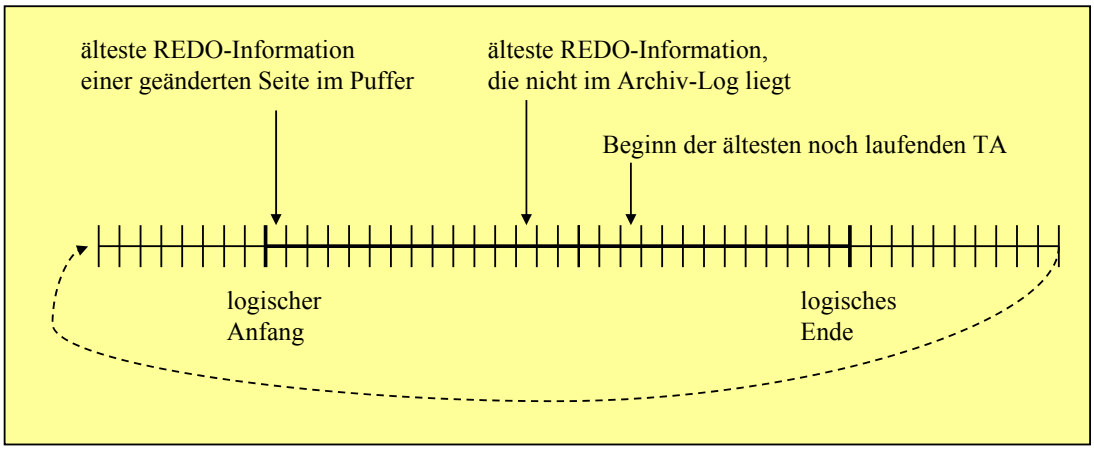

Beispiel einer Log-Datei

Ablauf T_1	**Ablauf T_2**	**Log-Eintrag** *(LSN, TA-Id, Page-Id, REDO, UNDO, PrevLSN)*
begin		(#1, T_1, begin, 0)
read(A, a_1)		
	begin	(#2, T_2, begin, 0)
	read(C, c_2) //80	
$a_1 := a_1 - 50$		
write(A, a_1)		(#3, T_1, p_A, A-=50, A+=50, #1)
	$c_2 := 100$	
	write(C, c_2)	(#4, T_2, p_C, C=100, C=80, #2)
read(B, b_1) //70		
$b_1 := 50$		
write(B, b_1)		(#5, T_1, p_B, B=50, B=70, #3)
commit		(#6, T_1, commit, #5)
	read(A, a_2)	
	$a_2 := a_2 - 100$	
	write(A, a_2)	(#7, T_2, p_A, A-=100, A+=100, #4)
	commit	(#8, T_2, commit, #7)

(hier: logisches Logging)

Inhalt

1. Recovery-Arten
2. Logging-Techniken
3. Abhängigkeiten zu anderen Systemkomponenten
4. Sicherungspunkte

Abhängigkeiten zu anderen Systemkomponenten

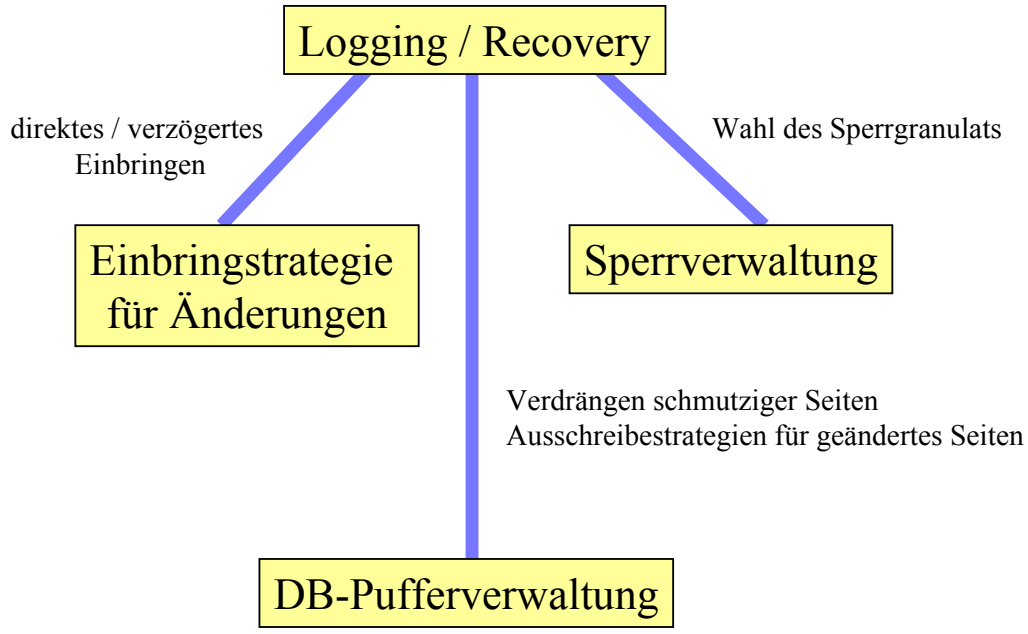

Einbringstrategien (1)

- **Direktes Einbringen (*NonAtomic, Update-in-Place*)**
  - Geänderte Objekte werden immer auf denselben Block auf Platte zurück geschrieben
  - Schreiben ist dadurch gleichzeitig Einbringen in die permanente DB
  - Atomares Einbringen mehrere Seiten ist nicht möglich, d.h. Unterbrechungsfreiheit des Einbringens kann nicht garantiert werden (*NonAtomic*).

Einbringstrategien (2)

- **Indirektes (verzögertes) Einbringen (*Atomic*)**
  - Ziel: Einbringen in die Datenbank wird unterbrechungsfrei durchgeführt
  - Geänderte Seite wird in separaten Block auf Platte geschrieben (z.B. *Schattenspeichertechnik* oder *Twin-Block*-Verfahren)
  - Einbringen in die DB kann von *COMMIT* losgelöst werden und z.B. erste beim nächsten Sicherungspunkt stattfinden (*verzögertes* Einbringen)
  - Atomares Einbringen mehrerer geänderter Seiten ist durch Umschalten von Seitentabellen möglich (*Atomic*)
  - Alte Versionen der Objekte bleiben erhalten, d.h. es muss keine *UNDO*-Information explizit gespeichert werden

Einfluss des Sperrgranulats

- Log-Granulat muss kleiner oder gleich dem Sperrgranulat sein, sonst Lost Updates möglich
- D.h. Satzsperren erzwingen feine Log-Granulate
- Beispiel für Problem bei "Satzsperren mit Seitenlogging"

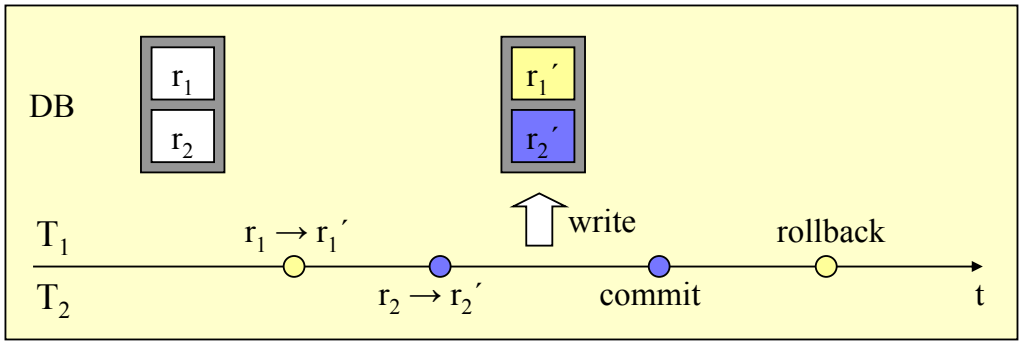

  - T_1 und T_2 ändern die Datensätze r_1 und r_2, die auf derselben DB-Seite liegen
  - Die Seite wird in die DB zurück geschrieben, T_2 endet mit *COMMIT*
  - Falls T_1 zurückgesetzt wird, geht auch die Änderung r_2 —> r_2' verloren
  - Lost Update, d.h. eklatanter Verstoß gegen die Dauerhaftigkeit des *COMMIT*

Pufferverwaltung (1)

- **Verdrängungsstrategien**
  Ersetzung „schmutziger" Seiten im Puffer, d.h. $Seite_{Puffer} \neq Seite_{DB}$
  - **No-Steal**
    - Schmutzige Seiten dürfen nicht aus dem Puffer entfernt werden
    - DB enthält keine Änderungen nicht-erfolgreicher TAs
    - *UNDO*-Recovery ist nicht erforderlich
    - Probleme bei langen Änderungs-TAs, da große Teile des Puffers blockiert werden
  - **Steal**
    - Schmutzige Seiten dürfen jederzeit ersetzt und in die DB eingebracht werden
    - DB kann unbestätigte Änderungen enthalten
    - *UNDO*-Recovery ist erforderlich
    - effektivere Puffernutzung bei langen TAs mit vielen Änderungen

Pufferverwaltung (2)

- **Ausschreibestrategien** (*EOT*-Behandlung)
  - **Force**
    - Alle geänderte Seiten werden spätestens bei *EOT* (vor *COMMIT*) in die DB geschrieben
    - keine *REDO*-Recovery erforderlich bei Systemfehler
    - sehr hoher I/O-Aufwand, da Änderungen jeder TA einzeln geschrieben werden
    - Vielzahl an Schreibvorgängen führt zu schlechteren Antwortzeiten, länger gehaltenen Sperren und damit zu mehr Sperrkonflikten
    - Große DB-Puffer werden schlecht genutzt
  - **No-Force**
    - Änderungen können auch erst nach dem *COMMIT* in die DB geschrieben werden
    - Beim *COMMIT* werden lediglich *REDO*-Informationen in die Log-Datei geschrieben
    - *REDO*-Recovery erforderlich bei Systemfehler
    - Änderungen auf einer Seite über mehrere TAs hinweg können gesammelt werden

Pufferverwaltung (3)

- Kombination der Verdrängungs- und Ausschreibestrategien

	No-Steal	**Steal**
Force	kein *UNDO* – kein *REDO* (nicht für Update-in-Place)	*UNDO* – kein *REDO*
No-Force	kein *UNDO* –*REDO*	*UNDO* –*REDO*

- Bewertung **Steal / No-Force**
  - erfordert zwar *UNDO* als auch *REDO*, ist aber allgemeinste Lösung
  - beste Leistungsmerkmale im Normalbetrieb
- Bewertung **No-Steal / Force**
  - optimiert den Fehlerfall auf Kosten des Normalfalls (sehr teures *COMMIT*)
  - für *Update-in-Place* nicht durchführbar:
    - wegen *No-Steal* dürfen Änderungen erst nach *COMMIT* in die DB gelangen, was jedoch *Force* widerspricht (*No-Steal* → *No-Force*)
    - wegen *Force* müssten Änderungen vor dem *COMMIT* in der DB stehen, was bei *Update-in-Place* unterbrochen werden kann, *UNDO* wäre nötig (*Force* → *Steal*)

WAL-Prinzip und COMMIT-Regel

Fundamentale Regeln zum korrekten Wiederanlauf im Fehlerfall:

- **WAL-Prinzip (*Write-Ahead-Log*)**
  - *UNDO*-Information (z.B. *BFIM*) muss vor Änderung der DB im Protokoll stehen
  - Wichtig, um schmutzige Änderungen rückgängig machen zu können
  - Nur relevant für *Steal*
  - Wichtig bei direktem Einbringen
- **COMMIT-Regel (*Force-Log-at-Commit*)**
  - *REDO*-Information (z.B. *AFIM*) muss vor dem *COMMIT* im Protokoll stehen
  - Vorraussetzung zur Durchführbarkeit der Crash-Recovery bei *No-Force*
  - Erforderlich für Geräte-Recovery (auch bei *Force*)
  - Gilt für direkte und indirekte Einbringstrategien gleichermaßen

- Bemerkung:
  Um die chronologische Reihenfolge im Ringpuffer zu wahren, werden alle Log-Einträge bis zum letzten notwendigen ausgeschrieben, d.h. es werden keine Log-Einträge übergangen

COMMIT-Verarbeitung (1)

- **Standard Zwei-Phasen-Commit**

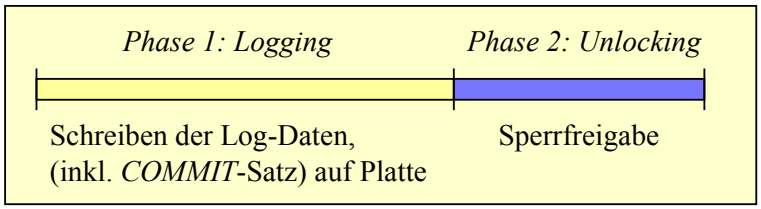

  - *Phase 1: Logging*
    - Überprüfen der verzögerten Integritätsbedingungen
    - Logging der *REDO*-Informationen incl. *COMMIT*-Satz
  - *Phase 2: Unlocking*
    - Freigabe der Sperren (Sichtbarmachen der Änderungen)
    - Bestätigung des *COMMIT* an das Anwendungsprogramm
  - *Problem*: COMMIT-Regel verlangt Ausschreiben des Log-Puffers bei jedem *COMMIT*
    - Beeinträchtigung für kurze TAs, deren Log-Daten weniger als eine Seite umfassen
    - Durchsatz an TAs ist eingeschränkt

COMMIT-Verarbeitung (2)

- **Gruppen-Commit**

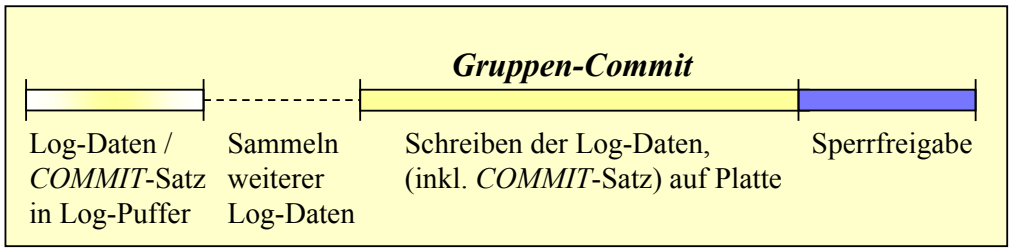

  - Log-Daten mehrerer Transaktionen werden im Puffer gesammelt
  - Log-Puffer wird auf Platte geschrieben, sobald Puffer gefüllt ist oder nach Timeout
  - Vorteil: Reduktion der Plattenzugriffe und höhere Transaktionsraten möglich
  - Nachteil: längere Sperrdauer führt zu längeren Antwortzeiten
  - wird von zahlreichen DBS unterstützt

COMMIT-Verarbeitung (3)

- **Prä-Commit**

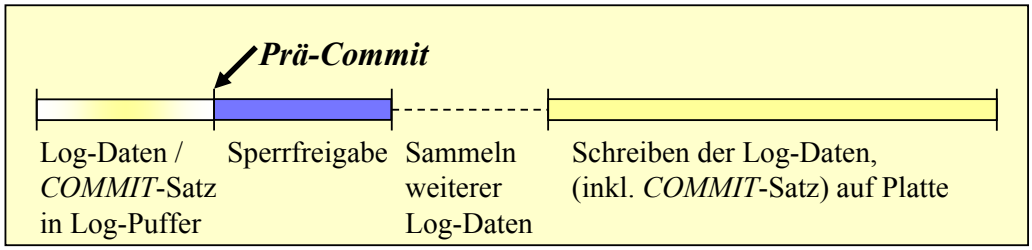

  - Vermeidung der langen Sperrzeiten des Gruppen-Commit indem Sperren bereits freigegeben werden, wenn *COMMIT*-Satz im Log-Puffer steht
  - Ist Prä-Commit zulässig?
    - *Normalfall*: ändernde TA kommt erfolgreich zu Ende, Änderungen sind gültig
    - *Fehlerfall*: Abbruch der TA nur noch durch Systemfehler möglich; bei Systemfehler werden auch die anderen laufenden TAs abgebrochen, “schmutziges Lesen” kann sich also nicht auf DB auswirken

Inhalt

Sicherungspunkte (1)

- Maßnahme zur Begrenzung des *REDO*-Aufwands nach Systemfehlern
- Ohne Sicherungspunkte müssten potentiell alle Änderungen seit Start des DBMS wiederholt werden
- Besonders kritisch: Hot-Spot-Seiten, die (fast) nie aus dem Puffer verdrängt werden

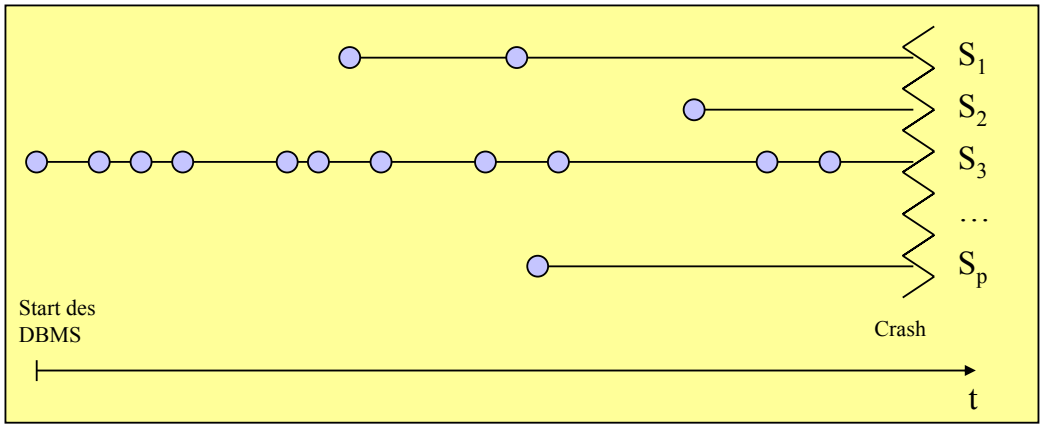

Sicherungspunkte (2)

- **Durchführung von Sicherungspunkten**
  - Spezielle Log-Einträge:
    BEGIN_CHKPT
    Info über laufende TAs
    END_CHKPT
  - *LSN* des letzten vollständig ausgeführten Sicherungspunktes wird in Restart-Datei geführt
- **Häufigkeit von Sicherungspunkten**
  - *zu selten*: hoher *REDO*-Aufwand
  - *zu oft*: hoher Overhead im Normalbetrieb
  - z.B. Sicherungspunkte nach bestimmter Anzahl von Log-Sätzen einfügen

Direkte Sicherungspunkte

- **Charakterisierung**
  - Alle geänderten Seiten werden in die persistente DB (Platte) geschrieben
  - Zeitbedarf steigt mit dem zeitlichen Abstand der Sicherungspunkte
  - Multi-Page-Access hilft, Schreibkopf-Positionierungen zu minimieren
  - *REDO*-Recovery kann beim letzten vollständig ausgeführten Checkpoint beginnen
- **3 Arten**
  - Transaktions-orientierte Sicherungspunkte (**TOC**)
  - Transaktions-konsistente Sicherungspunkte (**TCC**)
  - Aktions-konsistente Sicherungspunkte (**ACC**)

Transaktions-orientierte Sicherungspunkte: TOC (1)

- **TOC = *Force***, d.h. Ausschreiben aller Änderungen beim *COMMIT*
- Nicht alle Seiten im Puffer werden geschrieben, sondern nur Änderungen der jeweiligen TA
- Sicherungspunkt bezieht sich immer auf genau eine TA
- ***UNDO*-Recovery**
  Bei *Update-in-Place* ist *UNDO* nötig (*Force* → *Steal),*
  UNDO beginnt dann beim letzten Sicherungspunkt
- ***REDO*-Recovery** nicht nötig

Transaktions-orientierte Sicherungspunkte: TOC (2)

- **Vorteile:**
  - keine *REDO* nötig
  - Implementierung ist einfach in Kombination mit Seitensperren
- **Nachteil:** (sehr) aufwändiger Normalbetrieb, insbesondere für Hot-Spot-Seiten
- **Beispiel:** Sicherungspunkte bei *COMMIT* von T_1 und T_2, deshalb kein *REDO* nötig

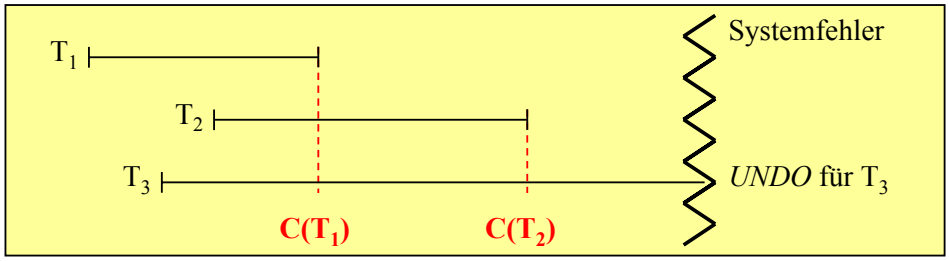

Transaktions-konsistente Sicherungspunkte: TCC (1)

- DB wird in TA-konsistenten Zustand gebracht, d.h. keine schmutzigen Änderungen
- Während der Sicherung dürfen keine Änderungs-TAs aktiv sein
- Sicherungspunkt bezieht sich immer auf alle TAs
- ***UNDO***- und ***REDO*-Recovery** sind durch letzten Sicherungspunkt begrenzt
- **Ablauf:**
  - Anmeldung des Sicherungspunktes
  - Warten, bis alle Änderungs-TAs abgeschlossen sind
  - Erzeugen des Sicherungspunktes
  - Verzögerung neuer Änderungs-TAs bis zum Abschluss der Sicherung

Transaktions-konsistente Sicherungspunkte: TCC (2)

- **Vorteil:** *UNDO*- und *REDO*-Recovery beginnen beim letzten Sicherungspunkt (im Beispiel: C_i), d.h. es sind nur TAs betroffen, die nach der letzten Sicherung gestartet wurden (hier: T_3, T_4)
- **Nachteil:** lange Wartezeiten ("Totzeiten") im System
- **Beispiel:**

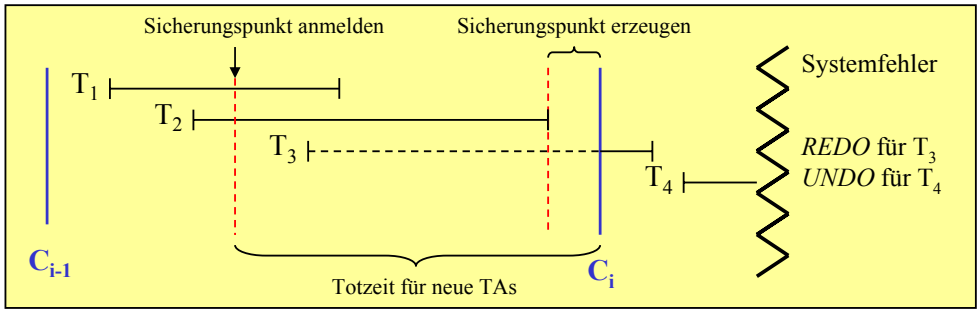

Aktions-konsistente Sicherungspunkte: ACC (1)

- Blockierung nur auf Operationenebene, nicht mehr für ganze TAs
- Keine Änderungsoperationen während der Sicherung
- ***UNDO*-Recovery** beginnt bei *MinLSN* = kleinste *LSN* aller noch aktiven TAs des letzten Sicherungspunktes
- ***REDO*-Recovery** durch letzten Sicherungspunkt begrenzt
- **Ablauf:**
  - Anmelden des Sicherungspunktes
  - Beendigung aller laufenden Änderungsoperationen abwarten (im Beispiel: T_4)
  - Erzeugen des Sicherungspunktes
  - Verzögerung neuer Änderungsoperationen bis zum Abschluss der Sicherung (im Beispiel: T_1)

Aktions-konsistente Sicherungspunkte: ACC (2)

- **Vorteil:** Totzeit des Systems für Änderungen deutlich reduziert
- **Nachteil:** Geringere Qualität der Sicherungspunkte
  - schmutzige Änderungen können in die Datenbank gelangen
  - zwar *REDO*-, nicht jedoch *UNDO*-Recovery durch letzten Sicherungspunkt begrenzt
- **Beispiel:**

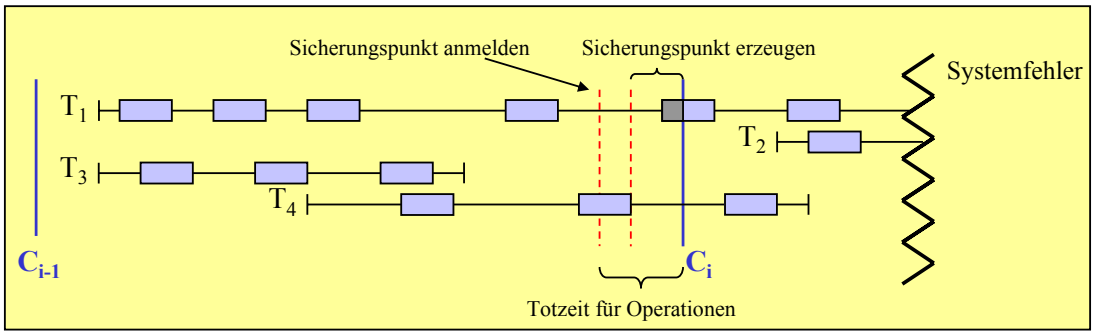

Indirekte Sicherungspunkte (1)

- **Charakterisierung**
  - Direkte Sicherungspunkte: hoher Aufwand bei großen DB-Puffern nicht akzeptabel
  - Indirekte Sicherungspunkte: Änderungen werden nicht vollständig ausgeschrieben
  - DB hat keinen Aktions- oder TA-konsistenten Zustand, sondern *unscharfen* (*fuzzy*) Zustand
- **Erzeugung** eines indirekten Sicherungspunktes
  - im wesentlichen Logging des Status von laufenden TAs und geänderten Seiten
  - minimaler Schreibaufwand, keine nennenswerte Unterbrechung des Betriebs

Indirekte Sicherungspunkte (2)

- **Ausschreiben von DB-Änderungen**
  - außerhalb der Sicherungspunkte, asynchron zur laufenden TA-Verarbeitung
  - länger nicht mehr referenzierte Seiten werden vorausschauend ausgeschrieben
  - Sonderbehandlung für Hot-Spot-Seiten nötig, die praktisch nie ersetzt werden:
    - zwangsweises Ausschreiben bei bestimmtem Log-Umfang
    - Anlegen einer Kopie, um keine Verzögerung für neue Änderungen zu verursachen
- ***UNDO*-Recovery** beginnt bei *MinLSN*
- ***REDO*-Recovery**
  - Startpunkt ist nicht mehr durch letzten Sicherungspunkt gegeben, auch weiter zurückliegende Änderungen müssen ggf. wiederholt werden
  - Zu jeder geänderten Seite wird *StartLSN* vermerkt (*LSN* der 1. Änderung seit Einlesen von Platte)
  - *REDO* beginnt bei *MinDirtyPageLSN* = min (*StartLSN*)

Indirekte Sicherungspunkte (3)

- **Beispiel:**
  - beim Sicherungspunkt stehen S_1 und S_2 geändert im Puffer
  - älteste noch nicht ausgeschriebene Änderung ist auf Seite S_2
  - *MinDirtyPageLSN* hat also den Wert 30, dort muss *REDO*-Recovery beginnen

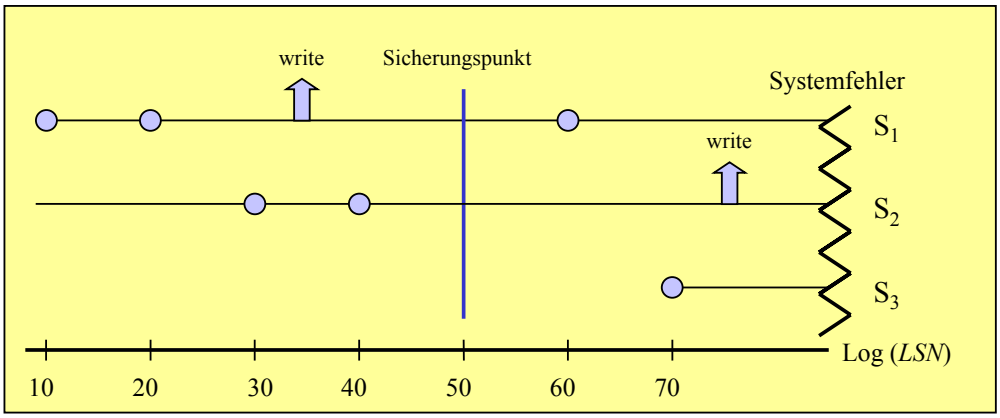

Allgemeine Prozedur der Crash-Recovery (1)

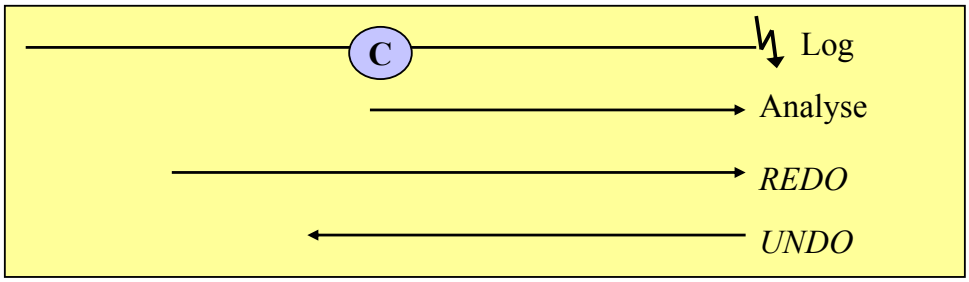

1. Analyse-Phase

- Lies Log-Datei vom letzten Sicherungspunkt bis zum Ende
- Bestimmung von Gewinner- und Verlierer-TAs, sowie der Seiten, die von ihnen geändert wurden
  - *Gewinner*: TAs, für die ein *COMMIT*-Satz im Log vorliegt
  - *Verlierer*: TAs, für die ein *ROLLBACK*-Satz bzw. kein *COMMIT*-Satz vorliegt
- Ermittle alle weiteren Seiten, die nach dem Checkpoint geändert wurden

Allgemeine Prozedur der Crash-Recovery (2)

***2. REDO*-Phase**

- Vorwärtslesen der Log-Datei: Startpunkt ist abhängig vom Sicherungspunktyp
- Aufgabe: Wiederholen der Änderungen, die noch nicht in der DB vorliegen
- zwei Ansätze:
  - vollständiges *REDO* (*redo all*): Alle Änderungen werden wiederholt
  - selektives *REDO*: Nur die Änderungen der Gewinner-TAs werden wiederholt

Allgemeine Prozedur der Crash-Recovery (3)

3. *UNDO*-Phase

- Rückwärtslesen der Log-Datei bis zum *BOT*-Satz der ältesten Verlierer TA
- Aufgabe: Zurücksetzen der Verlierer-TAs
- Fertig wenn Beginn der ältesten TA erreicht ist, die bei letztem Checkpoint aktiv war
- abhängig von *REDO*-Vorgehen:
  - vollständiges *REDO*: nur zum Fehlerzeitpunkt noch laufende TAs zurücksetzen
  - selektives *REDO*: alle Verlierer-TAs zurücksetzen (beendete und unbeendete)

4. Abschluß der Recovery durch einen Sicherungspunkt

Durchführung des REDO

Technik

- *PageLSN* im Seitenkopf kennzeichnet letzte Speicherung der Seite ("Versionsnr.")
- REDO nur erforderlich für Änderungen, deren *LSN* größer als die *PageLSN* ist
- Anwendung des Logeintrags L auf die Seite B

```
IF (B nicht im Puffer) THEN (lies B in Hauptspeicher ein) ENDIF;
IF LSN(L) > PageLSN(B) THEN REDO (Änderungen aus L);
PageLSN(B) := LSN(L); ENDIF;
```

i) Vollständiges REDO

- Alle Änderungen von Gewinner- und von Verlierer-TAs werden wiederholt
- *PageLSN* wird nur für REDO, nicht für UNDO herangezogen
- UNDO für alle Änderungen nicht beendeter Verlierer-TAs

ii) Selektives REDO

- nur die Änderungen der Gewinner-TAs werden wiederholt
- UNDO nur für ausgeschriebene Änderungen, d.h. $LSN \leq PageLSN$