Datenbanken

Prof. Dr. Ralf Möller
Universität zu Lübeck
Institut für Informationssysteme

Karsten Martiny (Übungen)

Transaktionsverwaltung

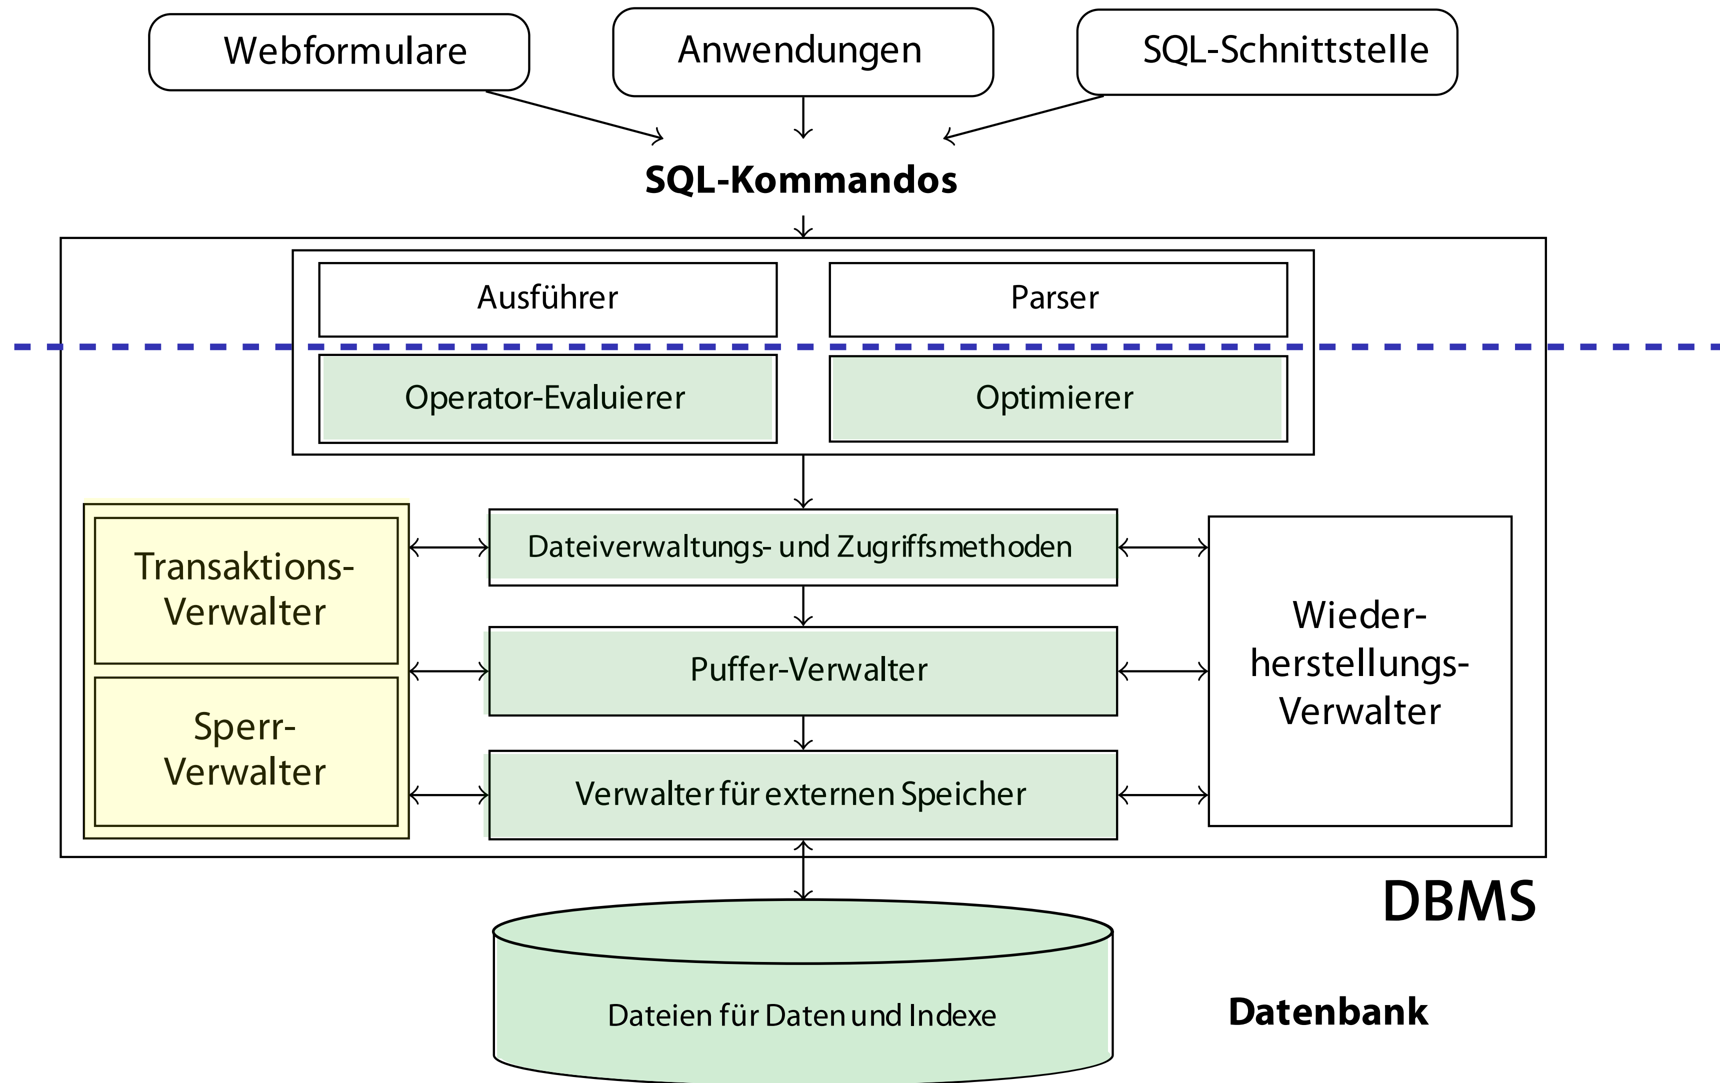

Danksagung

- Diese Vorlesung ist inspiriert von den Präsentationen zu dem Kurs:

  „Architecture and Implementation of Database Systems“ von Jens Teubner an der ETH Zürich

- Graphiken und Code-Bestandteile wurden mit Zustimmung des Autors (und ggf. kleinen Änderungen) aus diesem Kurs übernommen

Eine einfache Transaktion

- Ab und zu verwende ich meine Kreditkarte, um Geld von meinem Konto abzuheben
- Der Bankautomat führt folgende Transaktion auf der Datenbasis der Bank aus

1. $bal \leftarrow$ `read_bal` $(acct_no)$;
2. $bal \leftarrow bal - 100$ CHF ;
3. `write_bal` $(acct_no, bal)$;

- Wenn alles fehlerfrei abläuft, wird mein Konto richtig verwaltet

Nebenläufiger Zugriff

Mein Frau verwendet eine Karte für das gleiche Konto…

- Eventuell verwenden wir unsere Karten zur gleichen Zeit

me	my wife	DB state
$bal \leftarrow$ `read` $(acct)$;		1200
	$bal \leftarrow$ `read` $(acct)$;	1200
$bal \leftarrow bal - 100$;		1200
	$bal \leftarrow bal - 200$;	1200
`write` $(acct, bal)$;		1100
	`write` $(acct, bal)$;	1000

- Die erste Aktualisierung des Kontos
  ist verlorengegangen: Mich freut's! Allerdings…

... kann es auch nach hinten losgehen

- Diesmal wird Geld von einem Konto auf ein anderes transferiert

```
   // Subtract money from source (checking) account
1  chk_bal ← read_bal (chk_acct_no) ;
2  chk_bal ← chk_bal − 500 CHF ;
3  write_bal (chk_acct_no, chk_bal) ;
   // Credit money to the target (saving) account
4  sav_bal ← read_bal (sav_acct_no) ;
5  sav_bal ← sav_bal + 500 CHF ;
6  write_bal (sav_acct_no, sav_bal) ;
```

- Bevor die Transaktion zum Schritt 6 kommt, wird die Ausführung abgebrochen (Stromversorgungsproblem, Plattenproblem, Softwarefehler, ...).
- Mein Geld ist verschwunden ☹

ACID-Eigenschaften und Transaktionen

Um diese und viele andere Effekte zu vermeiden, stellen DMBS folgende Eigenschaften sicher

- **A**tomicity: Entweder werden alle oder keine Werteänderungen einer Transaktion in den Datenbankzustand übernommen
- **C**onsistency: Eine Transaktion überführt einen konsistenten Zustand (FDs, Integritätsbedingungen) in einen anderen
- **I**solation: Eine Transaktion berücksichtigt bei der Berechnung keine Effekte andere parallel laufender Transaktionen
- **D**urability: Effekte einer erfolgreichen Transaktion werden persistent gemacht

Anomalien: Lost Update

- Wir haben schon „Lost Update“ im Beispiel betrachtet
- Effekte einer Transaktion gehen verloren, weil eine andere Transaktion geänderte Werte unkontrolliert überschreibt

Anomalien: Inconsistent Read

Betrachten wir die Überweisung in SQL

Transaction 1	Transaction 2
`UPDATE Accounts SET balance = balance - 500 WHERE customer = 4711 AND account_type = 'C';`	
	`SELECT SUM(balance) FROM Accounts WHERE customer = 4711;`
`UPDATE Accounts SET balance = balance + 500 WHERE customer = 4711 AND account_type = 'S';`	

- ➢ Transaktion 2 sieht einen inkonsistenten Zustand

Anomalien: Dirty Read

An einem anderen Tag heben meine Frau und ich zur gleichen Zeit Geld vom Automaten ab

me	my wife	DB state
$bal \leftarrow$ `read` $(acct)$;		1200
$bal \leftarrow bal - 100$;		1200
`write` $(acct, bal)$;		1100
	$bal \leftarrow$ `read` $(acct)$;	1100
	$bal \leftarrow bal - 200$;	1100
`abort` ;		1200
	`write` $(acct, bal)$;	900

- Die Transaktion meiner Frau hat schon einen geänderten Zustand gelesen bevor meine Transaktion zurückgerollt wird

Nebenläufige Ausführung

- Ein Steuerprogramm (Scheduler) entscheidet über die Ausführungsreihenfolge der nebenläufigen Datenbankzugriffe

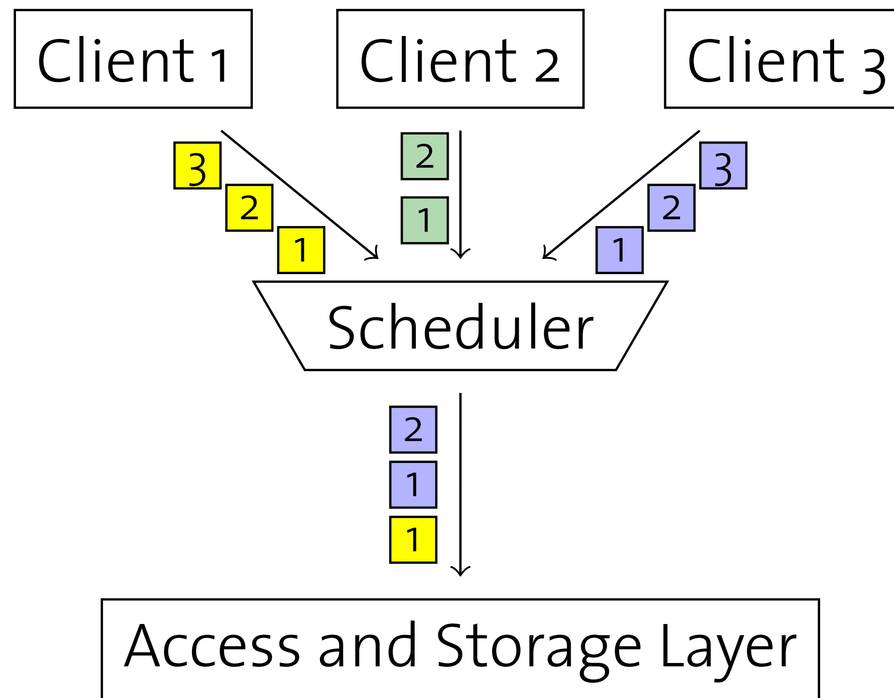

Datenbankobjekte und Zugriffe daraus

- Wir nehmen ein vereinfachtes Datenmodell an
  - Eine Datenbank besteht aus einer Menge von benannten Objekten. In jedem Zustand hat ein Objekt einen Wert.
  - Transaktionen greifen auf ein Objekt o mit den Operationen read und write zu

- In einer relationalen DB haben wir:
  Objekt ≙ Komponente eines Tupels

Transaktion: Definition

- Eine Datenbanktransaktion ist eine (strikt geordnete) Folge von Schritten, wobei ein Schritt eine Zugriffsoperation auf ein Objekt ist
  - Transaktion $T = \langle s_1, ..., s_n \rangle$
  - Schritt $s_i = a_i(e_i)$
  - Zugriffsoperation $a_i \in \{ r(ead), w(rite) \}$
- Die Länge einer Transaktion ist definiert als die Anzahl der Schritte $|T| = n$
- Beispiel: $T = \langle r(A), w(A), r(B), w(B) \rangle$
- Abarbeitung durch Mischung der Schritte mehrerer Transaktionen (Sequenzieller Plan, Sequenz, S)

Serielle Ausführung

Ein spezieller sequentieller Plan ist die serielle Ausführung

- Ein Plan heißt seriell genau dann, wenn für jede Transaktion T_j alle ihre Schritte direkt aufeinanderfolgen (ohne Schritte anderer Transaktion dazwischen)

Betrachten wir das Geldautomatenbeispiel:

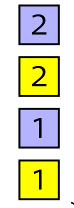

- $S = \langle r_1(B), r_2(B), w_1(B), w_2(B) \rangle$
- Dieser Plan ist nicht seriell

Wenn meine Frau später zum Automaten geht, ergibt sich

- $S = \langle r_1(B), w_1(B), r_2(B), w_2(B) \rangle$
- Dieser Plan ist seriell

Korrektheit der seriellen Ausführung

- Anomalien können nur auftreten, wenn die Schritte mehrerer Transaktionen verschränkt ausgeführt werden (Multi-User-Modus)
- Falls alle Transaktionen bis zum Ende ausgeführt werden (keine Nebenläufigkeit), treten keine Anomalien auf
- Jede serielle Ausführung ist korrekt
- Verzicht auf nebenläufige Ausführung nicht praktikabel, da zu langsam (Wartezeit auf Platten)
- Jede verschränkte Ausführung, die einen gleichen Zustand wie eine serielle erzeugt, ist korrekt

Abarbeitungsreihenfolge

- Vorstellung: Sequentieller Plan gegeben
- Manchmal kann man einfach Teilschritte aus verschiedenen Transaktionen in einem Plan umordnen
  - Nicht jedoch die Teilschritte innerhalb einer einzelnen Transaktion (sonst eventuell anderes Ergebnis)
- Jeder Plan S‘, der durch legale Umordnung von S generiert werden kann, heißt äquivalent zu S
- Falls Umordnung nicht möglich weil Ergebnis verfälscht → Konflikt
- Wie ist das definierbar?

Konflikte

Ausführbare Definition eines Konflikts:

- Zwei Operationen $a_i(e)$ und $a'_j(e')$ stehen in Konflikt zueinander in S, wenn
  - sie zu zwei verschiedenen Transaktionen gehören $i \neq j$
  - sie das gleiche Objekte referenzieren $(e = e')$ und
  - mindestens eine der Operationen a oder a' eine Schreiboperation ist
- Hierdurch ist eine sog. Konfliktmatrix definiert

	read	write
read		×
write	×	×

Serialisierbarkeit

- Ein Plan S heißt serialisierbar, gdw. er äquivalent ist zu **einem** seriellen Plan S'
- Die Ausführung eines serialisierbaren Plans S ist korrekt (S braucht nicht seriell zu sein)
- Korrektheit eines Plans kann anhand des Konfliktgraphen G_S gezeigt werden (auch Serialisierungsgraph genannt)
  - Knoten von G_S sind die Transaktionen T_i aus S
  - Kanten $T_i \longrightarrow T_j$ werden hinzugefügt, gdw. S Operationen $a_i(e)$ und $a'_j(e')$ enthält ($i \neq j$), so dass $a_i(e)$ vor $a'_j(e')$
  - S ist serialisierbar, wenn G_S zyklenfrei ist
  - Serielle Ausführung bestimmbar durch topologische Sortierung

Serialisierungsgraph

Beispiel: ATM-Transaktion

- $S = \langle r_1(A), r_2(A), w_1(A), w_2(A) \rangle$

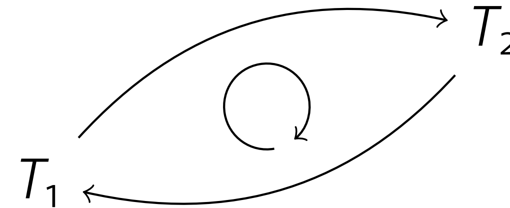

nicht serialisierbar

Beispiel: Zwei Geldtransfers

- $S = \langle r_1(C), w_1(C), r_2(C), w_2(C), r_1(S), w_1(S), r_2(S), w_2(S) \rangle$

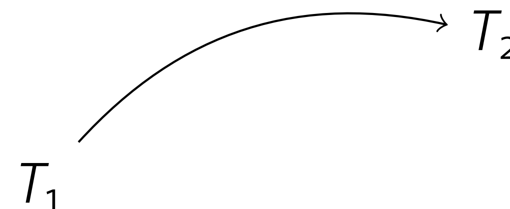

serialisierbar

Sperren im Anfrageplan

Können wir einen Scheduler bauen, der immer einen serialisierbaren Plan generiert?

Idee:

- Lasse jede Transaktion eine Sperre akquirieren, bevor auf ein Datum zugegriffen wird

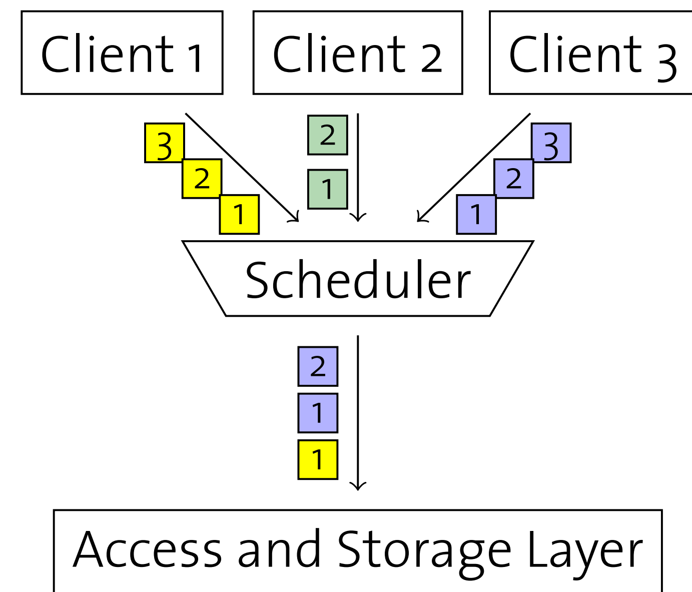


```
1 lock o;
2 ...access o...;
3 unlock o;
```

- Dadurch wird ein nebenläufiger Zugriff auf o verhindert

Sperr-Verwaltung

- Falls eine Sperre nicht zugeteilt wird (z.B. weil eine andere Transaktion T‘ die Sperre schon hält), wird die anfragende Transaktion T blockiert
- Der Verwalter setzt die Ausführung von Aktionen einer blockierten Transaktion T aus
- Sobald T‘ die Sperre freigibt, kann sie an T vergeben werden (oder an eine andere Transaktion, die darauf wartet)
- Eine Transaktion, die eine Sperre erhält, wird fortgesetzt
- Sperren regeln die relative Ordnung der Einzeloperationen verschiedener Transaktionen

Verwendung von Sperren vor dem Zugriff

```
1 lock (acct) ;                        } lock phase
2 bal ← read_bal (acct) ;
3 bal ← bal − 100 CHF ;
4 write_bal (acct, bal) ;
5 unlock (acct) ;                      } unlock phase
```

- Sperren werden automatisch in den Anfragebeantwortungsplan eingefügt

Serialisierbarkeit durch Sperren

Transaction 1	Transaction 2	DB state
`lock` (*acct*) ;		1200
`read` (*acct*) ;		
	`lock` (*acct*) ;	
`write` (*acct*) ;	↓ Transaction blocked	1100
`unlock` (*acct*) ;		
	`read` (*acct*) ;	
	`write` (*acct*) ;	900
	`unlock` (*acct*) ;	

- Kein Lost Update

Aufgabe:

- Reicht die Idee der Sperrverwaltung aus, um Serialisierbarkeit zu garantieren?

Transaction 1	Transaction 2
`lock` (*acct*) ;	
`read` (*acct*) ;	
`unlock` (*acct*) ;	
	`lock` (*acct*) ;
	`read` (*acct*) ;
	`unlock` (*acct*) ;
`lock` (*acct*) ;	
`write` (*acct*) ;	
`unlock` (*acct*) ;	
	`lock` (*acct*) ;
	`write` (*acct*) ;
	`unlock` (*acct*) ;

Zwei-Phasen-Sperrverwaltung

- Das Zwei-Phasen-Sperrprotokoll (Two-Phase Locking, 2PL) führt eine weitere Einschränkung ein
- Sobald eine Transaktion eine Sperre freigegeben hat, darf sie keine weiteren Sperren anfordern

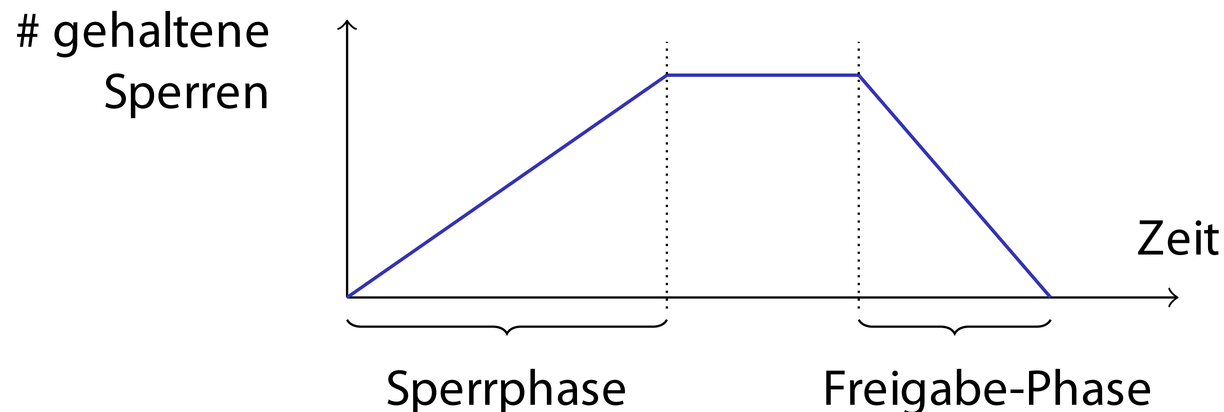

- Repeatable Read und kein Inconsistent Read

Sperrarten (Sperrmodi)

- Wir haben gesehen, dass zwei Leseoperationen nicht in Konflikt zueinander stehen
- Systeme verwenden verschiedene Arten von Sperren
  - Lesesperren (read locks, shared locks): Modus S
  - Schreibsperren (write locks, exclusive locks): Modus X
- Lock stehen nur in Konflikt zueinander, wenn eines davon eine X-Sperre ist:

	shared (S)	exclusive (X)
shared (S)		×
exclusive (X)	×	×

Beispiele noch einmal: Ser

Erst SLock, dann XLock?

Beispiel: ATM-Transaktion

- $S = \langle r_1(A), r_2(A), w_1(A), w_2(A) \rangle$

XLock

Xlock/Blockierung T_2
$w_1(A)$ rückt vor

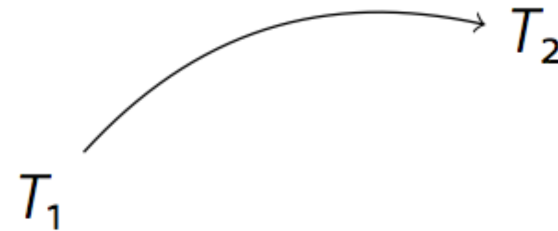

serialisierbar / korrekt

Beispiel: Zwei Geldtransfers

- $S = \langle r_1(C), w_1(C), r_2(C), w_2(C), r_1(S), w_1(S), r_2(S), w_2(S) \rangle$

XLock

Xlock/blockiert

....

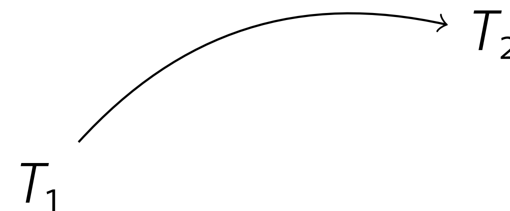

serialisierbar

Transaktionen leicht gemacht

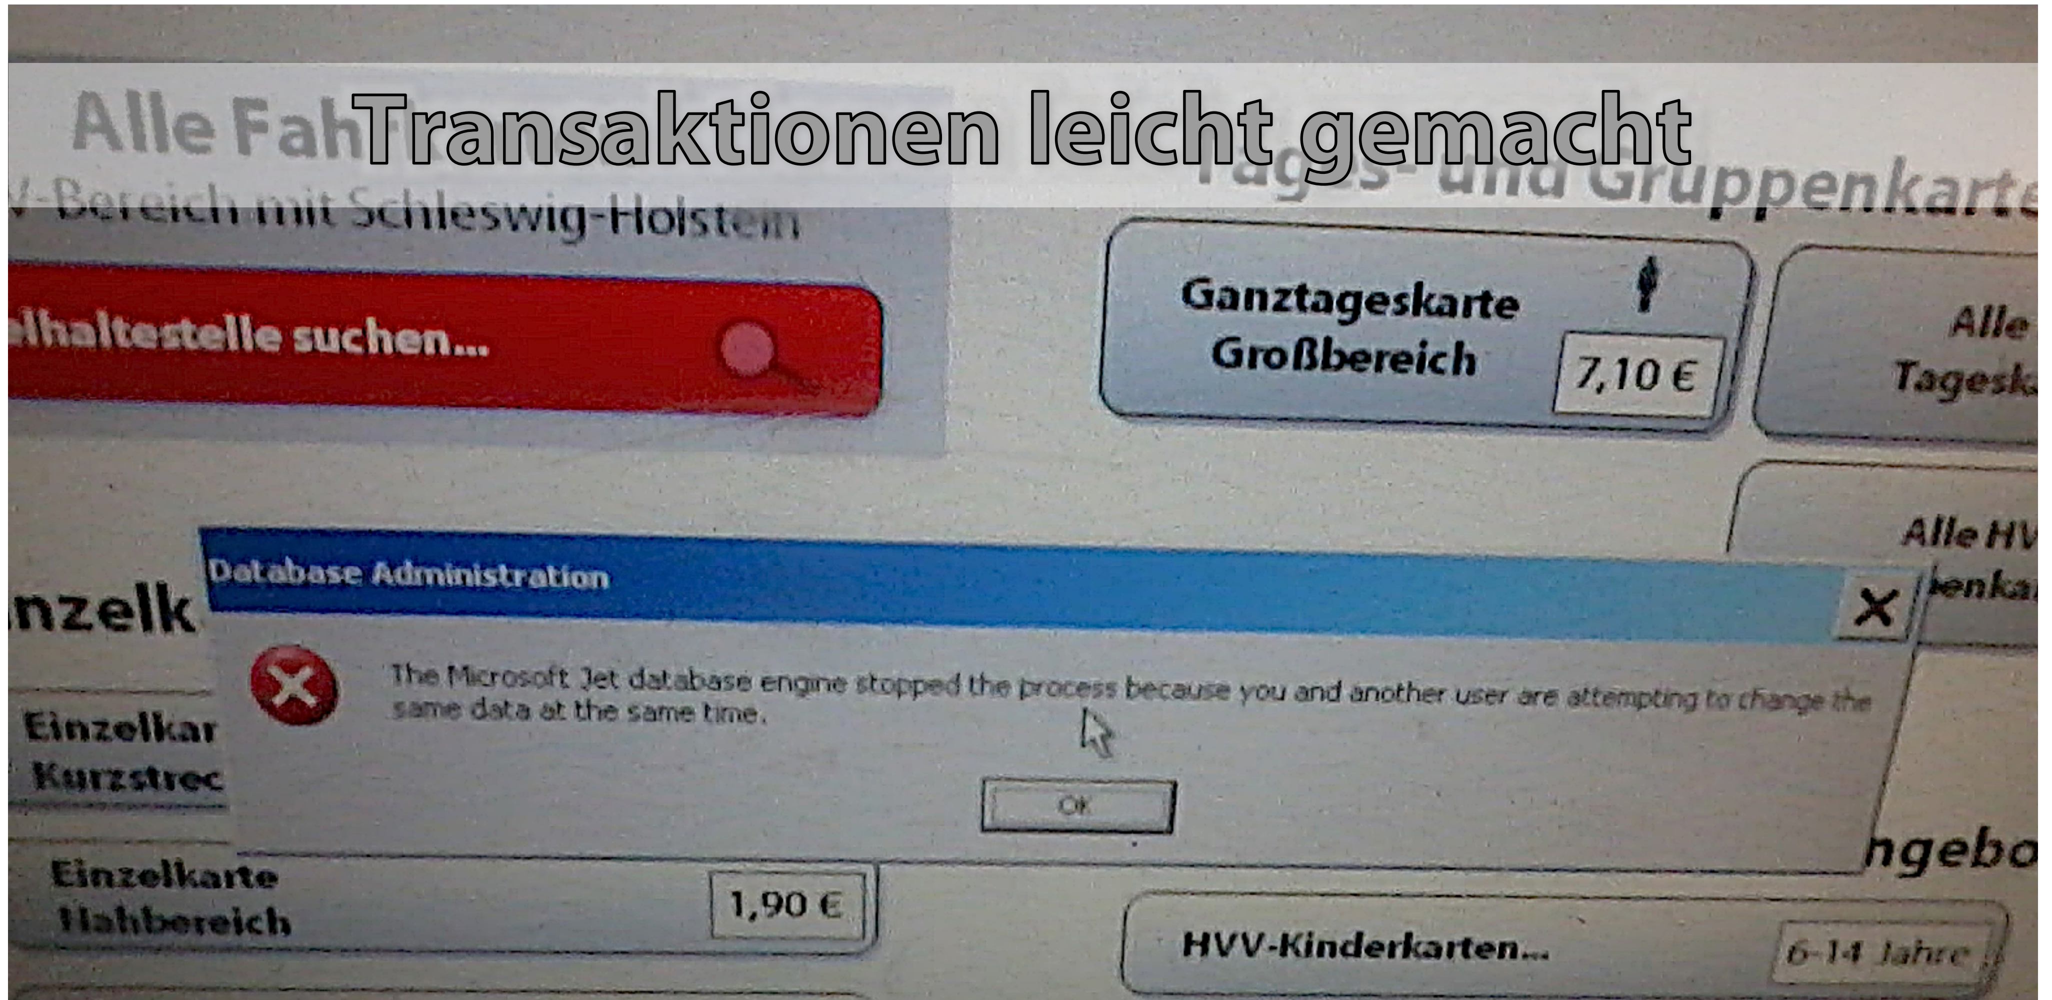

Vielleicht lag‘s an einer Verklemmung

Wechselseitiges Warten auf Freigabe

Siehe Vorlesung Betriebssysteme

Varianten des Zwei-Phasen-Sperrprotokolls

- Es gibt Freiheitsgrade bzgl. der Akquise- und Rückgabezeit von Sperren
- Mögliche Varianten

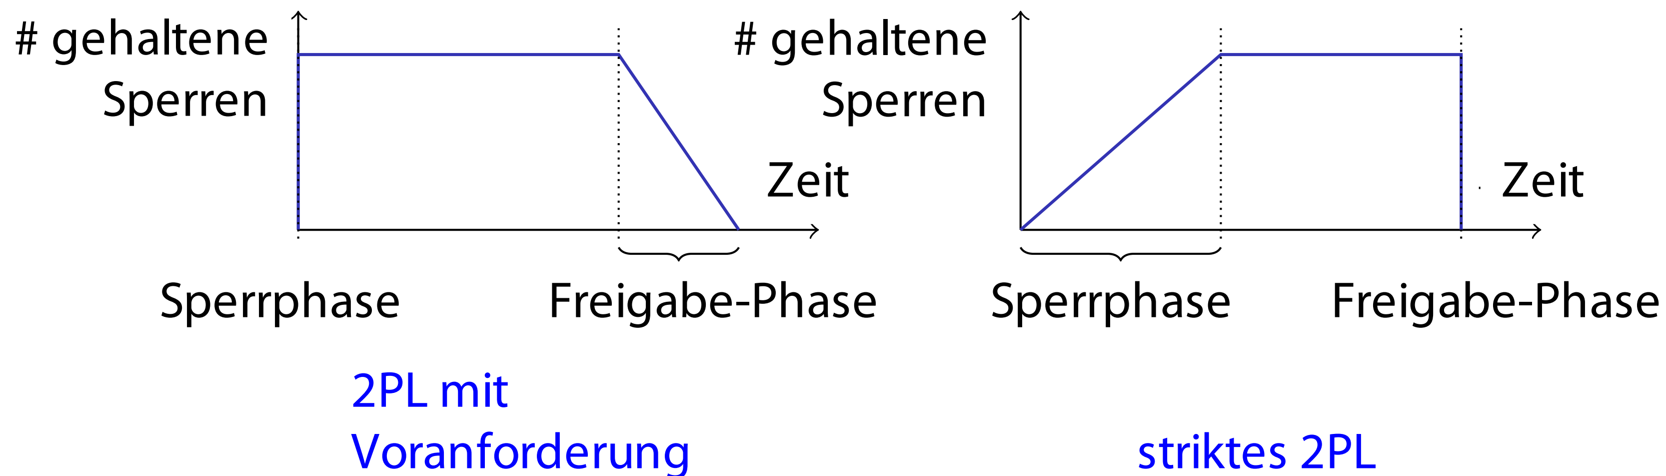

- Wodurch könnten die Varianten motiviert sein?

Aufgabe:

- Waskann passieren, wenn Sperren nicht in einem Schritt zurückgegeben werden?

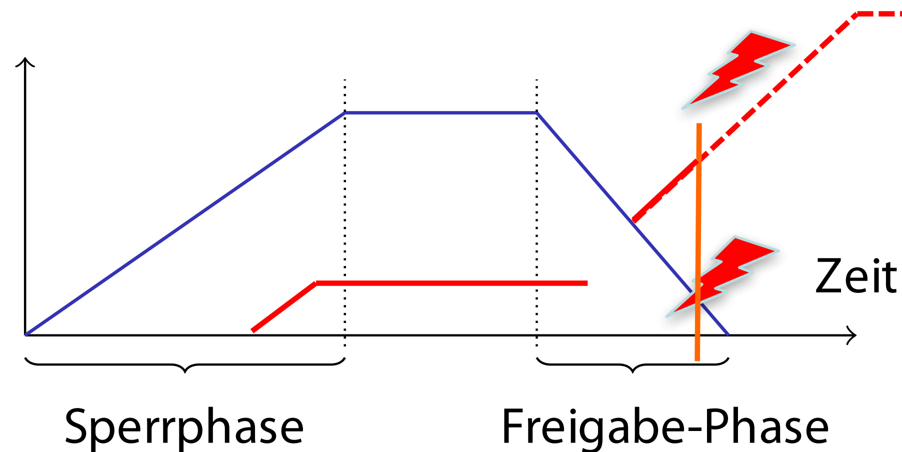

Durch Transaktionsverwaltung kein Dirty Read

Phantom-Problem

Transaction 1	Transaction 2	Effect
scan relation R ;		T_1 locks all rows
	insert new row into R ;	T_2 locks new row
	`commit` ;	T_2's lock released
scan relation R ;		reads **new** row, too!

- Obwohl beide Relationen dem 2PL-Protokoll folgen, sieht T_1 einen Effekt von T_2
- Ursache des Problems:
  T_1 kann nur existierende Tupel sperren
- Sollen wir immer die ganze Relation sperren?

Implementierung eines Sperrverwalters

Ein Sperrverwalter muss drei Aufgaben effektiv erledigen:

1. Prüfen, welche Sperren für eine Ressource gehalten werden (um eine Sperranforderung zu behandeln)
2. Bei Sperr-Rückgabe müssen die Transaktionen, die die Sperre haben wollen, schnell identifizierbar sein
3. Wenn eine Transaktion beendet wird, müssen alle von der Transaktion angeforderten und gehaltenen Sperren zurückgegeben werden

Wie muss eine Datenstruktur aussehen, mit der diese Anforderungen erfüllt werden können?

Datenstruktur zur Buchführung

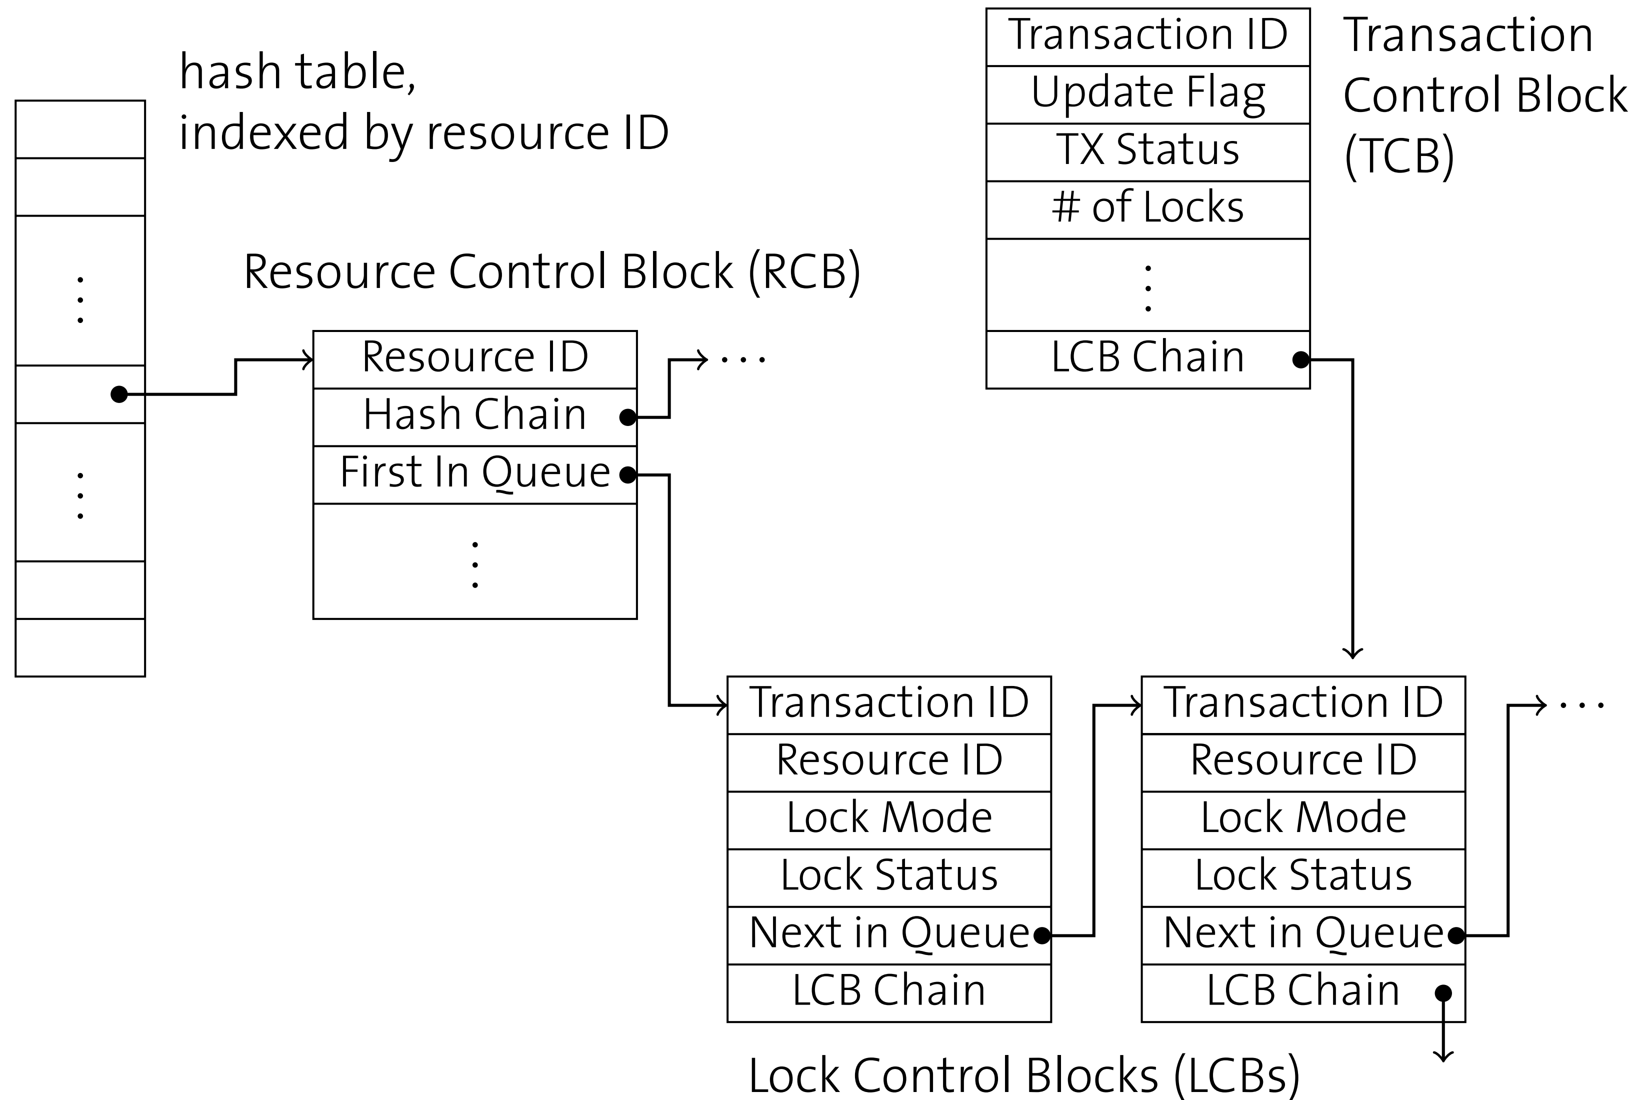

Implementierung von Aufgaben

1. Sperren für eine Ressource können über Hashzugriff gefunden werden
   - Verkettete Liste der Lock Control Blocks über ‚First In Queue/Next in Queue' (alle Anfragen enthalten, stattgegeben oder nicht)
   - Transaktion(en) am Kopf der Liste hält/halten Sperre für die Ressource
2. Wenn eine Sperre zurückgegeben wird (LCB aus der Liste entfernt), können die nächsten Transaktionen berücksichtigt werden
3. Sperren einer beendeten Transaktion können über ‚LCB Chain' identifiziert und zurückgegeben werden

Granularität des Sperrens

Die Granularität des Sperrens unterliegt Abwägung

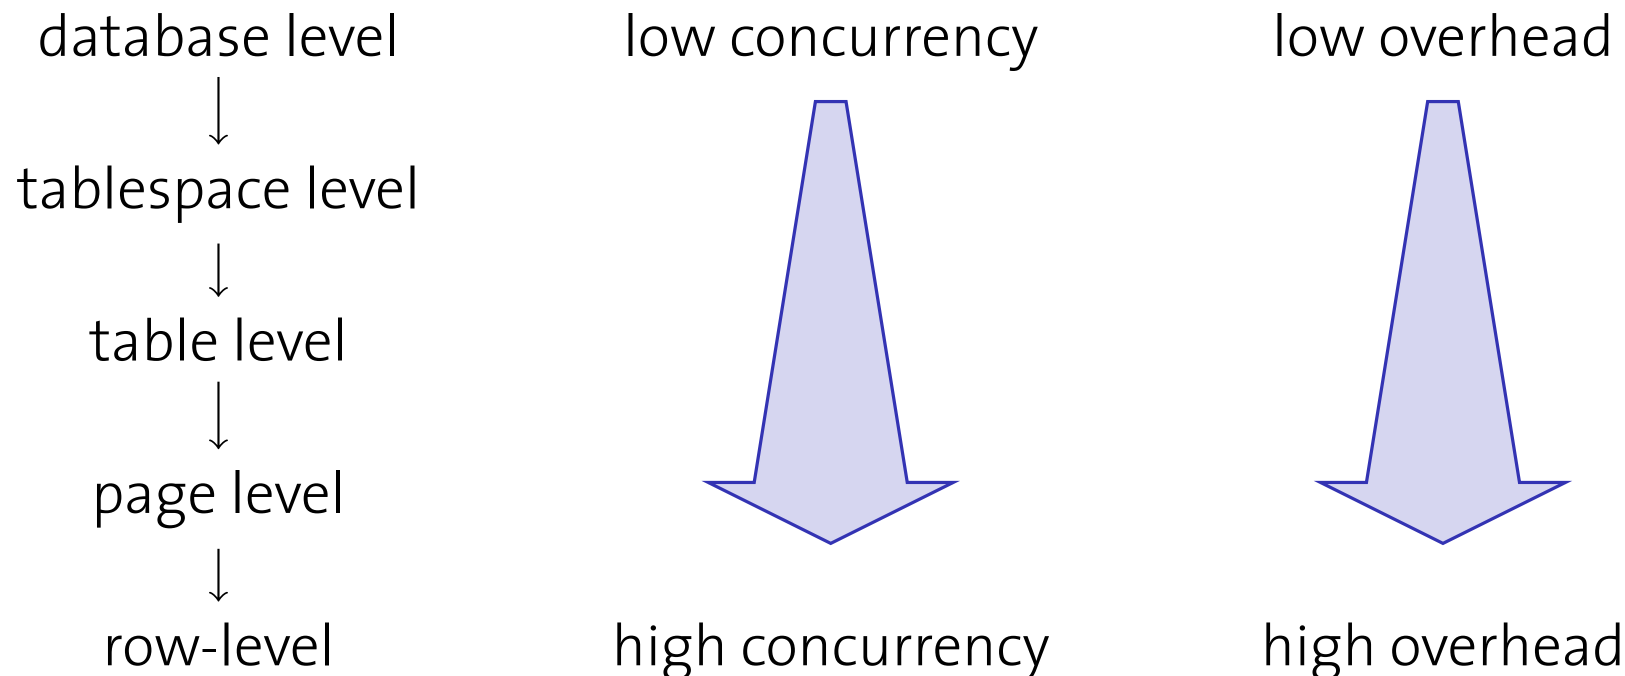

- Sperren mit multipler Granularität
- Wofür sollte man Sperren auf Seitenebene betrachten?

Sperren mit multipler Granularität

- Entscheide die Granularität von Sperren für jede Transaktion (abhängig von ihrer Charakteristik)
  - Tupel-Sperre z.B. für

```
SELECT *
FROM CUSTOMERS
WHERE C_CUSTKEY = 42
```

Q_1

  - und eine Tabellen-Sperre für

```
SELECT * FROM CUSTOMERS
```

Q_2

- Wie können die Sperren für die Transaktionen koordiniert werden?
  - Für Q_2 sollen nicht für alle Tupel umständlich Sperrkonflikte analysiert werden

Vorhabens-Sperren

Datenbanken setzten Vorhabens-Sperren (intention locks) für verschiedenen Sperrgranularitäten ein

- Sperrmodus Intention Share: IS
- Sperrmodus Intention Exclusive: IX
- Konfliktmatrix:

	S	X	IS	IX
S		×		×
X	×	×	×	×
IS		×		
IX	×	×		

- Eine Sperre I□ auf einer gröberen Ebene bedeutet, dass es eine Sperre □ auf einer niederen Ebene gibt

Vorhabens-Sperren

Protokoll für Sperren auf mehreren Ebenen:

1. Eine Transaktion kann jede Ebene g in Modus □ ∈ {S, X} sperren
2. Bevor Ebene g in Modus □ gesperrt werden kann, muss eine Sperre I□ für alle gröberen Ebenen gewonnen werden

Anfrage Q_1 würde

- eine IS-Sperre für Tabelle CUSTOMERS anfordern (auch für Tablespace und die Datenbank) und dann
- eine S-Sperre auf dem Tupel mit C_CUSTKEY=42 akquirieren

Anfrage Q_2 wurde eine

- S-Sperre für die Tabelle CUSTOMERS anfordern (und eine IS-Sperre auf dem Tablespace und der Datenbank)

Entdeckung von Konflikten

Nehmen wir an, folgende Anfrage ist zu bearbeiten

```
UPDATE CUSTOMERS
SET NAME = 'John Doe'
WHERE C_CUSTKEY = 17
```

	S	X	IS	IX
S		×		×
X	×	×	×	×
IS		×		
IX	×	×		

Hierfür wird

- eine IX-Sperre auf Tabelle CUSTOMERS (und ...) sowie
- eine X-Sperre auf dem Tupel mit Kunde 17

Diese Anfrage ist

- kompatibel mit Q_1 (kein Konflikt zw. IX und IS auf der Tabellenebene)
- aber inkompatibel mit Q_2 (die S-Sperre auf Tabellenebene von Q_2 steht in Konflikt mit der IX-Sperre bzgl. Q_3)

Konsistenzgarantien in SQL-92

In einigen Fall kann man mit einigen kleinen Fehlern im Anfrageergebnis leben

- „Fehler“ bezüglich einzelner Tupel machen sich in Aggregat-funktionen evtl. kaum bemerkbar
  - Lesen inkonsistenter Werte (inconsistent read anomaly)
- In SQL-92 kann man Isolations-Modi spezifizieren:
  SET ISOLATION <MODE>

```
SET ISOLATION SERIALIZABLE;
```

- Es gibt weniger strikte Modi, unter denen die Performanz höher ist (weniger Verwaltungsaufwand z.B. für Sperren)

SQL-92 Isolations-Modi

- Read uncommitted (auch: ‘dirty read‘ oder ‘browse‘)
  - Nur Schreibsperren akquiriert (nach 2PL)
- Read committed (auch ‘cursor stability‘)
  - Lesesperren werden nur gehalten, sofern der Zeiger auf das betreffende Tupel zeigt, Schreibsperren nach 2PL
- Repeatable read (auch ‘read stability‘)
  - Lese- und Schreibsperren nach 2PL akquiriert
- Serializable
  - Zusätzliche Sperranforderungen I☐, um Phantomproblem zu begegnen

Resultierende Konsistenzgarantien

isolation level	dirty read	non-repeat. rd	phantom rd
read uncommitted	possible	possible	possible
read committed	not possible	possible	possible
repeatable read	not possible	not possible	possible
serializable	not possible	not possible	not possible

- Einige Implementierungen unterstützen mehr, weniger oder andere Isolationsmodi (isolation levels)
- Nur wenige Anwendung benötigen (volle) Serialisierbarkeit

Nebenläufigkeit beim Indexzugriff

- Betrachten wir eine Transaktion T_w, die etwas in einen B-Baum einführt, was zu einer Splitoperation führt

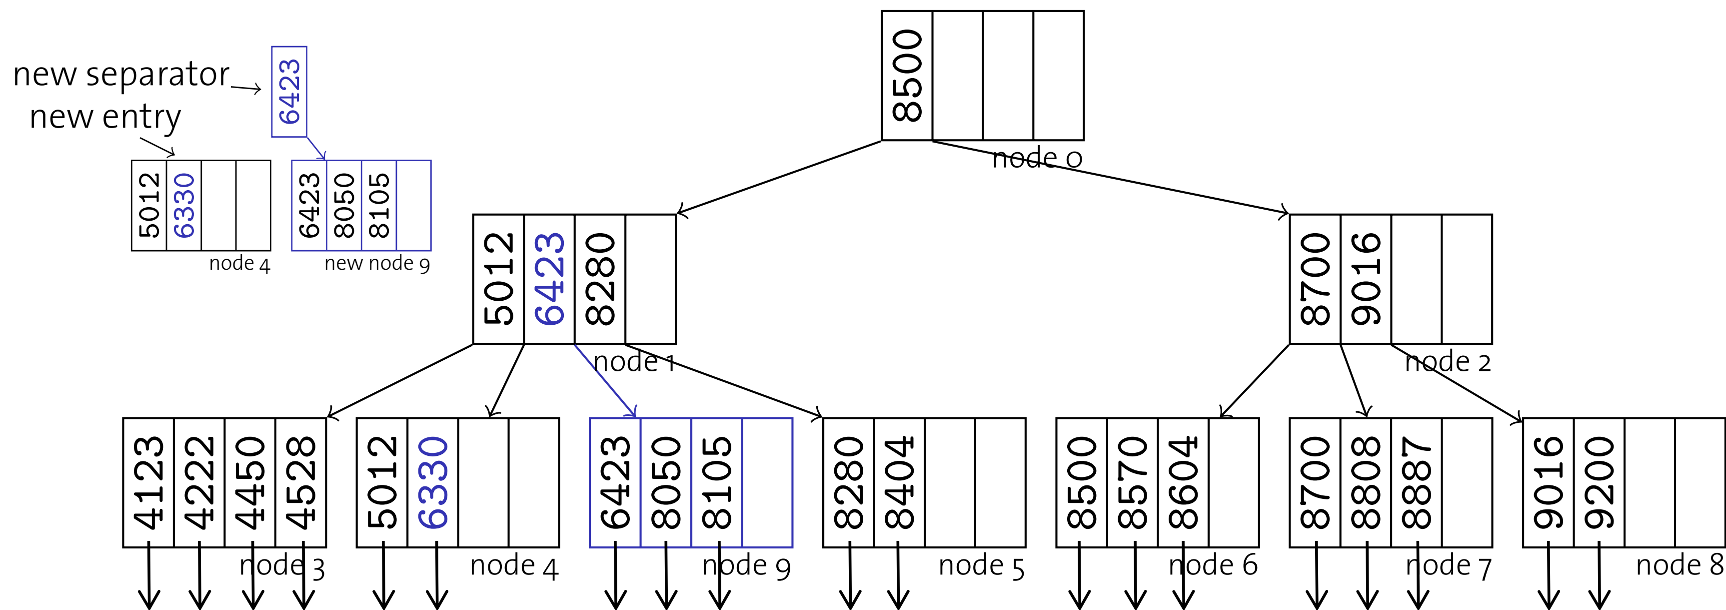

- Einfügung eines Eintrags mit Schlüssel 6330
  - Knoten 4 aufgespalten
  - Neuer Separator in Knoten 1

Nebenläufigkeit beim Indexzugriff

- Nehme an, die Aufspaltung ist gerade erfolgt, aber der neue Separator 6423 ist noch nicht etabliert
- Nehme weiterhin an, ein nebenläufiges Lesen in Transaktion T_r sucht nach 8085
  - Die Verzeigerung weist auf Knoten $node_4$
  - Knoten $node_4$ enthält aber 8050 nicht mehr, also wird der entsprechende Datensatz nicht gefunden
- Auch in B-Bäumen muss beim Umbau mit Sperren gearbeitet werden!

Sperren und B-Baum-Indexe

Betrachten wir B-Baum-Operationen

- Für die Suche erfolgt ein Top-Down-Zugriff
- Für Aktualisierungen ...
  - erfolgt erst eine Suche,
  - dann werden Daten ggf. in ein Blatt eingetragen und
  - ggf. werden Aufspaltungen von Knoten nach oben propagiert
- Nach dem Zwei-Phasen-Sperrprotokoll ...
  - müssen S/X-Sperren auf dem Weg nach unten akquiriert werden (Konversion provoziert ggf. Verklemmungen)
  - müssen alle Sperren bis zum Ende gehalten werden

Sperren und B-Baum-Indexe

- Diese Strategie reduziert die Nebenläufigkeit drastisch
- Während des Indexzugriffs einer Transaktion müssen alle anderen Transaktionen warten, um die Sperre für die Wurzel des Index zu erhalten
- Wurzel wird dadurch zum Flaschenhals und serialisiert alle (Schreib-)Transaktionen
- Zwei-Phasen-Sperrprotokoll nicht angemessen für B-Baum-Indexstrukturen

Sperrkopplung

Betrachten wir den Schreibe-Fall (alle Sperren mit Konflikt)

- Das Protokoll Write-Only-Tree-Locking (WTL) garantiert Serialisierbarkeit
  - Für alle Baumknoten n außer der Wurzel kann eine Sperre nur akquiriert werden, wenn die Sperre für den Elternknoten akquiriert wurde
  - Sobald ein Knoten entsperrt wurde, kann für ihn nicht erneut eine Sperre angefordert werden (2PL)

Und damit gilt:

- Alle Transaktionen folgen Top-Down-Zugriffsmuster
- Keine Transaktion kann dabei andere überholen
- WTL-Protokoll ist verklemmungsfrei

Aufspaltungssicherheit

- Wir müssen auf dem Weg nach unten in den B-Baum Schreibsperren wegen möglicher Aufspaltungen halten
- Allerdings kann man leicht prüfen, ob ein Spaltung von Knoten n die Vorgänger überhaupt erreichen kann
  - Wenn n weniger als 2d Einträge enthält kommt es nicht zu einer Weiterreichung der Aufspaltung nach oben
- Ein Knoten, der diese Bedingung erfüllt, heißt aufspaltungssicher (split safe)
- Ausnutzung zur frühen Sperrrückgabe
  - Wenn ein Knoten auf dem Weg nach unten als aufspaltungssicher gilt, können alle Sperren der Vorgänger zurückgegeben werden
  - Sperren werden weniger lang gehalten

Sperrkopplungsprotokoll (Variante 1)

readers

```
1  place S lock on root ;
2  current ← root ;
3  while current is not a leaf node do
4      place S lock on appropriate son of current ;
5      release S lock on current ;
6      current ← son of current ;
```

writers

```
1  place X lock on root ;
2  current ← root ;
3  while current is not a leaf node do
4      place X lock on appropriate son of current ;
5      current ← son of current ;
6      if current is safe then
7          release all locks held on ancestors of current ;
```

Erhöhung der Nebenläufigkeit

- Auch mit Sperrkopplung werden eine beträchtliche Anzahl von Sperren für innere Knoten benötigt (wodurch die Nebenläufigkeit gemindert wird)
- Innere Knoten selten durch Aktualisierungen betroffen
  - Wenn d=50, dann Aufspaltung bei jeder 50. Einfügung (2% relative Auftretenshäufigkeit)
- Eine Einfügetransaktion könnte optimistisch annehmen, dass keine Aufspaltung nötig ist
  - Bei inneren Knoten werden währende der Baumtraversierung nur Lesesperren akquiriert (inkl. einer Schreibsperre für das betreffende Blatt)
  - Wenn die Annahme falsch ist, traversiere Indexbaum erneut unter Verwendung korrekter Schreibsperren

Sperrkopplungsprotokoll (Variante 2)

Modifikationen nur für Schreibvorgänge

```
1  place S lock on root ;
2  current ← root ;
3  while current is not a leaf node do
4      son ← appropriate son of current ;
5      if son is a leaf then
6          place X lock on son ;
7      else
8          place S lock on son ;
9      release lock on current ;
10     current ← son ;
11 if current is unsafe then
12     release all locks and repeat with protocol Variant 1 ;
```

Zusammenfassung

- Wenn eine Aufspaltung nötig ist, wird der Vorgang abgebrochen und erneut aufgesetzt
- Die resultierende Verarbeitung ist korrekt, obwohl es nach einem erneuten Sperren aussieht (was für WTL nicht erlaubt ist)
- Der Nachteile von Variante 2 ist, das im Falle einer Blattaufspaltung Arbeit verloren ist
- Es gibt viele Varianten dieser Sperrprotokolle

B+-Bäume ohne Lesesperren

- Es gibt Vorschläge, ohne Lesesperren auf B-Baum-Knoten zu operieren
- Anforderung: ein Next-Zeiger zeigt auf rechten Geschwisterknoten

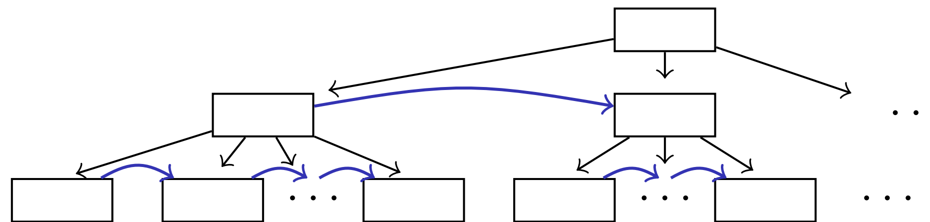

- Vorher schon betrachtet: Verkettete Liste auf Blattebene
- Zeiger stellen zweiten Pfad auf Knoten bereit
- Bei nebenläufigen Zugriffen und Aufspaltung von Knoten bleibt Zugriff auf Gesamtinformation möglich

Lehman and Yao, TODS vol. 6(4), **1981**

Einfügung mit Aufspaltung eines inneren Knotens

1. lock & read page B ;
2. create new page D and lock it ;
3. populate page D ;
4. set `next` pointer $D \rightarrow C$;
5. write D ;
6. set `next` pointer $B \rightarrow D$;
7. adjust content of B ;
8. write B ;
9. lock & read A ;
10. adjust content of A ;
11. write A ;

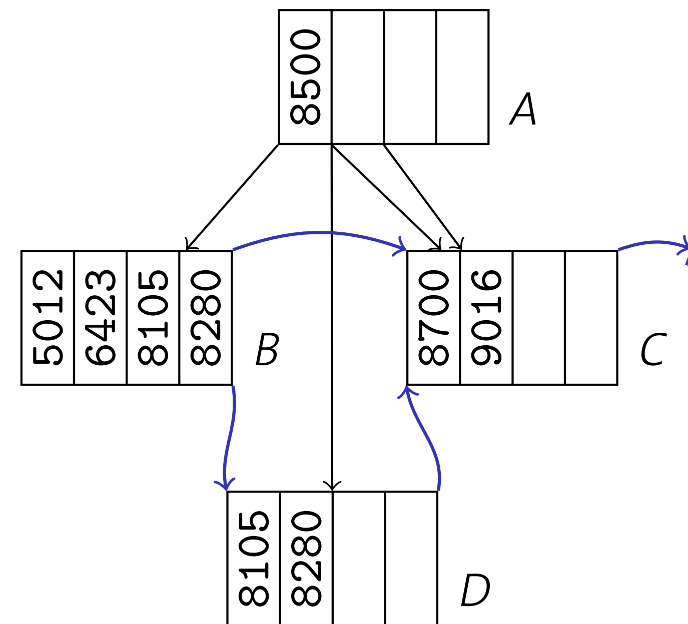

- Alle Indexeinträge sind zu jedem Zeitpunkt erreichbar

B-Baum-Zugriff beim Lesen

- Die Next-Zeiger ermöglichen Leseoperationen, Einträge sogar inmitten einer Aufspaltung zu finden, auch wenn einige Einträge schon auf eine neue Seite verschoben wurden
- Während tree_search() können Lesetransaktionen auf die Geschwister eine Knotens n zugreifen sofern
  - in n kein entsprechender Eintrag gefunden wird und
  - next kein Nullzeiger ist
- Es wird nur auf Geschwister mit gleichem Elternteil verwiesen
- Schreibsperren halten Lesetransaktionen nicht vom Zugriff auf eine Seite ab (Leser fordern keine Sperren an)
- Dieses Protokoll wird von PostgreSQL verwendet

Sperren (Locks) und Indexsperren (Latches)

- Welches Annahmen müssen wir machen für Sperr-freien Lesezugriff?
- Sperren wollte wir ja nicht verwenden
- Leichtgewichtige Sperren für kurzfristige atomare Ops
- Indexsperren induzieren wenige Verwaltungsaufwand (meist als Spinlocks implementiert)
- Sie sind nicht unter der Kontrolle des Sperrverwalters (es gibt keine Verklemmungsüberwachung oder automatisches Zurückgeben der Sperren bei Transaktionsabbruch)

Optimistische Organisation der Nebenläufigkeit

- Bisher waren wir pessimistisch
  - Wir haben uns immer den schlimmste Fall vorgestellt und durch Sperrverwaltung vermieden
- In der Praxis kommt der schlimmste Fall gar nicht sehr oft vor (siehe auch die Isolationsmodi)
- Wir können auch das beste hoffen und nur im Fall eines Konflikts besondere Maßnahmen ergreifen
- Führt auf die Idee der Optimistischen Kontrolle der Nebenläufigkeit

Optimistische Organisation der Nebenläufigkeit

Behandle Transaktionen in drei Phasen

- Lesephase: Führe Transaktion aus, aber schreibe Daten nicht sofort auf die Platte, halte Kopien in einem privaten Arbeitsbereich
- Validierungsphase: Wenn eines Transaktion erfolgreich angeschlossen wird (commit), teste ob Annahmen gerechtfertigt waren. Falls nicht, führe doch noch einen Abbruch durch
- Schreibphase: Transferiere Daten vom privaten Arbeitsbereich in die Datenbasis

Validierung von Transaktionen

Validierung wird üblicherweise implementiert durch Betrachtung der

- Gelesenen Attribute (read set $RS(T_i)$)
- Geschriebene Attribute (write set $WS(T_i)$)

Validierung von Transaktionen

- Rückwärtsorientierte optimistische Nebenläufigkeitsverwaltung
  - Vergleich T bezüglich aller erfolgreich beendeter (committed) Transaktionen
  - Test ist erfolgreich, wenn T_c beendet wurde bevor T gestartet wurde oder $RS(T) \cap WS(T_c) = \emptyset$
- Vorwärtsorientierte optimistische Nebenläufigkeitsverwaltung
  - Vergleiche T bezüglich aller laufenden Transaktionen T_r
  - Test ist erfolgreich, wenn $WS(T) \cap RS(T_r) = \emptyset$

Multiversions-Nebenläufigkeitsorganisation

Betrachten wir den folgenden Abarbeitungsplan

t ↓

$r_1(x), w_1(x), r_2(x), w_2(y), r_1(y), w_1(z)$

Ist dieser Plan serialisierbar?

- Angenommen, wenn T_1 den Wert y lesen möchte, sei der „alte" Wert vom Zeitpunkt t noch verfügbar,
- dann könnten wir eine Historie wie folgt erzeugen

$r_1(x), w_1(x), r_2(x), r_1(y), w_2(y), w_1(z)$

die serialisierbar ist

Multiversions-Nebenläufigkeitsorganisation

- Mit verfügbaren alten Objektversionen müssen Leseschritte nicht länger blockiert werden
- Es sind „abgelaufene", aber konsistente Werte verfügbar (vgl. Dirty-Read-Problematik)
- Problem: Versionierung benötigt Raum und erzeugt Verwaltungsaufwand (Garbage Collection)

Datenbanken

Prof. Dr. Ralf Möller

Universität zu Lübeck

Institut für Informationssysteme

Karsten Martiny (Übungen)

Wiederherstellung (Recovery)

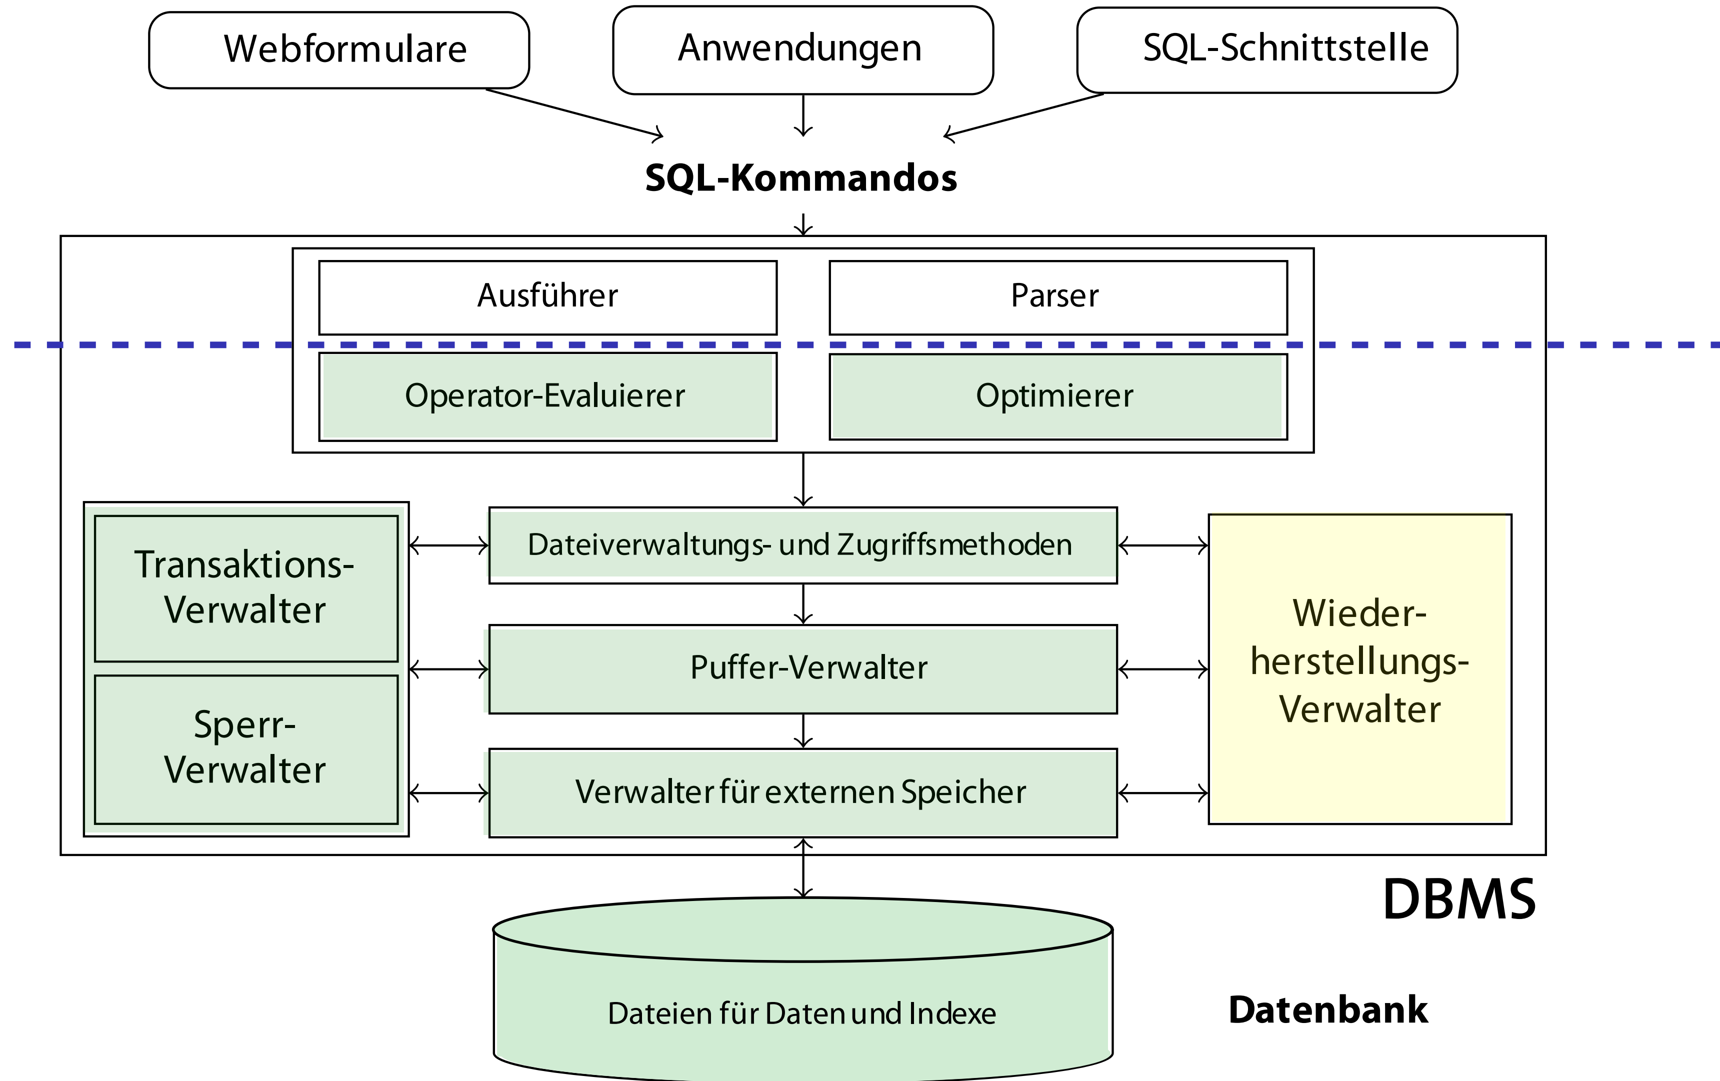

Wiederherstellung nach Fehlern

Drei Typen von Fehlern

- Transaktionsfehler (Prozessfehler)
  - Eine Transaktion wird abgebrochen (abort)
  - Alle Änderungen müssen ungeschehen gemacht werden
- Systemfehler
  - Datenbank- oder Betriebssystem-Crash, Stromausfall, o.ä.
  - Änderungen im Hauptspeicher sind verloren
  - Sicherstellen, dass keine Änderungen mit Commit verloren gehen (oder ihre Effekte wieder herstellen) und alle anderen Transaktionen ungeschehen gemacht werden
- Medienfehler (Gerätefehler)

Wiederherstellung nach Fehlern

Drei Typen von Fehlern

- Transaktionsfehler (Prozessfehler)
- Systemfehler
- Medienfehler (Gerätefehler)
  - Crash von Festplatten, Feuer, Wassereinbruch
  - Wiederherstellung von externen Speichermedien

Trotz Fehler müssen Atomarität und Durabilität garantiert werden (ACID-Bedingungen)

Beispiel: Systemausfall (oder Medienfehler)

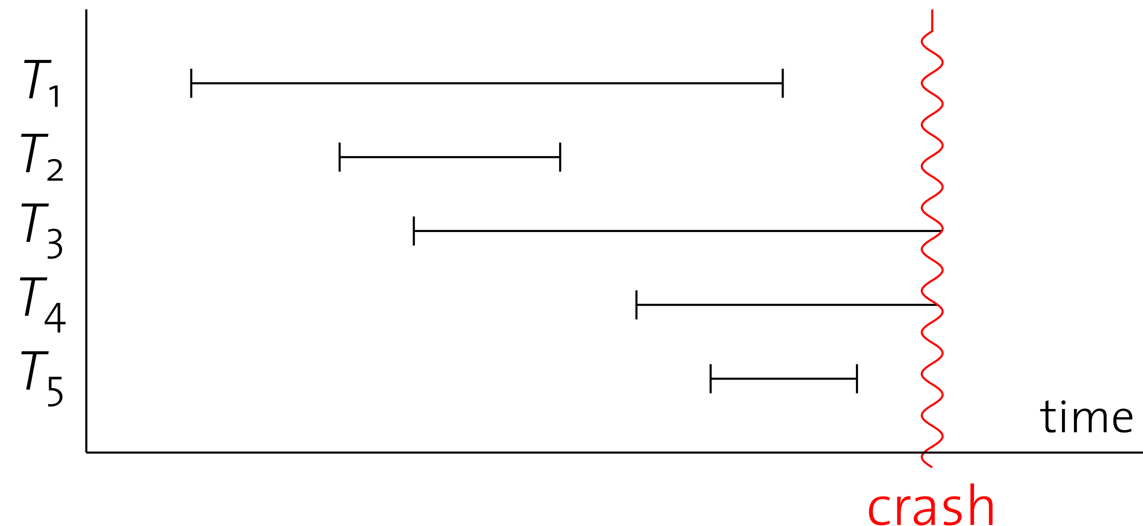

- Transaktionen T_1, T_2 und T_3 wurden vor dem Ausfall erfolgreich beendet → Dauerhaftigkeit: Es muss sicher-gestellt werden, dass die Effekte beibehalten werden oder wiederhergestellt werden können (redo)
- Transaktionen T_3 und T_4 wurden noch nicht beendet → Atomarität: Alle Effekte müssen rückgängig gemacht werden

Arten von Speichern

Wir nehmen an, es gibt drei Arten von Speichern

- Flüchtige Speicher
  - Wird vom Pufferverwalter verwendet (auch für Cache und Write-Ahead-Log, s.u.)
- Nicht-flüchtige Speicher
  - Festplatten
- Stabile Speicher
  - Nicht-flüchtiger Speicher, der alle drei Arten von Fehlern überlebt. Stabilität kann durch Replikation auf mehrere Platten erhöht werden (auch: Bänder)

Vergleiche Arten von Fehler und Arten von Speichern

Schatten-Seiten-Verwaltung

- Fehler können zu jeder Zeit auftreten, also muss das System jederzeit in einen konsistenten Zustand zurückgeführt werden können
- Dies kann durch Redundanz erreicht werden
- Schatten-Seiten (eingeführt durch IBMs „System R“)
  - Von jeder Seite werden zwei Versionen geführt
  - Aktuelle Version (Arbeitskopie, copy-on-write)
  - Schatten-Seite (konsistente Version auf nicht-flüchtigem Speicher zur Wiederherstellung)
- Operation SAVE, um aktuellen Zustand als Schatten-Version zu sichern (für Commit)
- Operation RESTORE, um Wiederherstellung einzuleiten (für Abort)

Schatten-Seiten-Verwaltung

- Am Anfang: shadow = current
- Ein Transaktion T ändert nun die aktuelle Version
  - Aktualisierung nicht in situ
  - Neue Seiten anfordern, kopieren, ändern und Seitentabelle anpassen
- Wenn T abgebrochen wird, überschreibe aktuelle Version mit Schatten-Version
- Wenn T beendet wird, aktualisiere Info in Verzeichnis, um aktuelle Version persistent zu machen
- Gewinne ggf. Seiten durch Garbage Collection wieder

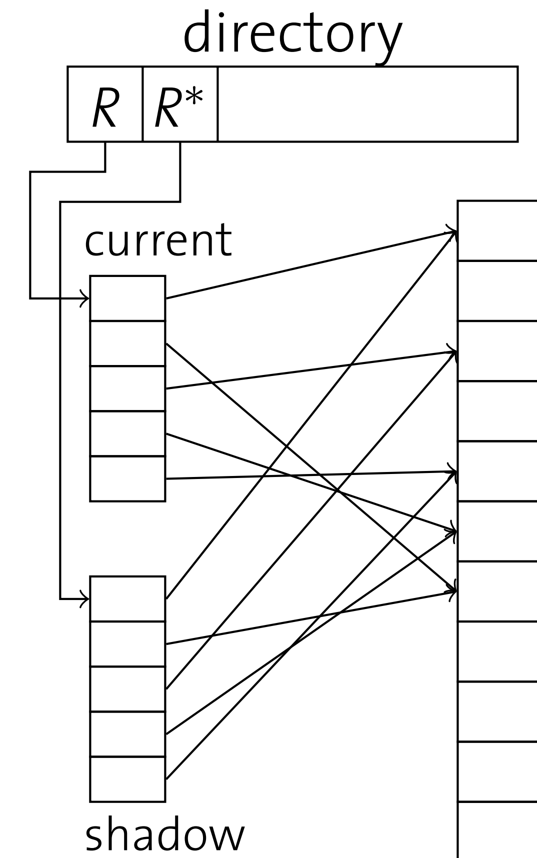

Schatten-Seiten: Diskussion

- Wiederherstellung schnell für ganze Relationen/Dateien
- Um Persistenz (Durabilität) sicherzustellen, müssen modifizierte Seiten bei einem Commit in nicht-flüchtigen Speicher (z.B. Festplatte) geschrieben werden (force to disk)
- Nachteile:
  - Hohe I/O-Kosten, keine Verwendung von Cache möglich
  - Langsame Antwortzeiten
- Besser: No-Force-Strategie, Verzögerung des Schreibens
- Transaktion muss neu abgespielt werden können (Redo), auch für Änderungen, die nicht gespeichert wurden

Gray et al.. The Recovery Manager of the System R Database Manager. ACM Comp. Surv., vol. 13(2), June **1981**.

Schatten-Seiten: Diskussion

- Schatten-Seiten ermöglichen das Stehlen der Rahmen im Pufferverwalter (frame stealing): Seiten werden möglicherweise sofort auf die Platte geschrieben (sogar bevor Transaktion erfolgreich beendet wird)
  - Stehlen erfolgt durch andere Transaktionen
  - Stehlen kann nur erfolgen, wenn Seite nicht gepinnt
  - Geänderte Seiten (dirty pages) werden auf die Platte geschrieben
- Diese Änderungen müssen ungeschehen gemacht werden während der Wiederherstellung
  - Leicht möglich durch Schatten-Seiten

Effekte, die Wiederherstellung berücksichtigen muss

- Entscheidungen zur Strategie haben Auswirkungen auf das, was bei der Wiederherstellung erfolgen muss

	force	**no force**
no steal	no redo no undo	must redo no undo
steal	no redo must undo	must redo must undo

- Bei **steal** und **no force** wird zur Erhöhung der Nebenläufigkeit und der Performanz ein **redo** und ein **undo** implementiert

Write-Ahead-Log (WAL)

- Die ARIES[1]-Wiederherstellungsmethode verwendet ein Write-Ahead-Log zur Implementierung der notwendigen redundanten Datenhaltung
- Datenseiten werden in situ modifiziert
- Für ein Undo müssen Undo-Informationen in eine Logdatei auf nicht-flüchtigem Speicher geschrieben werden bevor eine geänderte Seite auf die Platte geschrieben wird
- Zur Persistenzsicherung muss zur Commit-Zeit Redo-Information sicher gespeichert werden (No-Force-Strategie: Daten auf der Platte enthalten alte Information)

[1] Algorithm for Recovery and Isolation Exploiting Semantics
Mohan et al. ARIES: A Transaction Recovery Method Supporting Fine-Granularity Locking and Partial Rollbacks Using Write-Ahead Logging. ACM TODS, vol. 17(1), March **1992**.

Inhalte des Write-Ahead-Logs

LSN	Type	TX	Prev	Page	UNxt	Redo	Undo
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

LSN (Log Sequence Number)

- Monoton steigende Zahl, um Einträge zu identifizieren
  Trick: Verwende Byte-Position of Log-Eintrag

Typ (Log Record Type)

- Repräsentiert, ob es ein Update-Eintrag (UPD), End-of-Transaction-Eintrag (EOT), Compensation-Log-Record (CLR)

TX (Transaktions-ID)

- Transaktionsbezeichner (falls anwendbar)

Inhalte des Write-Ahead-Logs (Forts.)

Prev (Previous Log Sequence Number)

- LSN des vorigen Eintrags von der gleichen Transaktion (falls anwendbar, am Anfang steht '-')

Page (Page Identifier)

- Seite, die aktualisiert wurde (nur für UPD und CLR)

UNxt (LSN Next to be Undone)

- Nur für CLR: Nächster Eintrag der Transaktion, der während des Zurückrollens bearbeitet werden muss

Redo

- Information zum erneuten Erzeugen einer Operation

Undo

- Information zum Ungeschehenmachen einer Operation

Beispiel

Transaction 1	Transaction 2	LSN	Type	TX	Prev	Page	UNxt	Redo	Undo
$a \leftarrow \texttt{read}(A)$;									
	$c \leftarrow \texttt{read}(C)$;								
$a \leftarrow a - 50$;									
	$c \leftarrow c + 10$;								
$\texttt{write}(a,A)$;		1	UPD	T_1	–	...		$A := A - 50$	$A := A + 50$
	$\texttt{write}(c,C)$;	2	UPD	T_2	–	...		$C := C + 10$	$C := C - 10$
$b \leftarrow \texttt{read}(B)$;									
$b \leftarrow b + 50$;									
$\texttt{write}(b,B)$;		3	UPD	T_1	1	...		$B := B + 50$	$B := B - 50$
$\texttt{commit}$;		4	EOT	T_1	3	...			
	$a \leftarrow \texttt{read}(A)$;								
	$a \leftarrow a - 10$;								
	$\texttt{write}(a,A)$;	5	UPD	T_2	2	...		$A := A - 10$	$A := A + 10$
	$\texttt{commit}$;	6	EOT	T_2	5	...			

Redo/Undo-Information

ARIES nimmt seitenorientiertes Redo an

- Keine anderen Seiten müssen angesehen werden, um eine Operation erneut zu erzeugen
- Z.B.: Physikalisches Logging
  - Speicher von Byte-Abbildern von (Teilen von) Seiteninhalten
  - Vorher-Abbild (Abbild vor der Operation)
  - Nachher-Abbild (Abbild nach der Operation)
  - Wiederherstellung unabhängig von Objekten
    - Struktur braucht nicht bekannt zu sein, nur Seitenstruktur relevant
- Gegensatz: Logisches Redo (‚Setze Tupelwert auf v')
  - Redo müsste vollständig durchgeführt werden, auch Indexeinträge würden neu generiert, inkl. Aufspaltung usw.

Redo/Undo-Information

- ARIES unterstützt logisches Undo
- Seitenorientiertes Undo kann kaskadierende Rückroll-Situationen heraufbeschwören
  - Selbst wenn eine Transaktion T_1 nicht direkt Tupel betrachtet hat, die von anderer Transaktion T_2 beschrieben wurden, ist doch das physikalische Seitenlayout, dass T_1 sieht, von T_2 beeinflusst
  - T_1 kann nicht vor T_2 erfolgreich beendet werden
- Logisches Undo erhöht also die Nebenläufigkeit

Schreiben von Log-Einträgen

- Aus Performanzgründen werden Log-Einträge zunächst in flüchtigen Speicher geschrieben
- Zu bestimmten Zeiten werden die Einträge bis zu einer bestimmten LSN in stabilen Speicher geschrieben
  - Alle Einträge bis zum EOT einer Transaktion T werden auf die Platte geschrieben wenn T erfolgreich beendet (um ein Redo von Ts Effekten vorzubereiten)
  - Wenn eine Datenseite p auf die Platte geschrieben wird, werden vorher die letzten Modifikationen von p im WAL auf die Platte geschrieben (zur Vorbereitung eines Undo)
- Die Größe des Logs nimmt immer weiter zu (s. aber Schnappschüsse weiter unten)

Normaler Verarbeitungsmodus

Während der normalen Transaktionsverarbeitung werden zwei Dinge im Transaktionskontrollblock gespeichert

- LastLSN (Last Log Sequence Number)
  - LSN des letzten geschriebenen Log-Eintrags für die Transaktion
- UNxt (LSN Next to be Undone)
  - LSN des nächsten Eintrags, der beim Rückrollen betrachtet werden muss

Wenn eine Aktualisierung einer Seite p durchgeführt wird

- wird ein Eintrag r ins WAL geschrieben und
- die LSN von r im Seitenkopf von p gespeichert

Datenstruktur zur Buchführung

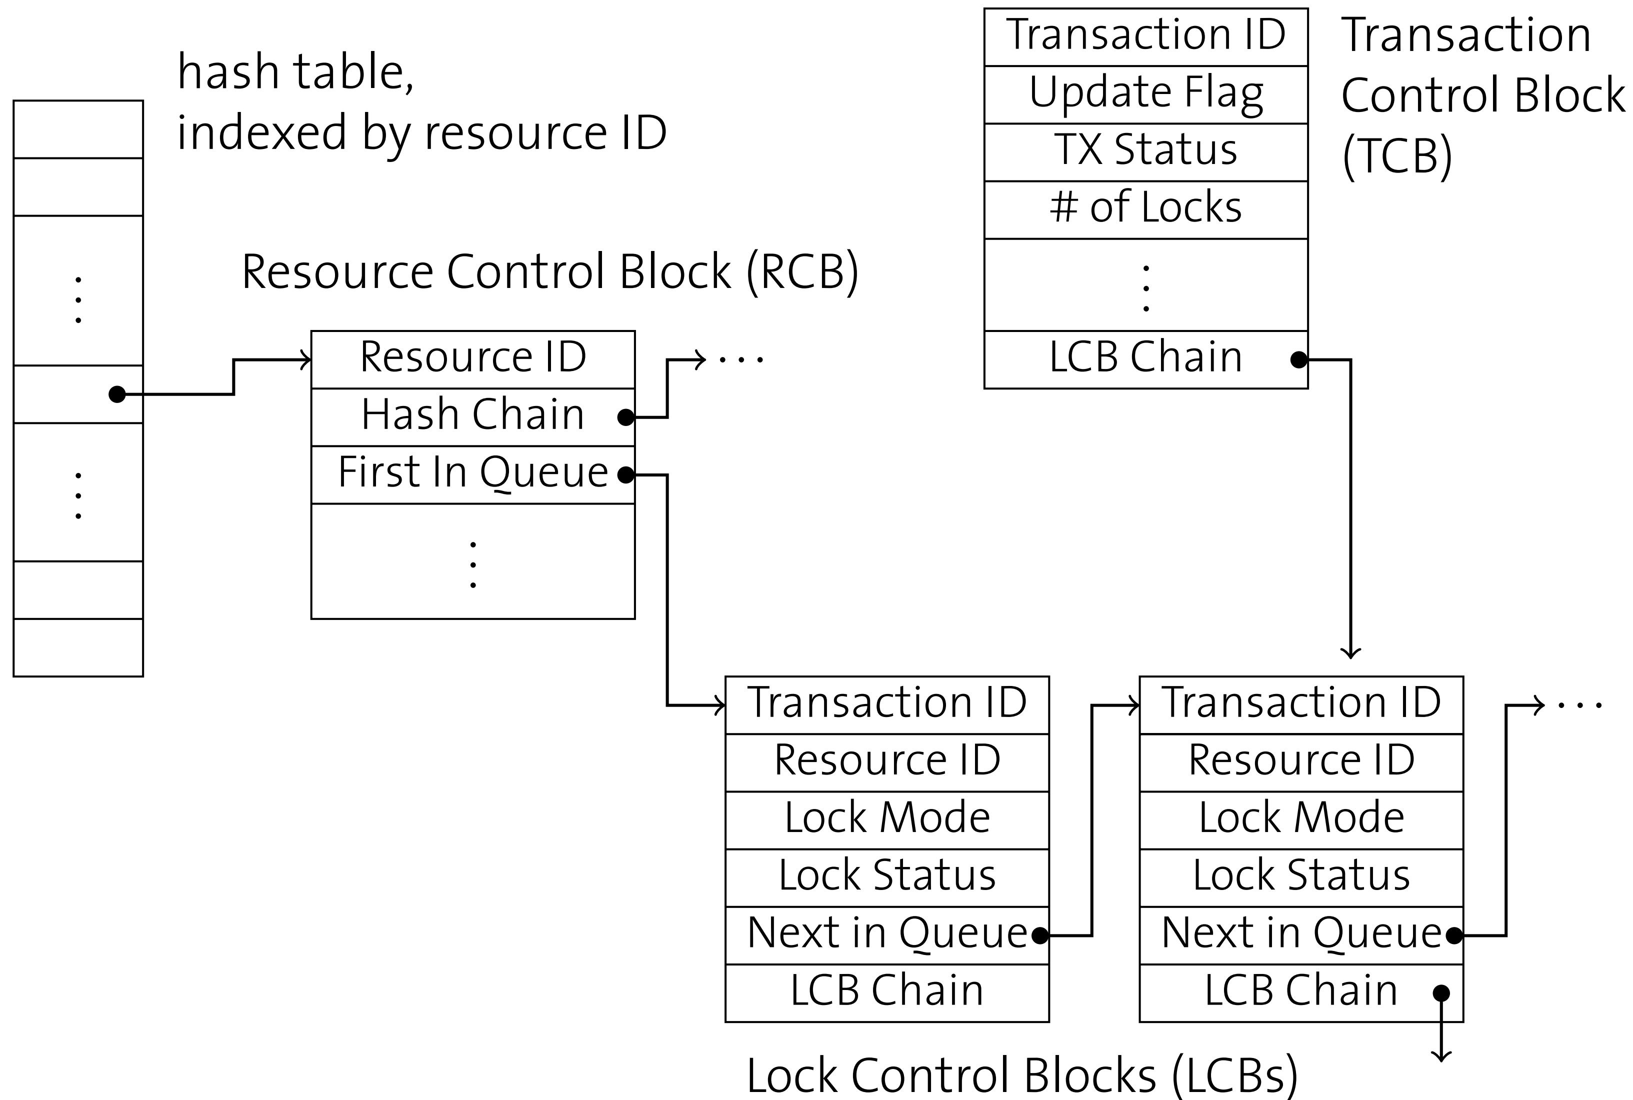

Rückrollen einer Transaktion

Schritte zum Rückrollen einer Transaktion T:

- Abarbeiten des WAL in Rückwärtsrichtung
- Beginn bei Eintrag, auf den UNxt im Transaktionskontrollblock von T zeigt
- Finden der übrigen Einträge von T durch Verfolgen der Prev- und UNxt-Einträge im Log

Undo-Operationen modifizieren ebenfalls Seiten

- Logging der Undo-Operationen im WAL
- Verwendung von Compensation-Log-Record (CLRs) für diesen Zweck

Rückrollen einer Transaktion

```
1  Function: rollback (SaveLSN, T)
2  UndoNxt ← T.UNxt ;
3  while SaveLSN < UndoNxt do
4      LogRec ← read log entry with LSN UndoNxt ;
5      switch LogRec.Type do
6          case UPD
7              perform undo operation LogRec.Undo on page LogRec.Page ;
8              LSN ← write log entry
                       ⟨CLR, T, T.LastLSN, LogRec.Page, LogRec.Prev, ··· , ∅⟩ ;
9              set LSN = LSN in page header of LogRec.Page ;
10             T.LastLSN ← LSN ;
11         case CLR
12             UndoNxt ← LogRec.UNxt ;
13     T.UNxt ← UndoNxt ;
```

Rückrollen einer Transaktion

- Transaktionen können auch partiell zurückgerollt werden (zur SaveLSN)
  - Wozu könnte das nützlich sein?
- Das UNxt-Feld in einem CLR zeigt auf den Logeintrag vor demjenigen, der ungeschehen gemacht wurde

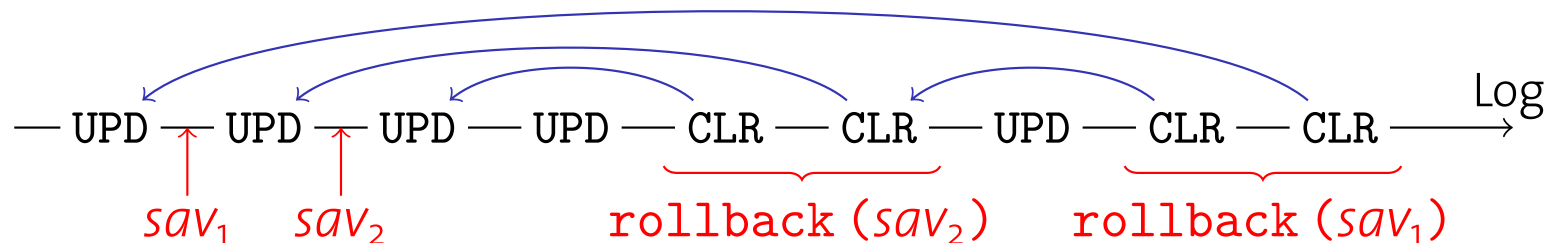

Wiederherstellung nach Ausfall

Neustart nach einem Systemabsturz in drei Phasen

1. Analyse-Phase:
   - Lese Log in Vorwärtsrichtung
   - Bestimmt Transaktionen, die aktiv waren als der Absturz passierte (solche Transaktionen nennen wir Pechvögel)
2. Redo-Phase:
   - Spiele Operation im Log erneut ab (in Vorwärtsrichtung), um das System in den Zustand vor dem Fehler zu bringen
3. Undo-Phase:
   - Rolle Pechvögel-Transaktionen zurück, in dem das Log in Rückwärtsrichtung abgearbeitet wird (wie beim normalen Zurückrollen)

Analyse-Phase

```
1  Function: analyze ()
2  foreach log entry record LogRec do
3      switch LocRec.Type do
4          create transaction control block for LogRec.TX if necessary ;
5          case UPD or CLR
6              LogRec.TX.LastLSN ← LogRec.LSN ;
7              if LocRec.Type = UPD then
8                  LogRec.TX.UNxt ← LogRec.LSN ;
9              else
10                 LogRec.TX.UNxt ← LogRec.UNxt ;
11         case EOT
12             delete transaction control block for LogRec.TX ;
```

Redo-Phase

```
1 Function: redo ()
2 foreach log entry record LogRec do
3     switch LocRec.Type do
4         case UPD or CLR
5             v ← pin (LogRec.Page) ;
6             if v.LSN < LogRec.LSN then
7                 perform redo operation LogRec.Redo on v ;
8                 v.LSN ← LogRec.LSN ;
9             unpin (v, ···) ;
```

Auch beim Wiederherstellen können Abstürze eintreten

- Undo und Redo einer Transaktion müssen idempotent sein
  - undo(undo(T)) = undo(T) // Nicht z.B. bei A := A - 10
  - redo(redo(T)) = redo(T)
- Prüfe LSN vor der Redo-Operation

Wiederholung

Funktion pin für Anfragen nach Seiten und
unpin für Freistellungen von Seiten nach Verwendung

- pin(pageno)
  - Anfrage nach Seitennummer pageno
  - Lade Seite in Hauptspeicher falls nötig
  - Rückgabe einer Referenz auf pageno
- unpin(pageno, dirty)
  - Freistellung einer Seite pageno zur möglichen Auslagerung
  - dirty = true bei Modifikationen der Seite

Redo-Phase

- Beachte, dass alle Operationen (auch solche von Pechvögeln) in chronologischer Ordnung erneut durchgeführt werden
- Nach der Redo-Phase ist das System im gleichen Zustand, wie zum Fehlerzeitpunkt
  - Einige Log-Einträge sind noch nicht auf der Platte, obwohl erfolgreich beendete Transaktionen ihre Änderung geschrieben hätten. Alle anderen müssten ungeschehen gemacht werden
- Wir müssen hinterher alle Effekte von Pechvögeln ungeschehen machen
- Als Optimierung kann man den Puffermanager instruieren, geänderte Seiten vorab zu holen (Prefetch)

Undo-Phase

- Die Undo-Phase ist ähnlich zum Rückrollen im normalen Betrieb
- Es werden mehrere Transaktionen auf einmal zurückgerollt (alle Pechvögel)
- Alle Pechvögel werden vollständig zurückgerollt

Undo-Phase

```
1  Function: undo ()
2  while transactions (i.e., TCBs) left to roll back do
3      T ← TCB of loser transaction with greatest UNxt ;
4      LogRec ← read log entry with LSN T.UNxt ;
5      switch LogRec.Type do
6          case UPD
7              perform undo operation LogRec.Undo on page LogRec.Page ;
8              LSN ← write log entry
                       ⟨CLR, T, T.LastLSN, LogRec.Page, LogRec.Prev, ··· , ∅⟩ ;
9              set LSN = LSN in page header of LogRec.Page ;
10             T.LastLSN ← LSN ;
11         case CLR
12             UndoNxt ← LogRec.UNxt ;
13     T.UNxt ← UndoNxt ;
14     if T.UNxt = '–' then
15         write EOT log entry for T ;
16         delete TCB for T ;
```

Checkpointing

- WAL ist eine immer-wachsendes Log-Datei, die bei der Wiederherstellung gelesen wird
- In der Praxis sollte die Datei nicht zu groß werden (Wiederherstellung dauert zu lange)
- Daher wird ab und zu ein sog. Checkpoint erstellt
  - Schwergewichtiger Checkpoint:
    Speicherung aller geänderter Seiten auf der Platte, dann Verwaltungsinformation für Checkpoint schreiben (Redo kann dann ab Checkpoint erfolgen)
  - Leichtgewichtiger Checkpoint:
    Speichere Information bzgl. geänderter Seiten in Log, aber keine Seiten (Redo ab Zeitpunkt kurz vor Checkpoint)

Medien-Wiederherstellung

- Um Medienfehler zu kompensieren, muss peridiodisch eine Sicherungskopie erstellt werden (nicht-flüchtiger Speicher)
- Kann während des Betriebs erfolgen, wenn WAL auch gesichert wird
- Wenn Pufferverwalter verwendet wird, reicht es, das Log vom Zeitpunkt des Backups zu archivieren
  - Pufferverwalter hat aktuelle Seiten
  - Sonst muss bis zum ältesten Write der aktualisierten Seiten zurückgegangen werden
- Anderer Ansatz:
  Spiegeldatenbank auf anderem Rechner

Leichtgewichtiger Checkpoint

Schreibe periodisch Checkpoint in drei Phasen

1. Schreibe Begin-Checkpoint-Logeintrag BCK
2. Sammle Information
   - über geänderte Seiten im Pufferverwalter und dem LSN ihrer letzten Modifikationsoperation und
   - über alle aktiven Transaktionen (und ihrer LastLSN und UNxt TCB-Einträge)

   Schreibe diese Information in End-Checkpoint Eintrag ECK
3. Setze Master-Record auf bekannte Position auf der Platte und zeige auf LSN und BCK Logeinträge

Wiederherstellung mit leichtgew. Checkpoint

Während der Wiederherstellung

- Starte Analyse beim BCK-Eintrag im Master-Record (anstelle vom Anfang des Logs)
- Wenn der ECK-Eintrag gelesen wird
  - Bestimme kleinste LSN für die die Redo-Verarbeitung und
  - Erzeuge TCBs für alle Transaktionen im Checkpoint

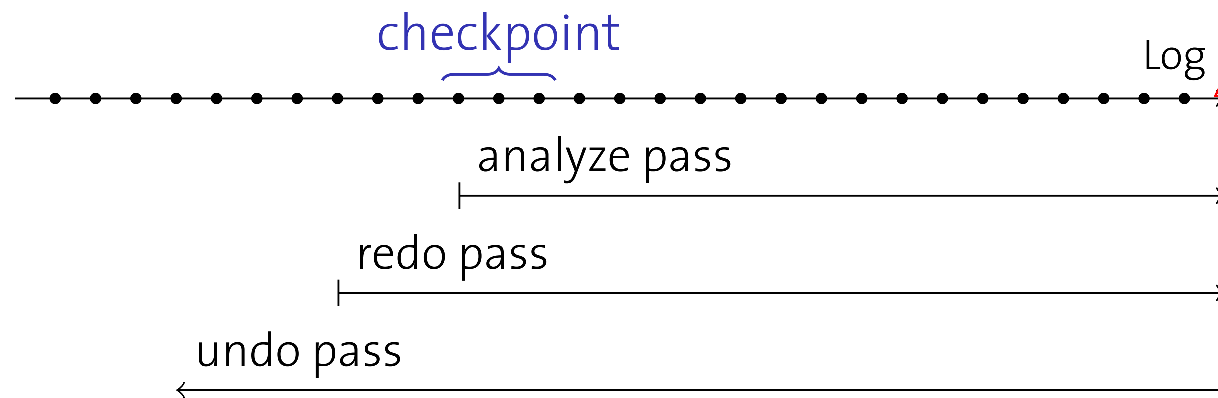

Zusammenfassung

- ACID und Serialisierbarkeit
  - Vermeiden von Anomalien durch Nebenläufigkeit
  - Serialisierbarkeit reicht für Isolation
- Zwei-Phasen-Sperrprotokoll
  - 2PL ist eine praktikable Technik, um Serialisierbarkeit zu garantieren (meist wird strikte 2PL verwendet)
  - In SQL-92 können sog. Isolationsgrade eingestellt werden (Abschwächung der ACID-Bedingungen)
- Nebenläufigkeit in B-Bäumen
  - Spezialisierte Protokolle (WTL) zur Flaschenhalsvermeidung
- Wiederherstellung (ARIES)
  - Write-Ahead-Log, Checkpoints

Das Gesamtbild der Architektur