WWU MÜNSTER

Transaktionen

Datenbanken

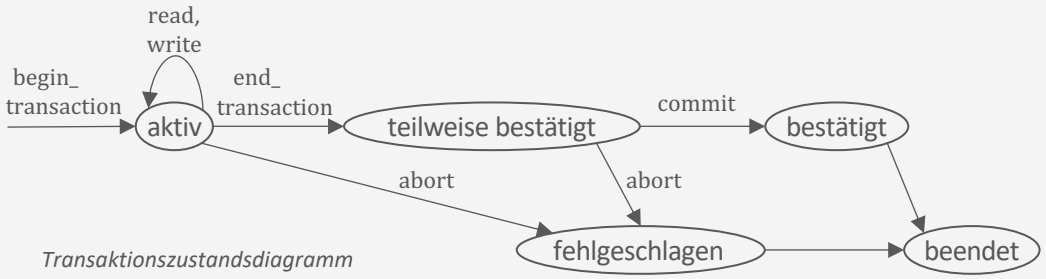

Transaktionszustandsdiagramm

wissen.leben

Tanya Braun
Arbeitsgruppe Data Science, Institut für Informatik

Inhalte: Datenbanken (DBs)

1. **Einführung**
   - Anwendungen
   - Datenbankmanagementsysteme
2. **Datenbank-Modellierung**
   - Entity-Relationship-Modell (ER-Modell)
   - Beziehung zwischen ER und UML
3. **Das relationale Modell**
   - Relationales Datenmodell (RM)
   - Vom ER-Modell zum RM
   - Relationale Algebra als Anfragesprache
4. **Datenbank-Entwurf**
   - Funktionale Abhängigkeiten
   - Normalformen
5. **Structured Query Language (SQL)**
   - Datendefinition
   - Datenmanipulation
6. **Anfrageverarbeitung**
   - Architektur
   - Indexierung
   - Anfragepläne, Optimierung
7. **Transaktionen**
   - Transaktionsverarbeitung, Schedules, Sperren
   - Wiederherstellung
8. **Erweiterung**
   - Noch offen: verteilte DBs, deduktive DBs (DataLog → Logik-Verbindung), XML, Graph-DBs

Architektur eines DBMS

- Speicherung
- Anfrageverarbeitung
- Transaktionsmanagement
  - Transaktionsverwaltung
  - Sperrverwaltung
  - Wiederherstellungsverwaltung

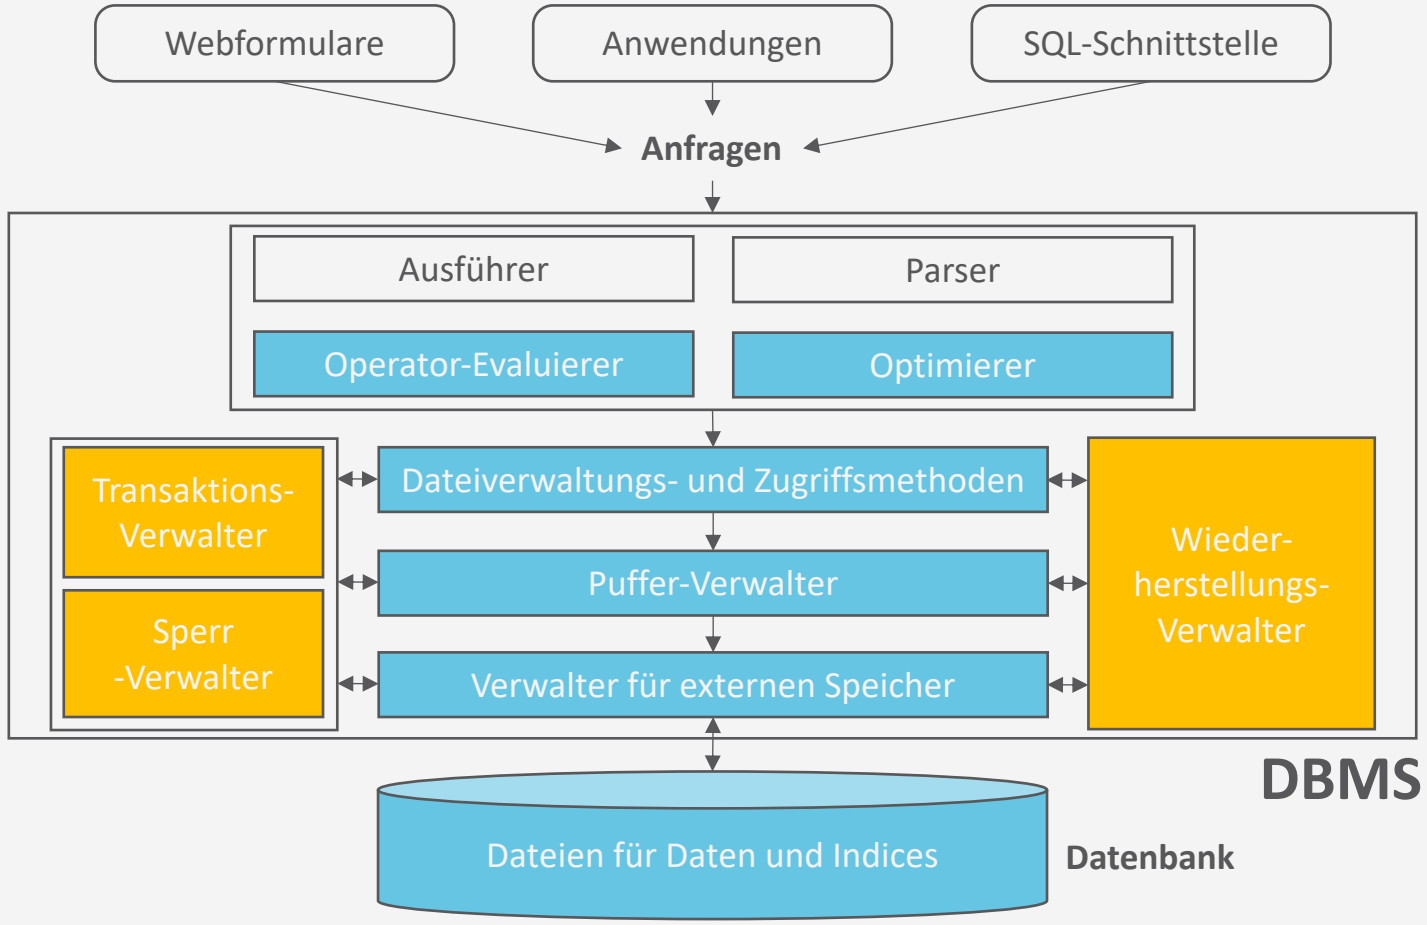

Überblick: 7. Transaktionen

A. ***Transaktionsverarbeitung***
   - Fehlersituationen
   - Schedules: Korrektheit, Serialisierbarkeit, Äquivalenzen

B. *Sperrverwaltung*
   - Sperren, Sperrprotokolle
   - Deadlocks
   - Weitere Methoden zur Mehrbenutzerkontrolle

C. *Wiederherstellungsverwaltung*
   - Fehlersituationen
   - Logging
   - Recovery

Architektur eines DBMS

- Speicherung
- Anfrageverarbeitung
- Transaktionsmanagement
  - Transaktionsverwaltung
  - Sperrverwaltung
  - Wiederherstellungsverwaltung

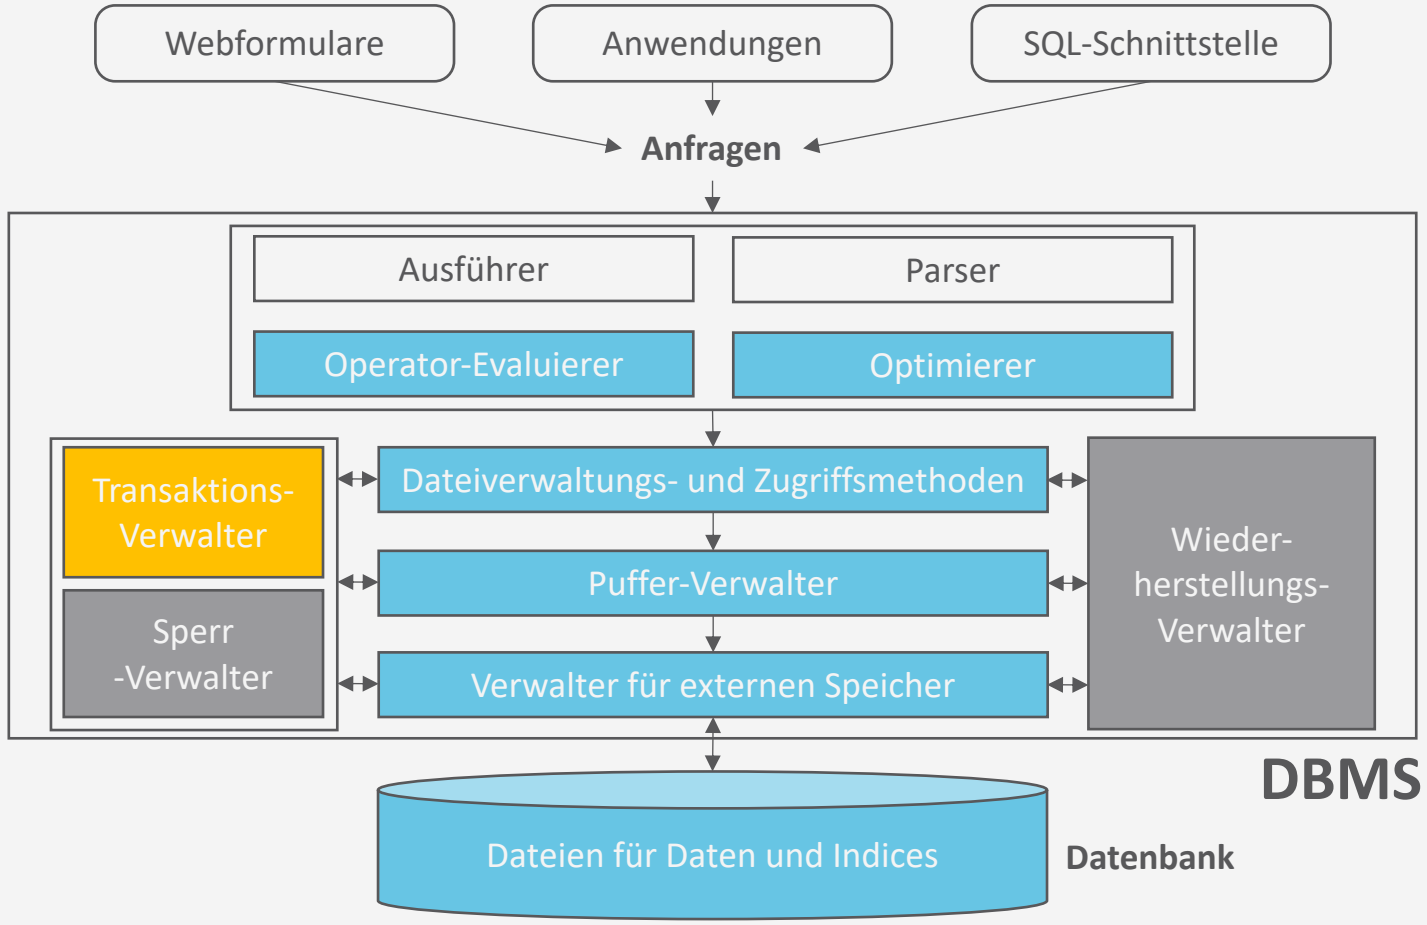

Viele gleichzeitige Nutzer*innen

- Jede*r Nutzer*in
  - Stellt Anfrage an den Kontostand
  - Verändert den Kontostand

  → Abfolge von DB-Befehlen = Transaktion
- Anforderungen:
  - **A**tomicity (Atomarität): Alles oder nichts
  - **C**onsistency (Konsistenz): Vorher ok, hinterher ok
  - **I**solation (Isolation): Jede*r denkt, sie seien alleine auf der DB
  - **D**urability (Dauerhaftigkeit): Transaktionen bestätigt? Dann sind die Daten jetzt sicher

ACID-Eigenschaften (später mehr)

Es ist später

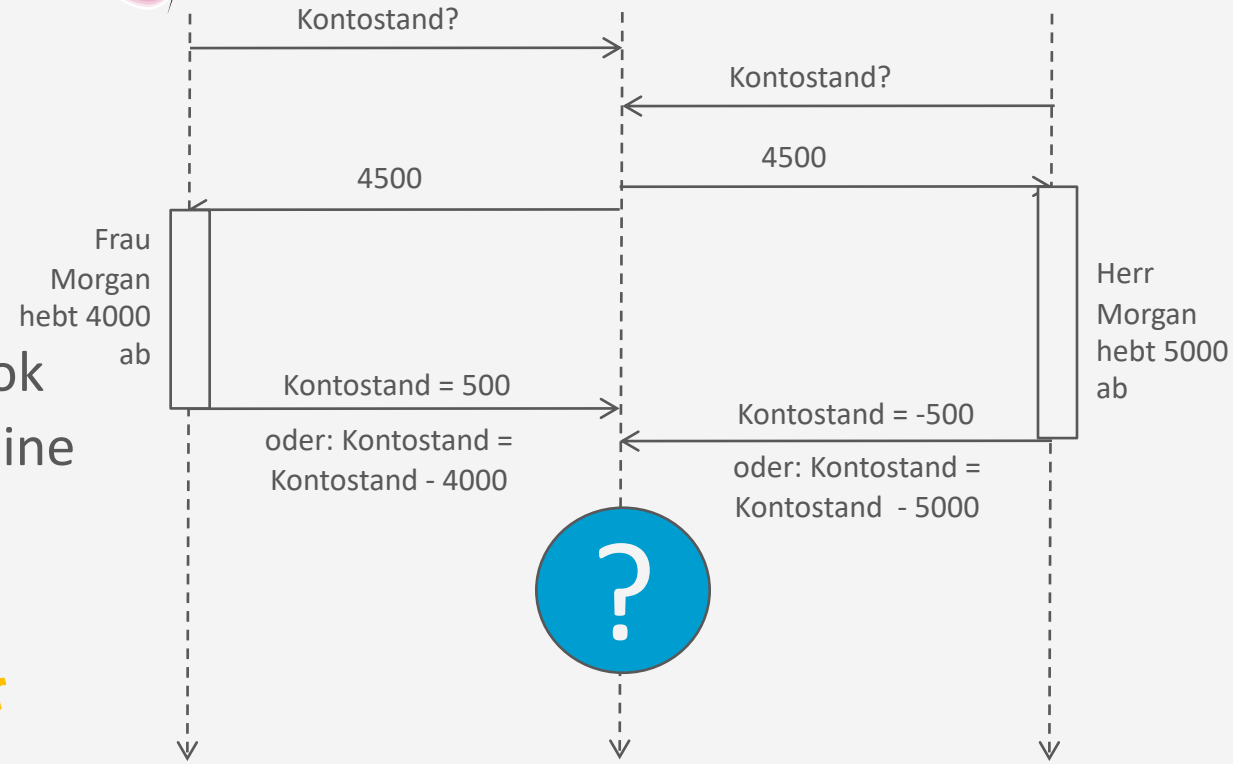

DB-Transaktion - Definition

- (DB-)Transaktion: logische Verarbeitungseinheit auf einer DB
  - Enthält typischerweise mehrere DB-Operationen (Lesen, Einfügen, Aktualisieren, Löschen)
  - Können aus Anwendungsprogrammen heraus oder im Rahmen manueller Eingaben über eine SQL-Schnittstelle realisiert werden
  - Werden mit einem speziellen Schlüsselwort gestartet (BEGIN_TRANSACTION, BOT) und beendet (END_TRANSACTION, EOT)
    - Gelten nach Ausführung von END_TRANSACTION als teilweise (bzw. vorläufig) bestätigt
      - Sind dann aber erst „logisch“ und noch nicht physisch persistent abgeschlossen
      - Werden erst nach COMMIT endgültig physisch durchgeführt (Vgl. Logging, siehe später)
      - Müssen zurückgesetzt werden (ABORT), wenn die Persistenz nicht durch COMMIT erreicht wird

      → Transaktion muss mit COMMIT oder ABORT enden
- Lesende Transaktion: DB wird innerhalb einer Transaktion nicht verändert

Schüsselwörter einer Transaktion

- begin_transaction: Startet eine Transaktion
- end_transaction: Beendet eine Transaktion logisch
- commit (Bestätigung): Fügt die Ergebnisse der Transaktion persistent in den Datenbestand ein
- abort: Abbruch einer Transaktion, DB-Änderungen werden vollständig verworfen bzw. zurückgenommen

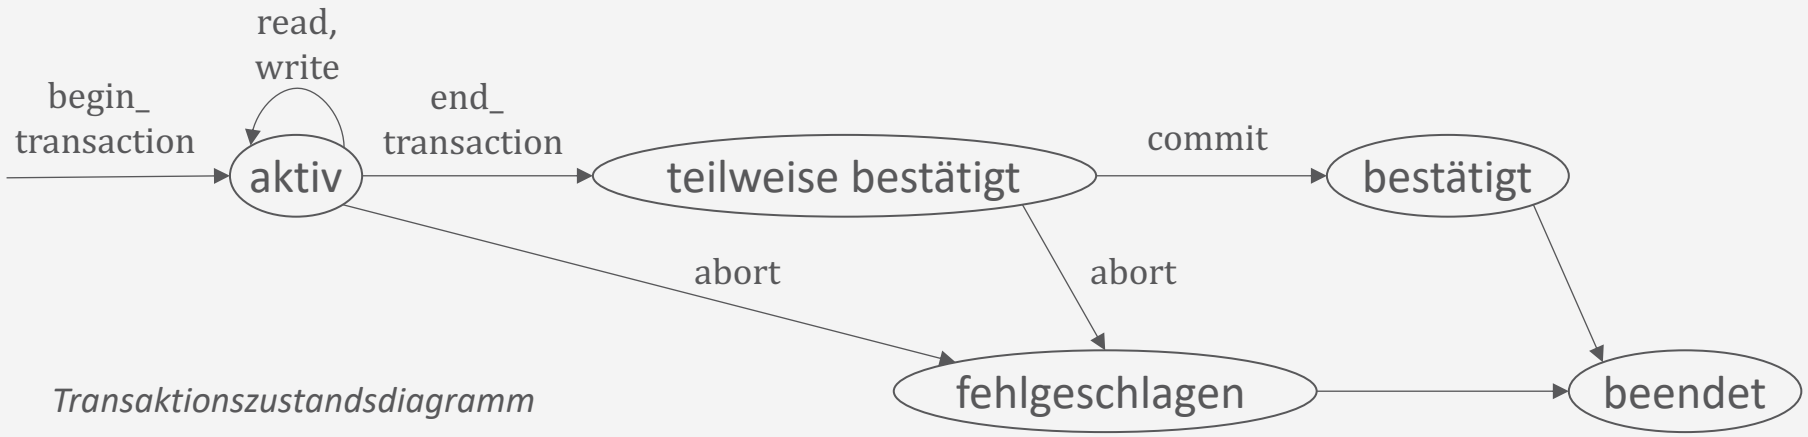

Transaktionszustandsdiagramm

Lese- und Schreib-Operationen

- Für diese Lerneinheit: Datenbank = Sammlung von Datenobjekten
  - Datenobjekt kann Feld (Attribut) eines Datensatzes (Tupels), ein gesamter Datensatz oder ein Plattenblock (Zusammenfassung vieler Datensätze) sein
    → Abstraktion von deren Größe (Granularität)
- Grundlegenden DB-Zugriffsoperationen in Transaktionen:
  - $\text{read\_item}(X)$:
    - Liest ein Datenobjekt X aus einer DB in eine Programmvariable
    - Zur Vereinfachung der Notation wird angenommen, dass die Programmvariable ebenfalls X heißt
  - $\text{write\_item}(X)$:
    - Schreibt den Wert einer Programmvariablen X in das entsprechende Datenobjekt X der DB
  - Beispiel: Transaktionen T_1, T_2

T_1	T_2
$\text{read\_item}(X)$	$\text{read\_item}(X)$
$X := X - N$	$X := X + M$
$\text{write\_item}(X)$	$\text{write\_item}(X)$
$\text{read\_item}(Y)$	
$Y := Y + N$	
$\text{write\_item}(Y)$	

Realisierung von Read und Write

- Aktionen zur Realisierung einer $\text{read\_item}(X)$-Anweisung:
  1. Suche Adresse des Plattenblocks, der Datenobjekt X enthält
  2. Kopiere den ermittelten Plattenblock in Arbeitsspeicher (sofern der Plattenblock noch extern ist, d.h. sich nicht im internen Arbeitsspeicher befindet)
  3. Kopiere den Wert des Datenobjekts X in die entsprechende Programm-variable X
- Aktionen zur Realisierung einer $\text{write\_item}(X)$-Anweisung:
  1. Suche Adresse des Plattenblocks, der Datenobjekt X enthält
  2. Kopiere den ermittelten Block in Arbeitsspeicher (sofern der Plattenblock noch extern ist, d.h. sich nicht im internen Arbeitsspeicher befindet)
  3. Kopiere den Wert der Programmvariablen X an die entsprechende Stelle im Arbeitsspeicher
  4. Schreibe den modifizierten Block sofort oder später in den Plattenblock

Fehlersituationen

Transaktionsverarbeitung

Fehlermöglichkeiten

- Eine (verschachtelt) nebenläufige Ausführung der in T_1 und T_2 enthaltenen Anweisungen ohne jegliche Kontrollmechanismen, die die korrekte Ausführung sicherstellen, kann in verschiedene Fehlersituationen münden:
  - Lost Update
  - Dirty Read
  - Ghost Update
  - Unrepeatable Read

  - *Für die vier grundsätzlichen Fehlersituationen folgt je ein Beispiel zur Erläuterung. Die Fehler entstehen je nach konkreter zeitlicher Abfolge der einzelnen Operationen in nebenläufigen Transaktionen.*
  - *Für alle Beispiele in diesem Foliensatz: Annahme, dass die Transaktionen mit ihrer letzten Operation logisch beendet werden (end_transaction)*

LOST UPDATE

- Operationen zweier Transaktionen greifen auf die gleichen Datenobjekte zu
- Dabei überschneiden sie sich zeitlich derart, dass einzelne durchgeführte Aktualisierungen der Datenobjekte verloren gehen
- Beispiel: Verschränkte Ausführung von T_1, T_2
  - Aktualisierung von X in T_1 in Zeile 5 geht durch das Schreiben in T_2 in Zeile 7 verloren
    - X hat einen falschen Wert in Zeile 3

Zeit

	T_1	T_2
1	$\text{read\_item}(X)$	
2	$X := X - N$	
3		$\text{read\_item}(X)$
4		$X := X + M$
5	$\text{write\_item}(X)$	
6	$\text{read\_item}(Y)$	
7		$\text{write\_item}(X)$
8	$Y := Y + N$	
9	$\text{write\_item}(Y)$	

DIRTY READ

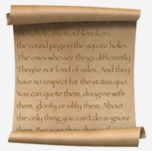

- Durch eine Transaktion, die später abgebrochen wird, findet zunächst eine Aktualisierung eines Datenobjekts statt
- Eine andere Transaktion liest das modifizierte Datenobjekt, bevor die bereits durchgeführte Aktualisierung in T_1 verworfen wird
- Beispiel: Verschränkte Ausführung von T_1, T_2
  - T_1 schlägt fehl → Wert von X muss auf den alten Wert zurückgesetzt werden
  - Inzwischen hat aber T_2 den von T_1 geschriebenen Wert gelesen und verrechnet

Zeit

	T_1	T_2
1	read_item(X)	
2	$X := X - N$	
3	write_item(X)	
4		read_item(X)
5		$X := X + M$
6		write_item(X)
7	read_item(Y)	
8	abort	
9		

Wie spielt ACID hier rein?

GHOST UPDATE

- Zwei nebenläufige Transaktionen
  - Eine Transaktion berechnet eine Aggregation auf einer Menge von Datenobjekten
  - Eine andere Transaktion aktualisiert einige dieser Datenobjekte
- In die Aggregation gehen u.U. Datenobjekte ein, die bereits aktualisiert wurden, und andere mit ihrem Wert vor einer Aktualisierung
- Beispiel: Verschränkte Ausführung von T_1, T_3
  - T_3 liest X, nachdem N in T_1 subtrahiert wurde, und Y, bevor N in T_1 addiert wird
    - Ergibt ein um N falsches Resultat

	T_1	T_3
1		$sum := 0$
2		$\text{read\_item}(A)$
3		$sum := sum + A$
		$\vdots$
4	$\text{read\_item}(X)$	
5	$X := X - N$	
6	$\text{write\_item}(X)$	
7		$\text{read\_item}(X)$
8		$sum := sum + X$
9		$\text{read\_item}(Y)$
10		$sum := sum + Y$
11	$\text{read\_item}(Y)$	
12	$Y := Y + N$	
13	$\text{write\_item}(Y)$	

UNREPEATABLE READ

- Datenobjekt wird innerhalb einer Transaktion mehrfach gelesen, während eine andere Transaktion dieses Datenobjekt modifiziert
- Je nach zeitlicher Abfolge der Anweisungen in den beiden Transaktionen wird nicht der jeweils gleiche Wert wiederholt gelesen
- Ähnlicher Fehler: PHANTOM READ
  - Während eine Transaktion eine Tabelle (wiederholt) liest, fügt eine andere Transaktion neue Tupel ein oder löscht Tupel
- Beispiel: Verschränkte Ausführung von T', T''
  - In Zeile 9 hat X einen um N niedrigeren Wert, als wenn der Lesebefehl vor Start von T'' erfolgt wäre

	T'	T''
1	$sum := 0$	
2	$\text{read\_item}(A)$	
3	$sum := sum + A$	
	$\vdots$	
4	$\text{read\_item}(X)$	
5	$sum := sum + X$	
6		$\text{read\_item}(X)$
7	$\vdots$	$X := X - N$
8		$\text{write\_item}(X)$
9	$\text{read\_item}(X)$	

Zwischenzusammenfassung

- Verschiedene Operationen und Zustände während der Transaktionsverarbeitung
  - BEGIN_TRANSACTION, END_TRANSACTION, COMMIT, ABORT
  - READ_ITEM, WRITE_ITEM
- Probleme bei verschränkter Ausführung von Transaktionen
  - *Lost Update*: Überschreiben einer Aktualisierung bzw. Arbeiten mit einem veralteten Wert
  - *Dirty Read*: Lesen eines Wertes, der durch eine Transaktion geändert wurde, die dannach abgebrochen wurde
  - *Ghost Update*: Zusammenhängende aktualisierte und nicht aktualisierte Werte werden verarbeitet
  - *Unrepeatable Read*: Werte ändern sich beim wiederholten Lesen (andere Reihenfolge führt zu anderem Ergebnis)

Schedules

Transaktionsverarbeitung

Nebenläufige Ausführung

- Große Menge von Transaktionen
  - Sequentielle Ausführung vermeidet Probleme, aber kostet viel Zeit
  - Nebenläufige Ausführung bei entsprechender Hardware-Unterstützung ist schneller, kann aber zu Anomalien führen
- Anforderung an DBMS:
  Nebenläufige Ausführung und keine Anomalien

- Steuerprogramm (Scheduler) entscheidet über die Ausführungsreihenfolge der nebenläufigen Datenbankzugriffe
  - Ziel: Korrekte verschachtelte *Schedules* (Definition folgt)

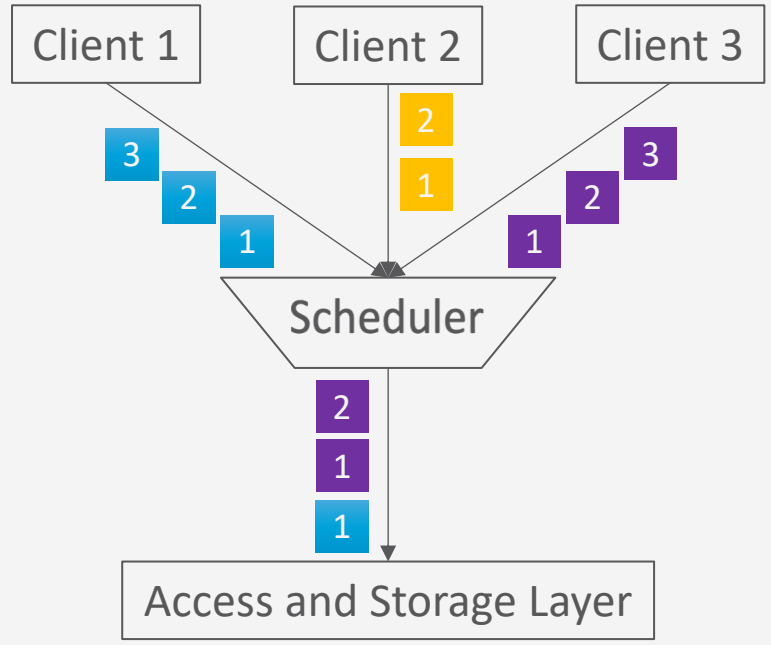

Schedules von Transaktionen

- Ausführungsplan / Schedule S
  - Integrierte Abfolge der Operationen überlappend ausgeführter Transaktionen
  - Schedule S von n Transaktionen $T_1, \ldots, T_n$ ist eine Sequenz von Transaktionsoperationen mit der Eigenschaft, dass die Operationen einer Transaktion T_i in S in der gleichen Reihenfolge wie in T_i erscheinen,
    - I.e., $T_i = \langle p_1, \ldots, p_{N'} \rangle$ und $S = \langle o_1, \ldots, o_N \rangle$ mit $T_i = \pi_i(S)$ (Reihenfolge erhaltende Abb. von S auf T_i)
- Abkürzungen für die folgenden Folien:
  - Operation (read oder write) auf Objekt X einer Transaktion T_i: $p_i(X)$
  - READ_ITEM auf Objekt X einer Transaktion T_i: $r_i(X)$
  - WRITE_ITEM von Objekt X einer Transaktion T_i: $w_i(X)$
  - COMMIT einer Transaktion T_i: c_i
  - ABORT einer Transaktion T_i: a_i

Beispiele für Schedules

- Transaktionen
  - Reduziert auf w_i, r_i
  - $T_1 = \langle r_1(X), w_1(X), r_1(Y), w_1(Y) \rangle$
    - Bzw. $T_1 = \langle r_1(X), w_1(X), r_1(Y), a_1 \rangle$
  - $T_2 = \langle r_2(X), w_2(X) \rangle$
- Schedules
  - $S_a = \langle r_1(X), r_2(X), w_1(X), r_1(Y), w_2(X), w_1(Y) \rangle$
  - $S_b = \langle r_1(X), w_1(X), r_2(X), w_2(X), r_1(Y), a_1 \rangle$

	S_a	T_1	T_2
1		read_item(X)	
2		$X := X - N$	
3			read_item(X)
4			$X := X + M$
5		write_item(X)	
6		read_item(Y)	
7			write_item(X)
8		$Y := Y + N$	
9		write_item(Y)	

	S_b	T_1	T_2
1		read_item(X)	
2		$X := X - N$	
3		write_item(X)	
4			read_item(X)
5			$X := X + M$
6			write_item(X)
7		read_item(Y)	
8		abort	
9			

Serielle Schedules

- Schedule S ist seriell, wenn die Operationen jeder in S enthaltenen Transaktion T vollständig hintereinander (streng sequenziell) ausgeführt werden
  - Für jede Transaktion T gilt, dass ihr Schritte direkt aufeinander folgen
  - Andernfalls ist ein Schedule nicht-seriell

Serielle Schedules: Beispiele

- Schedule S_d
  - $S_d = \langle r_1(X), w_1(X), r_1(Y), w_1(Y), r_2(X), w_2(X) \rangle$
  - $T_1 | T_2$
- Schedule S_e
  - $S_e = \langle r_2(X), w_2(X), r_1(X), w_1(X), r_1(Y), w_1(Y) \rangle$
  - $T_2 | T_1$

S_d	T_1	T_2
1	read_item(X)	
2	$X := X - N$	
3	write_item(X)	
4	read_item(Y)	
5	$Y := Y + N$	
6	write_item(Y)	
7		read_item(X)
8		$X := X + M$
9		write_item(X)

S_e	T_1	T_2
1		read_item(X)
2		$X := X + M$
3		write_item(X)
4	read_item(X)	
5	$X := X - N$	
6	write_item(X)	
7	read_item(Y)	
8	$Y := Y + N$	
9	write_item(Y)	

Korrekte Schedules

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

Korrekte Schedules

- Manchmal kann man einfach Teilschritte aus verschiedenen Transaktionen in einem Plan umordnen
  - Nicht jedoch die Teilschritte innerhalb einer einzelnen Transaktion (da 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 möglicherweise verfälscht) → Konflikt

Konflikte

- Zwei Operationen $p_i(X), p_j(X)$ in einem Schedule stehen in Konflikt (sind konfliktär), wenn alle folgenden Bedingungen erfüllt sind:
  - Sie gehören zu unterschiedlichen Transaktionen ($i \neq j$)
  - Sie greifen auf das gleiche Datenobjekt zu (X)
  - Mindestens eine Operation schreibt X ($p_i(X) = w_i(X) \vee p_j(X) = w_j(X)$)
    - Konfliktmatrix siehe rechts unten

  → Reihenfolge von $p_i(X), p_j(X)$ ist relevant
    - Nicht in Konflikt stehende Operationen können auch parallel ausgeführt werden
      - Solche Schedules heißen partiell geordnet

Konfliktmatrix

	$r_j(X)$	$w_j(X)$
$r_i(X)$		X
$w_i(X)$	X	X

Serialisierbarkeit

- Schedule S mit n Transaktionen ist serialisierbar, wenn er zu einem seriellen Schedule S' äquivalent ist, d.h., den gleichen DB-Zustand erreicht
  - Reihenfolge der konfliktären Operationen ist gleich
- Ausführung eines serialisierbaren Schedules S ist korrekt
  - S muss nicht seriell sein

Konflikte, Äquivalenz, Serialisierbarkeit, Korrektheit: Beispiele

- Schedule S_d
  - $S_d = \langle r_1(X), w_1(X), r_1(Y), w_1(Y), r_2(X), w_2(X) \rangle$
  - Konflikte: $r_1(X), w_2(Y), w_1(X), r_2(X), w_1(X), w_2(X)$
- Schedule S_c
  - $S_c = \langle r_1(X), w_1(X), r_2(X), w_2(X), r_1(Y), w_1(Y) \rangle$
  - Konflikte: Wie oben
    - Äquivalent
    - Serialisierbar
  - Damit: S_c korrekt

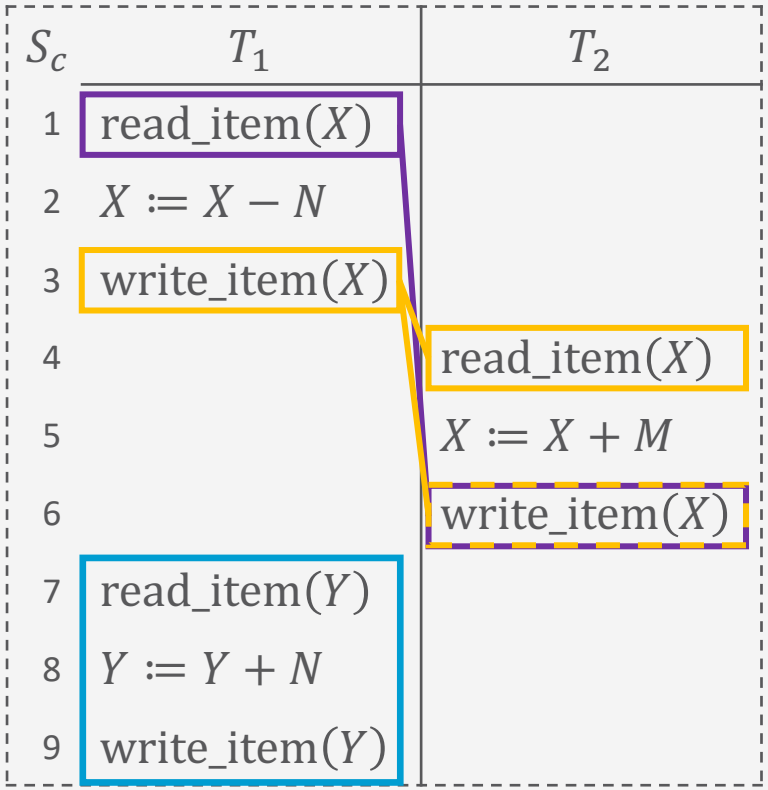

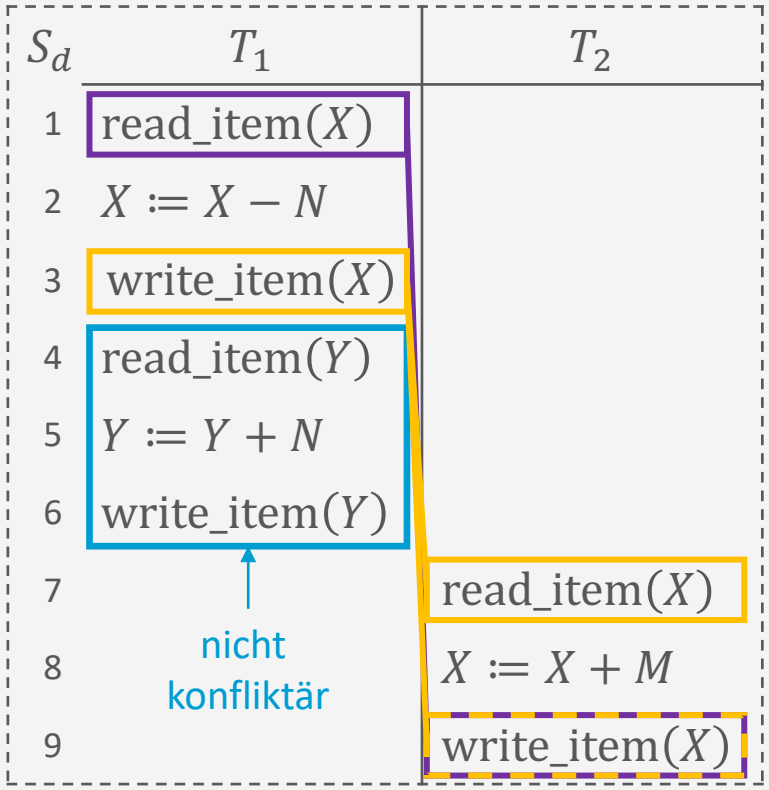

Konflikte, Äquivalenz, Serialisierbarkeit, Korrektheit: Beispiele

- Schedule S_a
  - $S_a = \langle r_1(X), r_2(X), w_1(X), r_1(Y), w_2(X), w_1(Y) \rangle$
  - Nicht äquivalent mit S_d
    - Konfliktäre Operationen $r_2(X), w_1(X)$ in S_a in anderer Reihenfolge in S_d
  - Auch nicht äquivalent mit $S_e = T_2 | T_1$
    - $S_e = \langle r_2(X), w_2(X), r_1(X), w_1(X), r_1(Y), w_1(Y) \rangle$
  - Damit S_a nicht serialisierbar
  - Damit S_a nicht korrekt

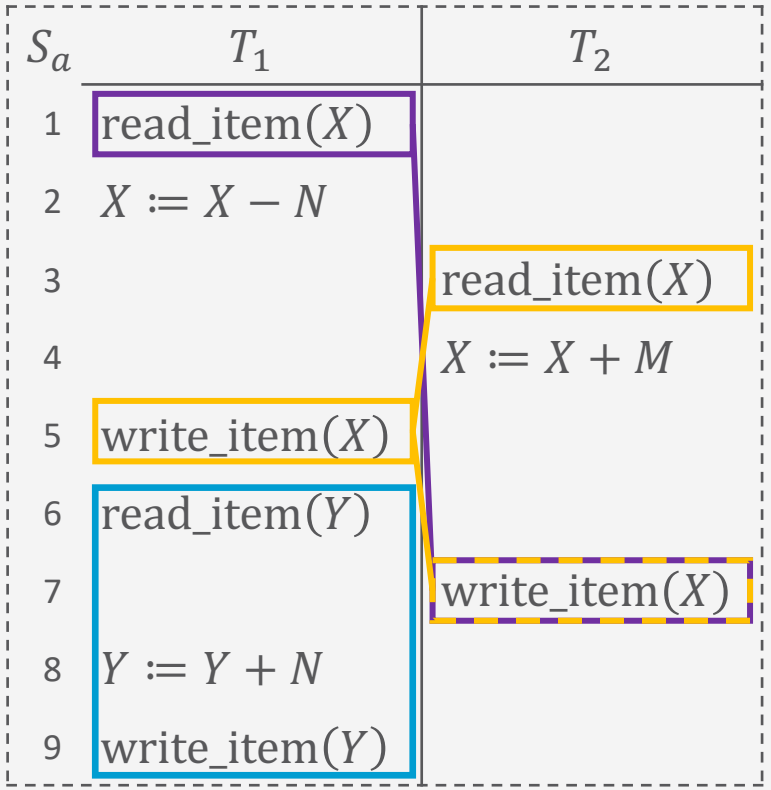

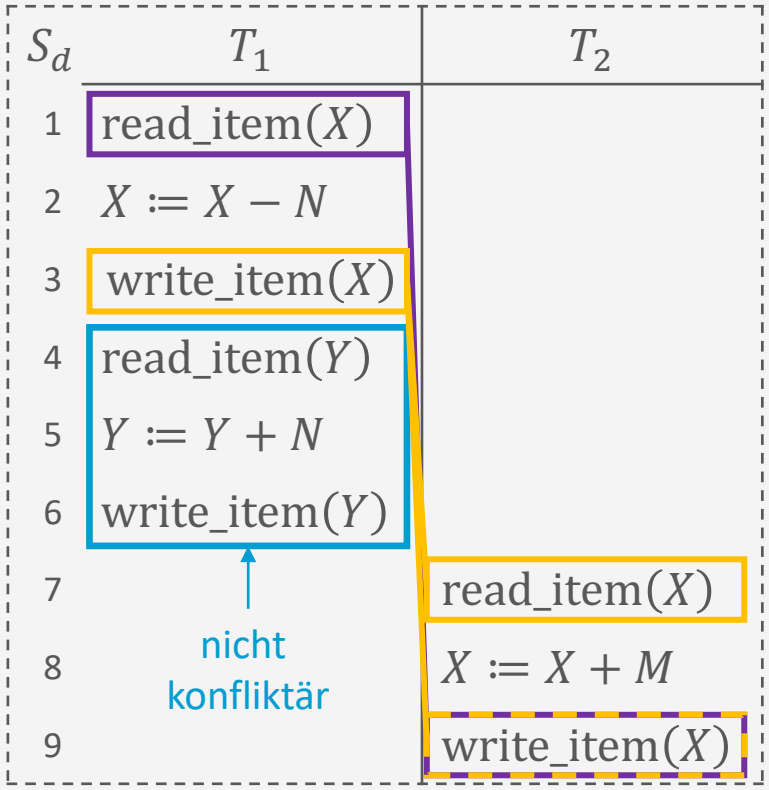

Korrektheitsprüfung mittels Serialisierungsgraphen

- Serialisierungsgraph (oder Konfliktgraph) SG für ein Schedule S ist ein gerichteter Graph $G = (N, E)$, wobei
  - $N = \{T_1, \dots, T_n\}$ Menge von Knoten, ein Knoten für jede Transaktion in S
  - $E = \{e_1, \dots, e_m\}$ Menge gerichteter Kanten
    - Jede Kante e im Graphen hat die Form $(T_i \longrightarrow T_j), 1 \leq i \leq n, 1 \leq j \leq n$, wobei T_i der Start- und T_j der Endknoten von e ist
- Kante $T_i \longrightarrow T_j$ wird erzeugt, wenn in S eine Operation von T_i vor einer mit ihr in Konflikt stehenden Operation in T_j vorkommt
  - I.e., $p_i(X)$ und $p_j(X)$ stehen in Konflikt und $p_i(X)$ erscheint vor $p_j(X)$ in S

Serialisierbarkeitstheorem
Schedule S ist serialisierbar, wenn der zugehörige Serialisierungsgraph keine Zyklen aufweist.

Korrektheitsprüfung

- Eingabe: Schedule S
- Ausgabe: S serialisierbar ja/nein
- Vorgehen
  1. Baue einen Serialisierungsgraph SG für S
     a. Erzeuge für jede Transaktion T_i, die in S auftritt, einen Knoten T_i in SG
     b. Für jeden Fall in S, bei dem erst T_i eine Operation $p_i(X)$ ausführt und dann T_j eine Operation $p_j(X)$ ausführt, wobei mindestens ein $p(X)$ eine Schreiboperation ist, erzeuge eine Kante $(T_i \longrightarrow T_j)$ in SG
        - Drei Fälle: (i) $w_i(X), r_j(X)$, (ii) $r_i(X), w_j(X)$, (iii) $w_i(X), w_j(X)$
  2. Prüfe, ob SG keinen Zyklus enthält
     a. Wenn kein Zyklus vorhanden: S ist serialisierbar
     b. Sonst: S ist nicht serialisierbar

Serialisierungsgraphen: Beispiele

- Serieller Schedule S_d
  - $S_d = \langle r_1(X), w_1(X), r_1(Y), w_1(Y), r_2(X), w_2(X) \rangle$

- Serieller Schedule S_e
  - $S_e = \langle r_2(X), w_2(X), r_1(X), w_1(X), r_1(Y), w_1(Y) \rangle$

- Beide Schedules serialisierbar

S_d	T_1	T_2
1	read_item(X)	
2	$X := X - N$	
3	write_item(X)	
4	read_item(Y)	
5	$Y := Y + N$	
6	write_item(Y)	
7		read_item(X)
8		$X := X + M$
9		write_item(X)

S_e	T_1	T_2
1		read_item(X)
2		$X := X + M$
3		write_item(X)
4	read_item(X)	
5	$X := X - N$	
6	write_item(X)	
7	read_item(Y)	
8	$Y := Y + N$	
9	write_item(Y)	

Serialisierungsgraphen: Beispiele

- Schedule S_a
  - $S_a = \langle r_1(X), r_2(X), w_1(X), r_1(Y), w_2(X), w_1(Y) \rangle$

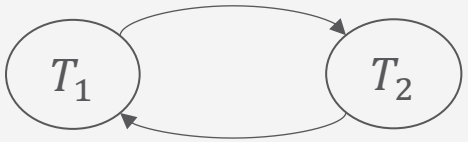

- Schedule S_c
  - $S_c = \langle r_1(X), w_1(X), r_2(X), w_2(X), r_1(Y), w_1(Y) \rangle$

- S_a nicht serialisierbar (Zyklus), S_c ja

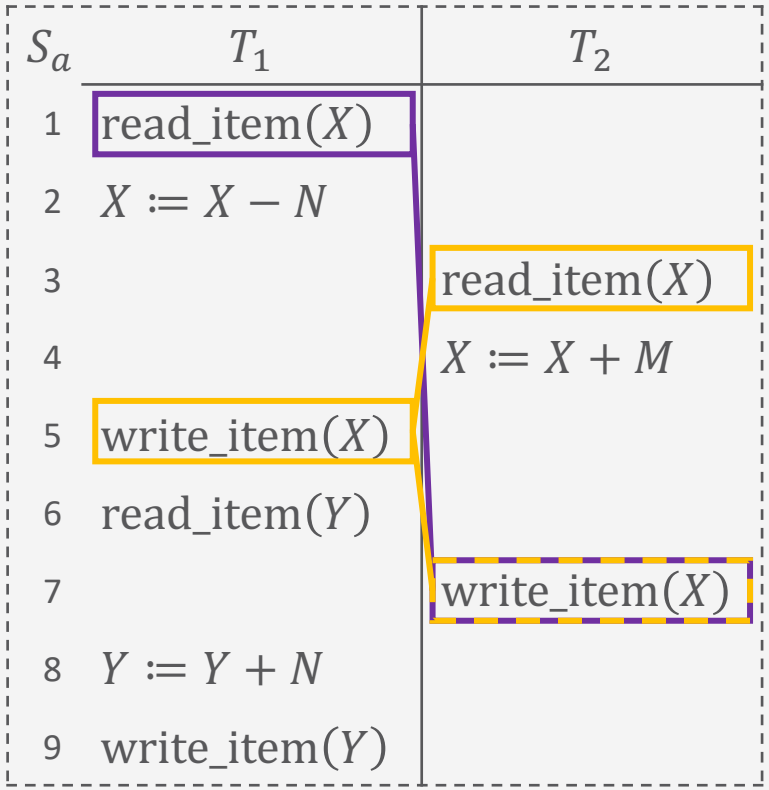

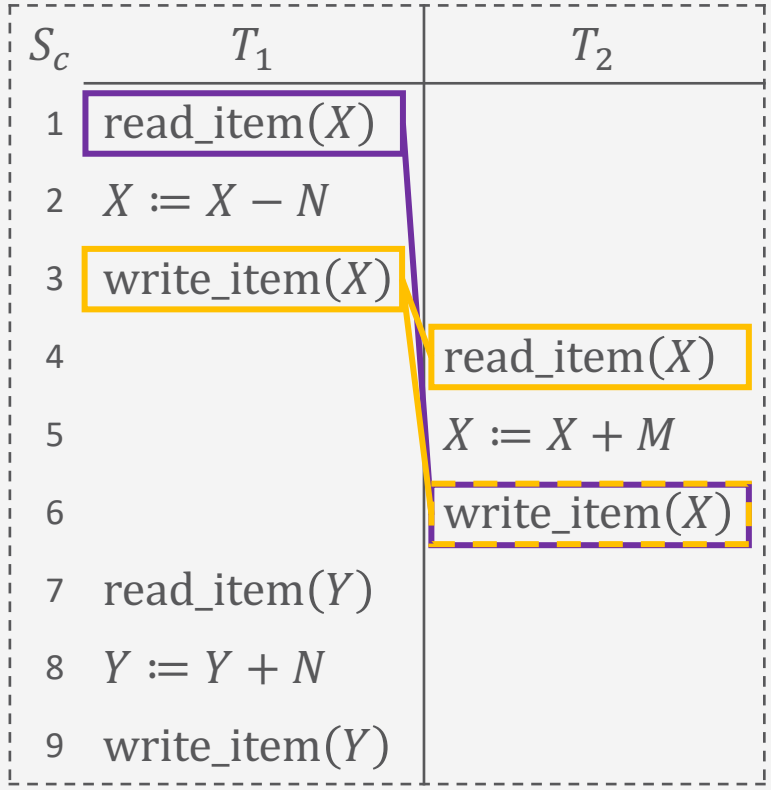

Serialisierungsgraphen: Beispiele

- Transaktionen T_1, T_2, T_3

T_1	T_2	T_3
read_item(X)	read_item(Z)	read_item(Y)
write_item(X)	read_item(Y)	read_item(Z)
read_item(Y)	write_item(Y)	write_item(Y)
write_item(Y)	read_item(X)	write_item(Z)
	write_item(X)	

- Schedule S_g rechts
  - Serialisierungsgraph:
    - Zyklen im Graph

  → Nicht serialisierbar (kein äquivalenter serieller Schedule)

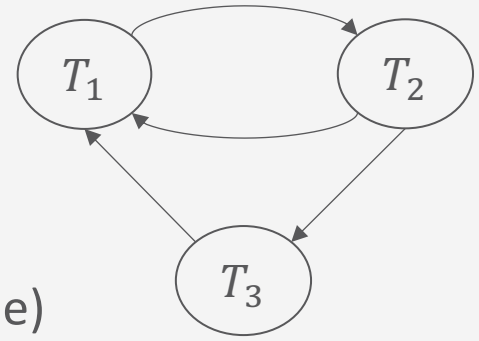

Transaktionen

S_g	T_1	T_2	T_3
1		read_item(Z)	
2		read_item(Y)	
3		write_item(Y)	
4			read_item(Y)
5			read_item(Z)
6	read_item(X)		
7	write_item(X)		
8			write_item(Y)
9			write_item(Z)
10		read_item(X)	
11	read_item(Y)		
12	write_item(Y)		
13		write_item(X)	

In Tabelle keine weiteren Konflikte hervorgehoben, die zu einer schon bestehenden Kante gehören.

Serialisierungsgraphen: Beispiele

- Transaktionen T_1, T_2, T_3

T_1	T_2	T_3
read_item(X)	read_item(Z)	read_item(Y)
write_item(X)	read_item(Y)	read_item(Z)
read_item(Y)	write_item(Y)	write_item(Y)
write_item(Y)	read_item(X)	write_item(Z)
	write_item(X)	

- Schedule S_h rechts
  - Serialisierungsgraph:
    - Graph zyklenfrei

    → Serialisierbar

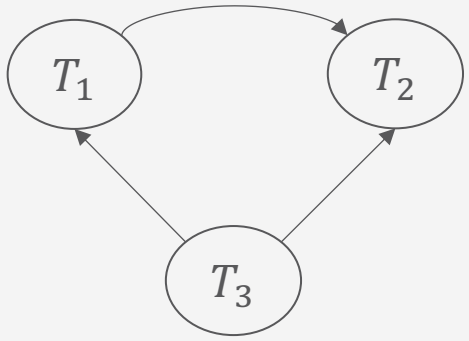

Transaktionen

S_h	T_1	T_2	T_3
1			read_item(Y)
2			read_item(Z)
3	read_item(X)		
4	write_item(X)		
5			write_item(Y)
6			write_item(Z)
7		read_item(Z)	
8	read_item(Y)		
9	write_item(Y)		
10		read_item(Y)	
11		write_item(Y)	
12		read_item(X)	
13		write_item(X)	

In Tabelle keine weiteren Konflikte hervorgehoben, die zu einer schon bestehenden Kante gehören.

Äquivalente serielle Schedules

- Gegeben ein zyklenfreier Serialisierungsgraphen SG für ein Schedule S
- Äquivalenter serieller Schedule durch topologische Sortierung von SG
  - *Topologische Sortierung*: Sequenz aller Knoten im Graph, wobei Elternknoten vor Kindknoten in der Sequenz erscheinen müssen
  - Beispiel vorherige Folie
    - Serialisierungsgraph:
      - Graph zyklenfrei

      → Serialisierbar

      → Äquivalenter serieller Schedule:

      $T_3|T_1|T_2$

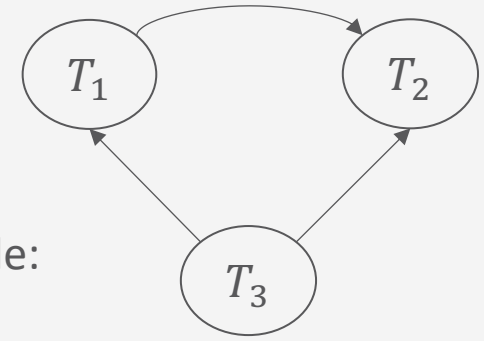

Transaktionen

S_h	T_1	T_2	T_3
1			read_item(Y)
2			read_item(Z)
3	read_item(X)		
4	write_item(X)		
5			write_item(Y)
6			write_item(Z)
7		read_item(Z)	
8	read_item(Y)		
9	write_item(Y)		
10		read_item(Y)	
11		write_item(Y)	
12		read_item(X)	
13		write_item(X)	

Zwischenzusammenfassung

- Schedules: Sequenz von Operationen aus einer Menge von Transaktionen
  - Ursprüngliche Reihenfolge der Operationen aus den Transaktionen beizubehalten
- Serielle Schedules: strikt sequentielle Anordnung der Transaktionen
  - Serielle Schedules sind korrekt
- Konflikte: Wenn Schreiboperationen auf demselben Datenobjekt involviert sind
- Serialisierbarkeit
  - Serialisierbarer Schedule äquivalent zu seriellem Schedule → Korrekter Schedule
- Serialisierungsgraphen
  - Knoten für Transaktionen; Kanten bei konfliktären Operationen
  - Test auf Serialisierbarkeit / Korrektheit: Zyklenfreier Serialisierungsgraph
  - Äquivalenter serieller Schedule mittels topologischer Sortierung

Architektur eines DBMS

- Speicherung
- Anfrageverarbeitung
- Transaktionsmanagement
  - Transaktionsverwaltung
    - Serielle, serialisierbare Schedules
    - Konflikte, Serialisierungsgraph
  - Sperrverwaltung
  - Wiederherstellungsverwaltung

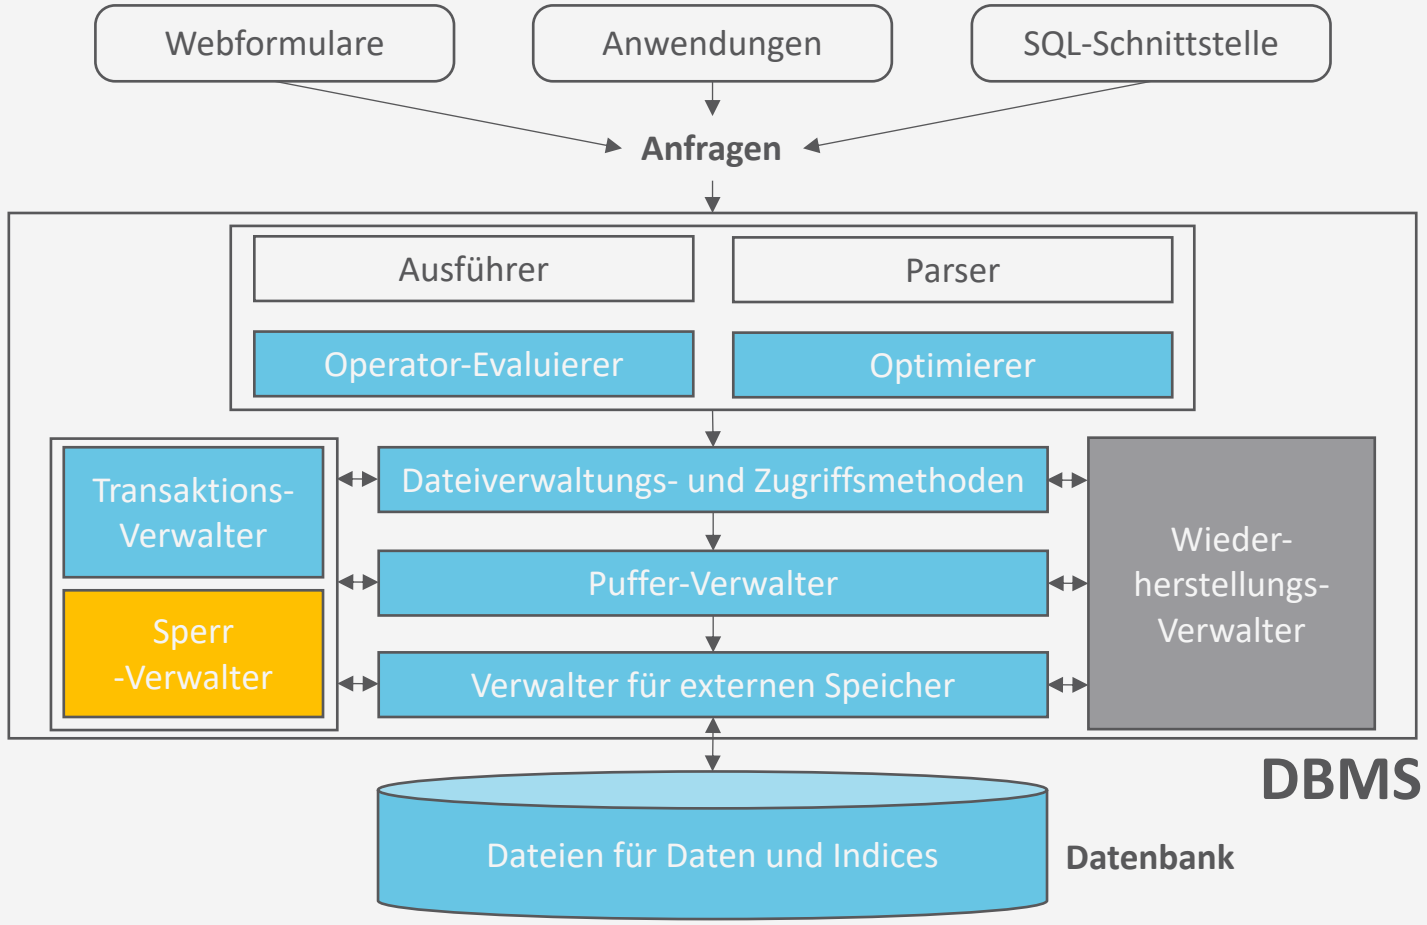

Überblick: 7. Transaktionen

A. Transaktionsverarbeitung
- Fehlersituationen
- Schedules: Korrektheit, Serialisierbarkeit, Äquivalenzen

B. Sperrverwaltung
- Sperren, Sperrprotokolle
- Deadlocks
- Weitere Methoden zur Mehrbenutzerkontrolle

C. Wiederherstellungsverwaltung
- Fehlersituationen
- Logging
- Recovery

Sperr-Verwaltung

- Transaktionen müssen Sperren anfragen für Datenobjekte, auf die sie zugreifen wollen
- Falls eine Sperre nicht zugeteilt wird (z.B. weil eine andere Transaktion T' die Sperre schon hält), wird die anfragende Transaktion T blockiert
  - Sperrverwalter 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)
  - Transaktion, die eine Sperre erhält, wird fortgesetzt
- Sperren regeln die relative Ordnung der Einzeloperationen verschiedener Transaktionen
- Ziel: Automatisierte Generierung von serialisierbaren Schedules

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
- Sperrtabelle: Datenstruktur zur Speicherung der Lock-Information zu jedem Objekt
  - Meist als Hash-Tabelle organisiert, um effizient auf Lock-Informationen zugreifen zu können

Sperren und Sperrprotokolle

Sperrverwaltung

Protokolle und Sperren

- Protokolle mit Sperren:
  - Binäre Sperren (einfach aber restriktiv)
  - Mehrfachmodus- bzw. gemeinsame/exklusive Sperren (praxisrelevant)
  - Zwei-Phasen-Sperrprotokoll (praxisrelevant)
  - Multiversionsprotokolle (Verbesserung der Performanz)
  - Multiversionsprotokolle mit Zeitstempelung (Verbesserung der Performanz)
  - Zertifizierungssperren (Verbesserung der Performanz)
- Protokolle ohne Sperren:
  - Zeitstempelbasierte Transaktionsverarbeitung (praxisrelevant)

Binäre Sperren

- Mit jedem Datenobjekt X ist eine Sperre assoziiert
  - Sperre kann zwei Zustände annehmen: „gesperrt“ oder „entsperrt“
    - 🔒 $Lock(X) = 1$: Objekt ist gesperrt
    - 🔓 $Lock(X) = 0$: Objekt ist entsperrt
  - Operationen:
    - $\text{lock\_item}(X)$: sperrt das Objekt
    - $\text{unlock\_item}(X)$: entsperrt das Objekt
- Wenn eine Transaktion T_1 ein Objekt X gesperrt hat, kann eine Operation T_2 auf X nicht zugreifen (bzw. selber sperren)
  - T_2 muss warten, bis X durch T_1 wieder entsperrt wurde
- Implementierung
  - Eintrag in Sperrtabelle: $(DatenobjektID, LOCKZustand, TransaktionsID)$

Binäre Sperren

- Protokoll mit binären Sperren nach folgenden Regeln für jede Transaktion T:
  1. Vor $\text{read\_item}(X)$ und $\text{write\_item}(X)$: $\text{lock\_item}(X)$
  2. Nach allen $\text{read\_item}(X)$ und $\text{write\_item}(X)$: $\text{unlock\_item}(X)$
  3. Kein $\text{lock\_item}(X)$ durch T, wenn T schon eine Sperre auf X hat
  4. Nur dann $\text{unlock\_item}(X)$, wenn T auch eine Sperre auf X hat

- Problem:
  - Sehr restriktiv
    - Z.B. keine parallelen Leseoperationen möglich

Sperren mit Mehrfachmodus

- Mit jedem Datenobjekt X ist eine Sperre assoziiert mit drei möglichen Zuständen:
  - $Lock(X) = \mathrm{S}$ (Lesesperre)
    - Auf X wird lesend zugegriffen (*shared*) → Als Sperrmodus S bezeichnet
    - Weiterer Lesezugriff problemlos möglich, Schreibzugriff potenziell problematisch
  - $Lock(X) = \mathrm{X}$ (Schreibsperre)
    - Auf X wird schreibend zugegriffen (*exklusive*) → Als Sperrmodus X bezeichnet
    - Auf X kann durch andere Transaktion nicht zugegriffen werden
  - $Lock(X) = 0$ (entsperrt) : Auf X wird nicht zugegriffen
  - Kompatibilitätsmatrix (rechts)
    - Zustand: Gibt es eine Sperre?
    - Anforderung: Was für eine Sperre soll gesetzt werden?
- Operationen: $\mathrm{read\_lock}(X)$, $\mathrm{write\_lock}(X)$ und $\mathrm{unlock}(X)$

Anforderung \ Zustand	0	S	X
S	✓	✓	–
X	✓	–	–

Sperren mit Mehrfachmodus

- Mögliche Implementierung:
  - Einträge in der Sperrtabelle:
    $(DatenobjektID, LOCKZustand, \#Zugriffsoperationen, [TransaktionsID, \ldots])$
  - Idee: Zählen der lesenden Transaktionen ($\#Zugriffsoperationen$)
  - Bei schreibenden Transaktionen ($\text{lock}(X) = \text{X}$) ist $\#Zugriffsoperationen = 1$
- Regeln für Transaktion T:
  1. $\text{read\_lock}(X)$ oder $\text{write\_lock}(X)$ anstoßen vor irgendwelchen $\text{read\_item}(X)$
  2. $\text{write\_lock}(X)$ vor irgendwelchen $\text{write\_item}(X)$
  3. $\text{unlock}(X)$ nach allen $\text{read\_item}(X)$ und $\text{write\_item}(X)$
  4. Kein $\text{read\_lock}(X)$, falls irgendeine Sperre auf X durch T besteht
  5. Kein $\text{write\_lock}(X)$, falls irgendeine Sperre auf X durch T besteht
  6. Nur dann $\text{unlock}(X)$, wenn eine Sperre auf X durch T besteht

Anforderung \ Zustand	0	S	X
S	✓	✓	–
X	✓	–	–

Sperren mit Mehrfachmodus - Sperrenänderung

- Für weniger restriktive Lock-Mechanismen Änderung von Regeln 4 und 5 → Sperrenänderung
- Damit kann eine Schreibsperre zur Lesesperre gelockert oder eine Lesesperre zur Schreibsperre verschärft werden:
  1. $\text{read\_lock}(X)$ oder $\text{write\_lock}(X)$ anstoßen vor irgendwelchen $\text{read\_item}(X)$
  2. $\text{write\_lock}(X)$ vor irgendwelchen $\text{write\_item}(X)$
  3. $\text{unlock}(X)$ nach allen $\text{read\_item}(X)$ oder $\text{write\_item}(X)$
  4. Kein $\text{read\_lock}(X)$, falls eine Lesesperre auf X durch T besteht
  5. Kein $\text{write\_lock}(X)$, falls eine Schreibsperre auf X durch T besteht
  6. Nur dann $\text{unlock}(X)$, wenn eine Sperre auf X durch T besteht

Sperren: Bewertung

- Binäre und Mehrfach-Sperren garantieren selbst noch keine Serialisierbarkeit
- Beispiel: Schedule S
  - Anfangswerte:
    - $X = 20, Y = 30$
  - Resultat von S:
    - $X = 50, Y = 50$
  - Resultat des seriellen Plans $T_1 | T_2$:
    - $X = 50, Y = 80$
  - Resultat des seriellen Plans $T_2 | T_1$:
    - $X = 70, Y = 50$

→ Besseres Protokoll gesucht!

S	T_1	T_2
1	read_lock(Y)	
2	read_item(Y)	
3	unlock(Y)	
4		read_lock(X)
5		read_item(X)
6		unlock(X)
7		write_lock(Y)
8		read_item(Y)
9		$Y := X + Y$
10		write_item(Y)
11		unlock(Y)
12	write_lock(X)	
13	read_item(X)	
14	$X := X + Y$	
15	write_item(X)	
16	unlock(X)	

Zwei-Phasen-Sperrprotokoll (*Two-Phase Locking*, 2PL)

- Idee: Sperroperationen aller Objekte werden vor der ersten **Ent**sperroperation ausgeführt
- Damit ergeben sich zwei Phasen für eine Transaktion T:
  1. Wachstumsphasen:
     - T sammelt immer mehr Sperren auf Objekte
  2. Schrumpfungsphase:
     - T gibt immer mehr Sperren auf Objekte frei
  - Bei Sperrenänderungen:
    - Verschärfungen nur in Wachstumsphase (Lesesperre zu Schreibsperre)
    - Lockerungen nur in Schrumpfungsphase (Schreibsperre zu Lesesperre)

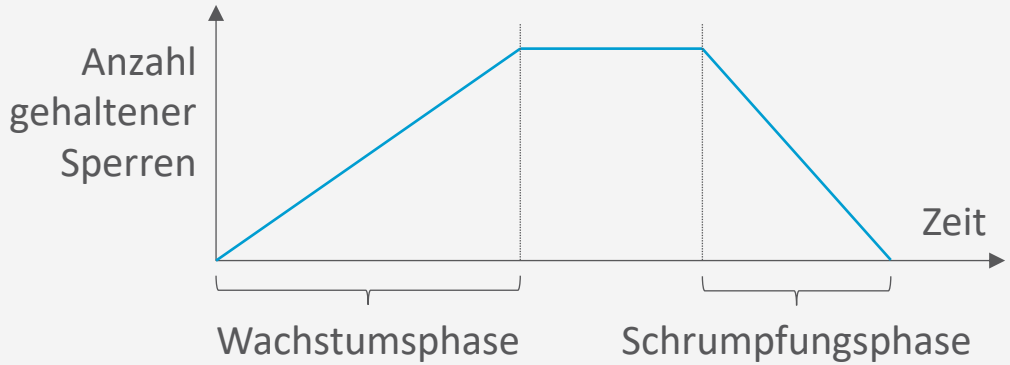

- Schedules, die dem Zwei-Phasen-Sperrprotokoll folgen, sind serialisierbar
  - Schreiboperationen sind durch exklusive Sperren abgesichert

Beispiel

- Nicht Zwei-Phasen-Sperrprotokoll
  - T_1: write_lock(X) nach unlock(Y)
  - T_2: write_lock(Y) nach unlock(X)

T_1	T_2
read_lock(Y)	read_lock(X)
read_item(Y)	read_item(X)
unlock(Y)	unlock(X)
write_lock(X)	write_lock(Y)
read_item(X)	read_item(Y)
$X := X + Y$	$Y := X + Y$
write_item(X)	write_item(Y)
unlock(X)	unlock(Y)

- Zwei-Phasen-Sperrprotokoll
  - Problem: Kann zu Deadlock führen
    - Beide Transaktionen aktiv + warten auf Sperre

T_2' wartet auf unlock(Y) von T_1'
und
T_1' wartet auf unlock(X) von T_2'

T_1'	T_2'
read_lock(Y)	read_lock(X)
read_item(Y)	read_item(X)
write_lock(X)	write_lock(Y)
unlock(Y)	unlock(X)
read_item(X)	read_item(Y)
$X := X + Y$	$Y := X + Y$
write_item(X)	write_item(Y)
unlock(X)	unlock(Y)

Varianten des Zwei-Phasen-Sperrprotokolls

Was sind Beweggründe für die Varianten?

- Konservatives 2PL: Transaktion T sperrt erst alle Objekte, bevor sie mit der Verarbeitung beginnt
  - Keine Deadlocks, aber alle benötigten Sperren müssen vorab bekannt und deklariert sein
- Striktes 2PL: Transaktion T hebt *Schreibsperren* erst auf, wenn T beendet wurde
  - In der Praxis recht verbreitet, garantiert aber nicht Deadlock-Freiheit
- Rigoroses 2PL: T hebt *Lese- und Schreibsperren* erst auf, wenn T beendet wurde
  - Einfacher umzusetzen als die strikte Variante, verhindert aber auch nicht Deadlocks

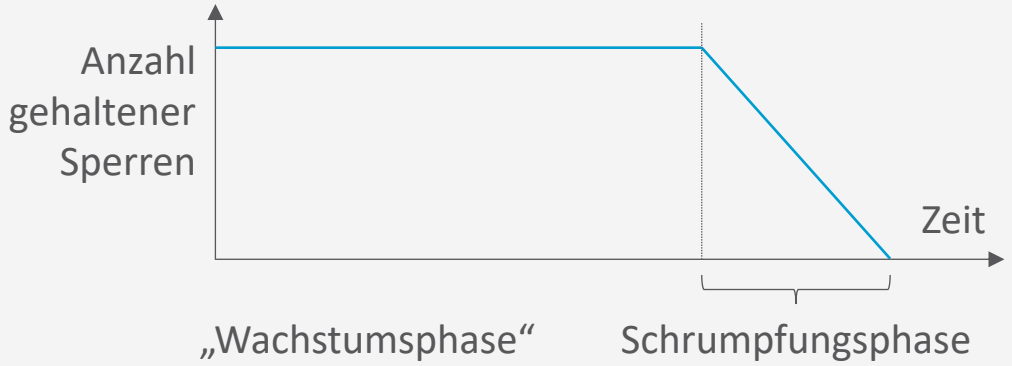

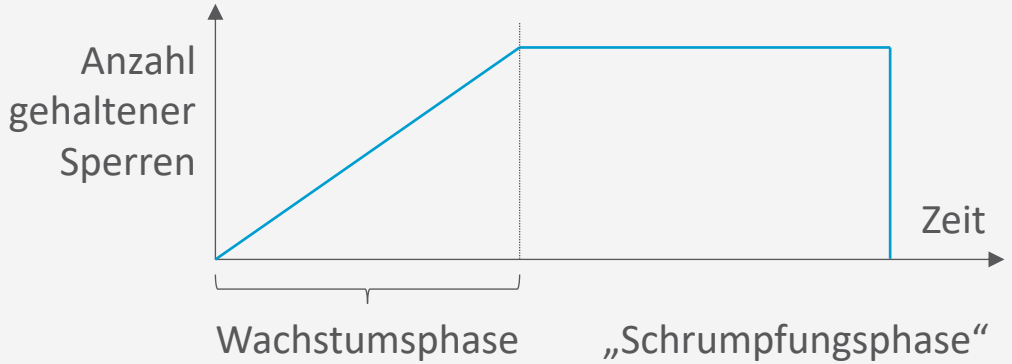

Beispiel

- Transaktionen T_1, T_2

T_1	T_2
read_lock(X)	write_lock(Y)
read_item(X)	read_item(Y)
read_lock(Y)	$Y := Y - 100$
read_item(Y)	write_lock(Z)
read_lock(Z)	read_item(Z)
read_item(Z)	$Z := Z + 100$
$S := X + Y + Z$	write_item(Y)
unlock(X)	write_item(Z)
unlock(Y)	unlock(Y)
unlock(Z)	unlock(Z)

S	T_1	T_2	X	Y	Z
1	begin_transaction		$free$	$free$	$free$
2	read_lock(X)		1: $read$		
3	read_item(X)				
4		begin_transaction			
5		write_lock(Y)		2: $write$	
6		read_item(Y)			
7	read_lock(Y)			1: $wait$	
8		$Y := Y - 100$			
9		write_lock(Z)			2: $write$
10		read_item(Z)			
11		$Z := Z + 100$			
12		write_item(Y)			
13		write_item(Z)			
14		end_transaction			
15		unlock(Y)		1: $read$	
16	read_item(Y)				
17	read_lock(Z)				1: $wait$
18		unlock(Z)			1: $read$
19	read_item(Z)				
20		commit			
21	$S := X + Y + Z$				
22	end_transaction				
23	unlock(X)		$free$		
24	unlock(Y)			$free$	
25	unlock(Z)				$free$
26	commit				

Probleme bei der Verwendung von Sperren

- Deadlocks können bei der Verwendung von Sperren entstehen
- Deadlock (Verklemmung):
  - Transaktion wartet auf ein Objekt, das eine andere Transaktion gesperrt hat – und umgekehrt
  - Kann auch zwischen mehr als zwei Transaktionen auftreten
  - Lösungsansätze folgen, können aber führen zu:
- Starvation (Verhungern):
  - Eine Transaktion wird über längere Zeit nicht abgearbeitet, da andere Transaktionen vorgezogen werden
  - Kompensationsmechanismen folgen

Deadlock

- Deadlock liegt vor, wenn jede Transaktion T einer Menge von zwei oder mehr Transaktionen $\boldsymbol{T}$ auf ein Objekt wartet, das von einer anderen Transaktion $T' \in \boldsymbol{T}, T' \neq T$, gesperrt wurde
- Beispiel:
  - T_1 und T_2 sperren wechselseitig Objekte X und Y
- Behandlung von Deadlocks
  - Vermeidung
  - Erkennung und Auflösung

S	T_1	T_2
1	read_lock(Y)	
2	read_item(Y)	
3		read_lock(X)
4		read_item(X)
5	write_lock(X)	
6		write_lock(Y)

Vermeidung von Deadlocks

- Konservatives 2PL
  - Eine Transaktion muss alle Objekte sperren, bevor sie ausgeführt wird
  - Ansonsten wartet sie, bis die gewünschten Objekte zugreifbar sind
  - Ist in der Praxis jedoch meist nicht umsetzbar
- Transaktionszeitstempel $TS(T)$
  - Eindeutiger Identifikator für eine Transaktion, der als Zeitstempel (*timestamp*) bezeichnet wird
    - In der Regel der Start-Zeitpunkt (Ablesen der internen Systemuhr) von T
  - Wird Transaktion T' vor T'' gestartet, so gilt $TS(T') < TS(T'')$
    - T' ist die ältere, T'' die jüngere Transaktion
  - Darauf basierende Verfahren:
    - Wait/Die
    - Wound/Wait

Vermeidung von Deadlocks

- Transaktion T' versucht Objekt X zu sperren, X durch andere Transaktion T schon gesperrt
  - Ältere Transaktionen werden bevorzugt

- Wait/Die ⏳|🗡️
  - Wenn $TS(T') < TS(T)$: T' ist älter als T und wartet
  - Wenn $TS(T') \geq TS(T)$: T' ist jünger als T und stirbt
    - T' bricht sich selbst ab (abort)
    - T' startet später mit gleichem Zeitstempel $TS(T')$ wieder (wird also älter sein, weniger häufig sterben)
  - T behält in beiden Fällen seine Sperre

- Wound/Wait: 🗡️|⏳
  - Wenn $TS(T') < TS(T)$: T' ist älter als T und verwundet/tötet T
    - T wird abgebrochen (abort)
    - T startet später mit dem gleichen Zeitstempel $TS(T)$ wieder (wird also älter sein, weniger häufig verwundet)
  - Wenn $TS(T') \geq TS(T)$: T' ist jünger als T und wartet
  - T behält seine Sperre nur, wenn T älter ist

Vermeidung von Deadlocks

- Weitere Ansätze:
  - No Waiting (NW)
    - Wenn die Transaktion keine Sperre bekommt, wird sie sofort abgebrochen
    - Viele unnötige Abbrüche und Neustarts
  - Cautious Waiting (CW)
    - T' versucht Sperre zu bekommen, T hat sie
      - Wenn T nicht blockiert ist, wird T' blockiert und wartet auf T
      - Sonst (T ist blockiert): T' wird abgebrochen (könnte länger dauern)
- Problem aller bisherigen Ansätze:
  - Sind zwar Deadlock frei
  - Erzeugen aber u.U. unnötige Abbrüche und Neustarts von Transaktionen, die nie einen Deadlock verursacht hätten → schlechtere Performanz

Erkennung von Deadlocks

- Optimistisches Verfahren: statt Vermeidung nachträgliche Erkennung und Auflösung
  - Gut, wenn wenig Deadlocks zu erwarten sind
- Grundideen:
  - (Physische) Zeitbeschränkungen
    - Wartet eine Transaktion T_i länger als eine Zeitbeschränkung t vorgibt:
      - Dann ist die Annahme: Transaktion ist in Deadlock-Situation
      - T_i wird abgebrochen
    - Vorteil: kann einfach geprüft werden
    - Nachteil: evtl. unnötige Transaktionsabbrüche
      - Schwierig Zeitbeschränkung richtig zu wählen:
        zu kurz → zu viele möglicherweise vermeidbare Abbrüche; zu lang → zu lange warten
  - (Logischer) Wartegraph
    - Nächste Folie…

Erkennung von Deadlocks: Wartegraph

- Wartegraph: Gerichteter Graph
  - Enthält für jede aktive Transaktion T_i einen Knoten
  - Wenn T_i auf eine Sperre von T_j wartet:
    - Füge Kante $(T_i \longrightarrow T_j)$ in den Graphen ein (Kante bei Freigabe löschen)
  - Weist der Wartegraph Zyklen auf, so liegt ein Deadlock vor
- Beispiel
  - T_1, T_2 starten (aktiv) → jeweils Knoten einfügen
  - Zeile 1 + 3: Objekte nicht gesperrt, alles ok
  - Zeile 5: T_1 fordert Sperre für X an
    - X gesperrt von T_2: Kante $(T_1 \longrightarrow T_2)$ → Kein Zyklus, alles ok
  - Zeile 6: T_2 fordert Sperre für Y an
    - Y gesperrt von T_1: Kante $(T_2 \longrightarrow T_1)$ → Zyklus

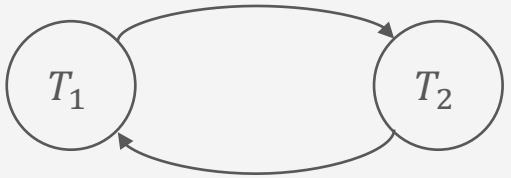

S	T_1	T_2
1	read_lock(Y)	
2	read_item(Y)	
3		read_lock(X)
4		read_item(X)
5	write_lock(X)	
6		write_lock(Y)

Behandlung von Deadlock - Opferauswahl

- Deadlock erkannt:
  - Transaktion T_i bestimmen, die abgebrochen werden soll, um Zyklus aufzulösen
- Folgende Heuristiken denkbar:
  - Wähle möglichst keine Transaktion, die bereits lange läuft
    - Bricht vor allem junge Transaktionen ab
    - Idee: Alte Transaktionen haben eine Chance endlich durchzulaufen
  - Wähle möglichst keine Transaktion, die bereits viele Aktualisierungen der DB durchgeführt hat
    - Idee: Nicht die ganze Arbeit verwerfen und alle Änderungen wieder rückgängig machen müssen
- Problem bei Wartegraphen-Ansatz:
  - Wann soll auf Existenz von Zyklen geprüft werden?
    - Zu oft → Kostet Zeit
    - Zu selten → Deadlocks können lange bestehen

Starvation

- Starvation: Transaktion wird über längere Zeit nicht abgearbeitet, da andere Transaktionen vorgezogen werden
  - Als Folge der Deadlock-Vermeidung oder -auflösung
- Kompensationsmechanismen:
  - First-Come-First-Served
    - Abarbeitung in Reihenfolge
  - Prioritäten (vergeben/anpassen)
    - Durch Transaktionsverwaltung abgebrochene Transaktion erhält höhere Priorität, wird deshalb bei der Neuausführung mit geringerer Wahrscheinlichkeit als Opfer gewählt
- Wait/Die und Wound/Wait vermeiden Verhungern
  - Ältere Transaktionen werden bevorzugt
  - Abgebrochene Transaktionen behalten ihre ID → Irgendwann ist jede Transaktion alt genug

Weitere Verfahren zur Mehrbenutzerkontrolle

Sperrverwaltung

Verfahren mit Zeitstempelung

- Zeitstempel $TS(T)$ der Transaktion T
  - Wie vorher definiert: Eindeutiger Identifikator, der vom DBMS generiert wird, um eine Transaktion zu identifizieren
    - In der Regel der Start-Zeitpunkt (Ablesen der internen Systemuhr) von T
- Zeitstempelbasierte Ansätze verwenden *keine Sperren* → *keine Deadlocks*
- Idee: Algorithmus stellt sicher, dass der Zugriff von konfliktären Operatoren nicht die Reihenfolge (mindestens) eines äquivalenten seriellen Schedules verletzt
  - $TS_r(X)$: Lesezeitstempel von X
    - Größter (aktuellster) $TS(T)$ aller Transaktionen, die X erfolgreich gelesen haben
  - $TS_w(X)$: Schreibzeitstempel von X
    - $TS(T)$ der Transaktion T, die X erfolgreich geschrieben hat

Basis-Zeitstempelordnung

- T möchte write_item(X) durchführen
  - Wenn $TS_r(X) > TS(T)$ oder $TS_w(X) > TS(T)$:

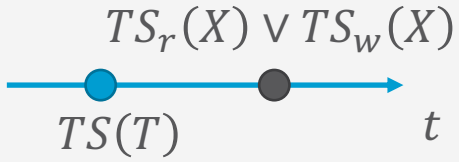

    - Jüngere Transaktionen haben X schon gelesen oder geschrieben
    - Operation wird abgewiesen, T wird abgebrochen („zu spät“)
      - T neu starten mit neuem Zeitstempel
  - Sonst:

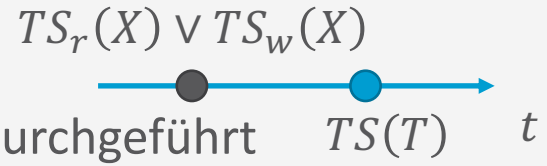

    - write_item(X) wird durchgeführt
    - $TS_w(X) \coloneqq TS(T)$

- T möchte read_item(X) durchführen:
  - Wenn $TS_w(X) > TS(T)$:

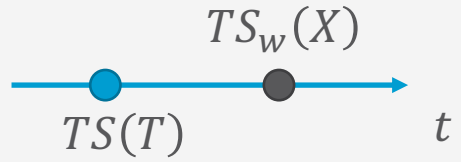

    - Jüngere Transaktionen haben X schon geschrieben
    - Operation wird abgewiesen, T wird abgebrochen („zu spät“)
      - T neu starten mit neuem Zeitstempel
  - Sonst:

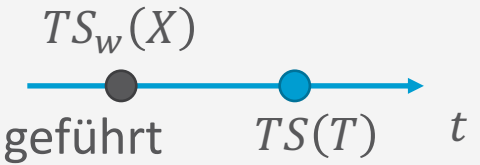

    - read_item(X) wird durchgeführt
    - $TS_r(X) \coloneqq \max\{TS_r(X), TS(T)\}$

Zeitstempelung: Beispiel

- Schedule: $r_8(X), r_6(X), r_9(X), w_8(X), w_{11}(X), r_{10}(X)$
  - Notation: Operation $p_i(X)$ der Transaktion T_i mit Zeitstempel $i = TS(T)$
- Initial: $TS_r(X) := 0, TS_w(X) := 0$

Anfrage	Antwort	Änderungen
$r_8(X)$	OK	$TS_r(X) := 8$
$r_6(X)$	OK	$TS_r(X) := 8$
$r_9(X)$	OK	$TS_r(X) := 9$
$w_8(X)$	abgelehnt	a_8
$w_{11}(X)$	OK	$TS_w(X) := 11$
$r_{10}(X)$	abgelehnt	a_{10}

Multiversionsprotokolle

- Multiversionsprotokolle verwalten unterschiedliche Versionen eines Datenobjekts, also auch die mit alten Werten
- Bei Zugriff wird die jeweils passende Version des Datenobjekts an die Transaktion geliefert
- Umsetzungen mit
  - Zeitstempelordnung
  - Zertifizierungssperren

Multiversionsprotokoll mit Zeitstempelordnung

- Mehrere Versionen $X_1, \ldots, X_k$ von einem Datenobjekt X
- Für jedes X_i werden Zeitstempel gespeichert:
  - $TS_r(X_i)$: der größte (aktuellste) aller Zeitstempel von Transaktionen, die diese Version gelesen haben
  - $TS_w(X_i)$: Zeitstempel der Transaktion T, die den Wert dieser Version geschrieben hat

Multiversionsprotokoll mit Zeitstempelordnung

- Zwei Regeln für die Serialisierung:

1. Schreiben:
   - Wenn Transaktion T eine write_item(X)-Operation ausführen will und
     - Für die Version i von X mit dem größten $TS_w(X_i)$ aller Versionen von X gilt, dass
       - $TS_w(X_i) < TS(T)$ und (ältere Transaktion als T hat X_i geschrieben)
       - $TS_r(X_i) > TS(T)$, (jüngere Transaktion als T hat X_i gelesen)

     dann wird T abgebrochen / zurückgesetzt
   - Sonst
     - Erstelle eine neue Version X_{k+1} von X
     - Setze $TS_w(X_{k+1})$ und $TS_r(X_{k+1})$ auf $TS(T)$

Multiversionsprotokoll mit Zeitstempelordnung

- Zwei Regeln für die Serialisierung

2. Lesen:
   - Wenn Transaktion T eine $\text{read\_item}(X)$-Operation ausführen will,
     - Gibt es eine Version i von X mit dem größten $TS_w(X_i)$ aller Versionen von X, für die gilt
       - $TS_w(X_i) < TS(T)$,

     dann wird T der Wert von X_i geliefert und $TS_r(X_i)$ wird auf den größeren Wert von $TS(T)$ und $TS_r(X_i)$ gesetzt.

     → $\text{read\_item}(X)$-Operationen können immer ausgeführt werden

Multiversionsprotokoll mit Zertifizierungssperren

- Standardfall: Wenn Transaktion T' eine Schreibsperre auf Objekt X hat, kann kein andere Transaktion T auf X zugreifen
- Beim Multiversionsprotokoll mit Zertifizierungssperren ist es T gestattet, X zu lesen, während eine Transaktion T' eine Schreibsperre auf X hält
  - Für jedes Objekt X sind zwei Versionen X', X'' zugelassen:
    - Version X' muss dabei immer von einer bestätigten Transaktion geschrieben worden sein
    - Version X'' wird erzeugt, wenn eine Transaktion T' eine Schreibsperre auf X anfordert
- Andere Transaktionen können die bestätigte Version von X, nämlich X', weiterhin lesen, während T' eine Schreibsperre erhält und mit X'' arbeitet
- Wenn T' bereit ist ein COMMIT durchzuführen, muss T' Zertifizierungssperren für *jedes* Objekt X anfordern, für das es eine *Schreibsperre* hat
  - Evtl. warten, bis andere Transaktionen ihre Lesesperren auf X freigeben

Multiversionsprotokoll mit Zertifizierungssperren

- Erweitertes Sperrkonzept mit Mehrfachmodus-Sperren
  - Statt Zeitstempelordnung
- Einführung eines neuen Zustands von Sperren, damit vier:
  - Lesegesperrt (S)
  - Schreibgesperrt (X)
  - Zertifizierungsgesperrt (C)
  - Entsperrt (0)
- Idee: Auch bei Lesesperre noch Schreiben und bei Schreibsperre noch Lesen zu erlauben, wenn dies geordnet geschieht
  - Kompatibilitätsmatrix rechts

Anforderung \ Zustand	0	S	X	C
S	✓	✓	✓, aber…	–
X	✓	✓, aber…	–	–
C	✓	–	–	–

Optimistische Verfahren

- Bisherige Verfahren: pessimistisch, Kontrolle vor Ausführung
- Optimistische Verfahren: während der Ausführung keine Kontrolle
  1. Lesephase
     - Bestätigte Datenobjekte der DB lesen
     - Aktualisierungen werden nur in lokale Kopien geschrieben
  2. Validierungsphase
     - Kontrollmechanismen werden angestoßen, die Serialisierbarkeit/Korrektheit (nachträglich) prüfen
  3. Schreibphase
     - Wenn Validierungsphase erfolgreich: Aktualisierungen werden auf der DB ausgeführt
     - Sonst: Transaktion wird abgebrochen und neu angestoßen
- Lohnt sich, wenn es nur selten Konflikte gibt
  - Z.B. bei großer DB → verteiltes Arbeiten (an unterschiedlichen Stellen der DB)

Granularität des Sperrens

- Datenobjekt kann alles sein, von Datenbank bis hin zu Datensatz (Zeile einer Tabelle)
- Granularität des Sperrens unterliegt Abwägung
- Sperren mit multipler Granularität

Sperren mit multipler Granularität

- Granularität von Sperren für jede Transaktion entscheiden (abhängig von Charakteristik)
  - Zeilenweise Sperre z.B. für

```
select *                    Q1
from Kunden
where Kunden_ID = 42
```

  - und eine Tabellen-Sperre für

```
select *                    Q2
from Kunden
```

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

Vorhabens-Sperren

- DBs setzen Vorhabens-Sperren (*intention locks*) für verschiedene Sperrgranularitäten ein
  - Sperrmodus Intention Share (IS)
  - Sperrmodus Intention Exclusive (IX)
  - Kompatabilitätsmatrix rechts
- Eine Sperre I_ auf einer gröberen Ebene bedeutet, dass es eine Sperre _ auf einer niederen Ebene gibt

Anforderung \ Zustand	0	S	X	IS	IX
S	✓	✓	–	✓	–
X	✓	–	–	–	–
IS	✓	✓	–	✓	✓
IX	✓	–	–	✓	✓

Vorhabens-Sperren

- Protokoll für Sperren auf mehreren Ebenen:
  1. Eine Transaktion kann jede Ebene g in Modus _ $\in \{S, X\}$ sperren
  2. Bevor Ebene g in Modus _ gesperrt werden kann, muss eine Sperre I_ für alle gröberen Ebenen gewonnen werden
- Beispiel
  - Anfrage Q_1 würde anfordern
    - IS-Sperre für Tabelle Kunden (plus Tablespace + DB)
    - S-Sperre auf dem Tupel mit Kunden_ID=42
  - Anfrage Q_2 würde anfordern
    - (IS-Sperren für Tablespace + DB)
    - S-Sperre für die Tabelle Kunden

Q_1
```
select *
from Kunden
where Kunden_ID = 42
```

Q_2
```
select *
from Kunden
```

Anforderung \ Zustand	0	S	X	IS	IX
S	✓	✓	–	✓	–
X	✓	–	–	–	–
IS	✓	✓	–	✓	✓
IX	✓	–	–	✓	✓

Entdeckung von Konflikten

- Beispiel
  - Momentane Sperren auf Tabelle Kunden oder tiefer
    - Tabelle Kunden: IS von Q_1, S von Q_2
    - Tupel mit Kunden_ID=42: S von Q_1
  - Nehmen wir an, Anfrage Q_3 ist auch noch zu bearbeiten
  - Benötigte Sperren
    - IX-Sperre auf Tabelle Kunden (plus Tablespace + DB)
    - X-Sperre auf dem Tupel mit Kunden_ID=17

    → Kompatibel mit Q_1 (kein Konflikt zwischen IX und IS auf Tabellenebene)

    → Inkompatibel mit Q_2 (S-Sperre auf Tabellenebene von Q_2 steht in Konflikt mit der IX-Sperre bzgl. Q_3)

Q_1
```
select *
from Kunden
where Kunden_ID = 42
```

Q_2
```
select *
from Kunden
```

Q_3
```
update Kunden
set Name= 'John Doe'
where Kunden_ID = 17
```

Anforderung \ Zustand	0	S	X	IS	IX
S	✓	✓	–	✓	–
X	✓	–	–	–	–
IS	✓	✓	–	✓	✓
IX	✓	–	–	✓	✓

Konsistenzgarantien

```
set isolation <mode>;
```

- In einigen Fällen kann man mit einigen kleinen Fehlern im Anfrageergebnis leben
  - Fehler bezüglich einzelner Tupel machen sich in Aggregatfunktionen evtl. kaum bemerkbar
    - Lesen inkonsistenter Werte (inconsistent read Anomalie)
- Ab SQL-92 kann man Isolations-Modi spezifizieren:
  SET ISOLATION <MODE>
  - Verfügbare Modi: READ UNCOMMITTED, READ COMMITTED, REPEATABLE READ, SERIALIZABLE
    - Je weiter durch in der Liste, desto strikter (weniger Fehler)
    - Je weiter durch in der Liste, umso mehr Verwaltungsaufwand, z.B. für Sperren (weniger Durchsatz)

Isolations-Modi

- Read uncommitted (auch: ‘dirty read‘ oder ‘browse‘)
  - Nur Schreibsperren akquiriert (nach 2PL)

Es muss kein read lock erworben werden

S	T_1	T_2 (read uncommitted)	DB: $acct$
1	read_item($acct$)		1200
2	$acct := acct - 100$		1200
3	write_item($acct$)		1200
4		read_item($acct$)	1100
5		$acct := acct - 200$	1100
6	abort		1200
7		~~write_item($acct$)~~	1200

Read uncommited nur für lesende Transaktion

Isolations-Modi

- Read committed (auch ‘cursor stability‘)
  - Lesesperren nur halten, sofern Zeiger auf betreffendes Tupel zeigt
    - Transaktion sieht Daten, wie sie zum Zeitpunkt der aktuellen Operation comitted sind
  - Schreibsperren nach 2PL

S	T_1	T_2 (read committed)
1		$\text{read\_item}(A)$
2	$\text{write\_item}(A)$	
3	$\text{write\_item}(B)$	
4	commit	
5		$\text{read\_item}(B)$
6		$\text{read\_item}(A)$

Nur commited gelesen

Aber:
Unrepeatable Read
nicht ausgeschlossen

Isolations-Modi

- Repeatable read (auch ‘read stability‘)
  - Lesen und Schreiben mittels Lese- und Schreibsperren eines konsistenten Zustandes zu Beginn
    - Transaktion sieht Daten, wie sie zu Beginn der Transaktion (Sperrzuteilung) committed sind
  - Problem: Serialisierung nicht garantiert
    - Anfrage Q_1
      - ```
        select sum(Gehalt)
        from Mitarbeiter
        where AbtNr=5
        ```
    - Anfrage Q_2
      - ```
        insert into Mitarbeiter
            (SVN, NName, VName, Adresse, Gehalt, GebDatum, AbtNr, VorgesSVN)
        values ('90123456G789 ', 'Marini', 'Richard',
            '98 Oak Forest, Katy, TX', 37000, '30.12.1962‘, 5, '67890123D456‘)
        ```
    - Neue Daten erscheinen während der Ausführung von Q_1 → Phantom Read

Isolations-Modi

- Read uncommitted (auch: ‘dirty read‘ oder ‘browse‘)
  - Nur Schreibsperren akquiriert (nach 2PL)
- Read committed (auch ‘cursor stability‘)
  - Lesesperren nur halten, sofern Zeiger auf betreffendes Tupel zeigt
  - Schreibsperren nach 2PL
- Repeatable read (auch ‘read stability‘)
  - Lese- und Schreibsperren nach 2PL
- Serializable
  - Zusätzliche Sperranforderungen $I\_$, um Phantomproblem zu begegnen

Resultierende Konsistenzgarantien

Isolationsmodus	dirty read	non-repeatable read	phantom read
read uncommitted	möglich	möglich	möglich
read committed	–	möglich	möglich
repeatable read	–	–	möglich
serializable	–	–	–

- Einige Implementierungen unterstützen mehr, weniger oder andere Isolationsmodi
  - PostgreSQL: *predicate locks*, z.B. Bedingungen auf Spalten
    - Blockieren nicht, sondern markieren mögliche Abhängigkeiten zwischen Transaktionen, die bei Verdacht auf Anomalie abgebrochen werden
- Nur wenige Anwendungen benötigen (volle) Serialisierbarkeit

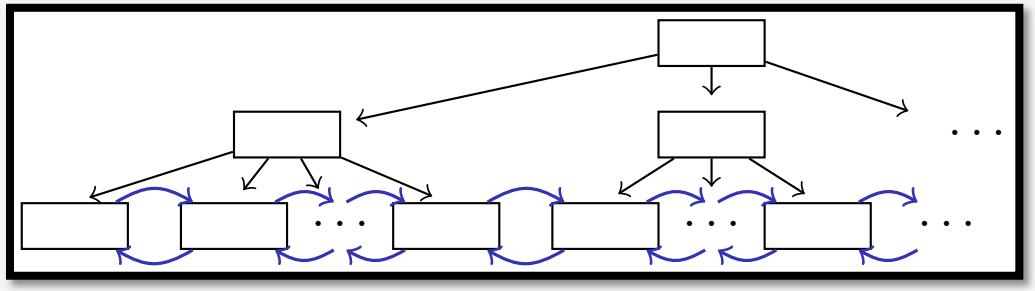

Sperren in Index-Strukturen

Sperrverwaltung

Nebenläufigkeit beim Indexzugriff

- Transaktion T_w führt zu Splitoperation
  - Beispiel: Einfügen eines Eintrags mit Schlüssel 6330
- Angenommen, Aufspaltung ist erfolgt, aber neue Verzeigerung hat noch nicht stattgefunden
- Weiterhin: nebenläufiges Lesen in Transaktion T_r, sucht nach 8050
  - Verzeigerung zeigt auf zweiten Blattknoten mit $5012{,}6330$ mit Zeigern auf dritten Blattknoten mit $8280{,}8404$
- Datensatz wird nicht gefunden
  → Sperren nötig

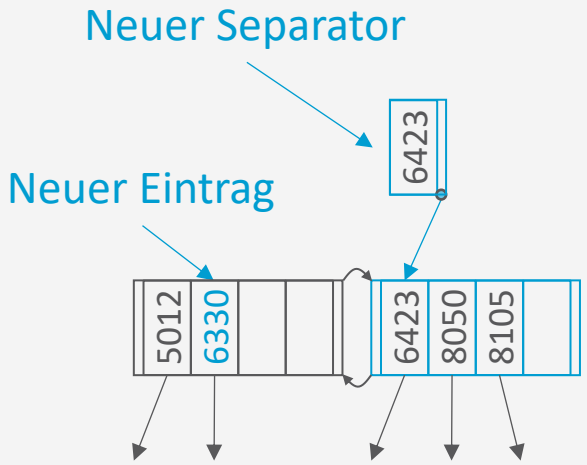

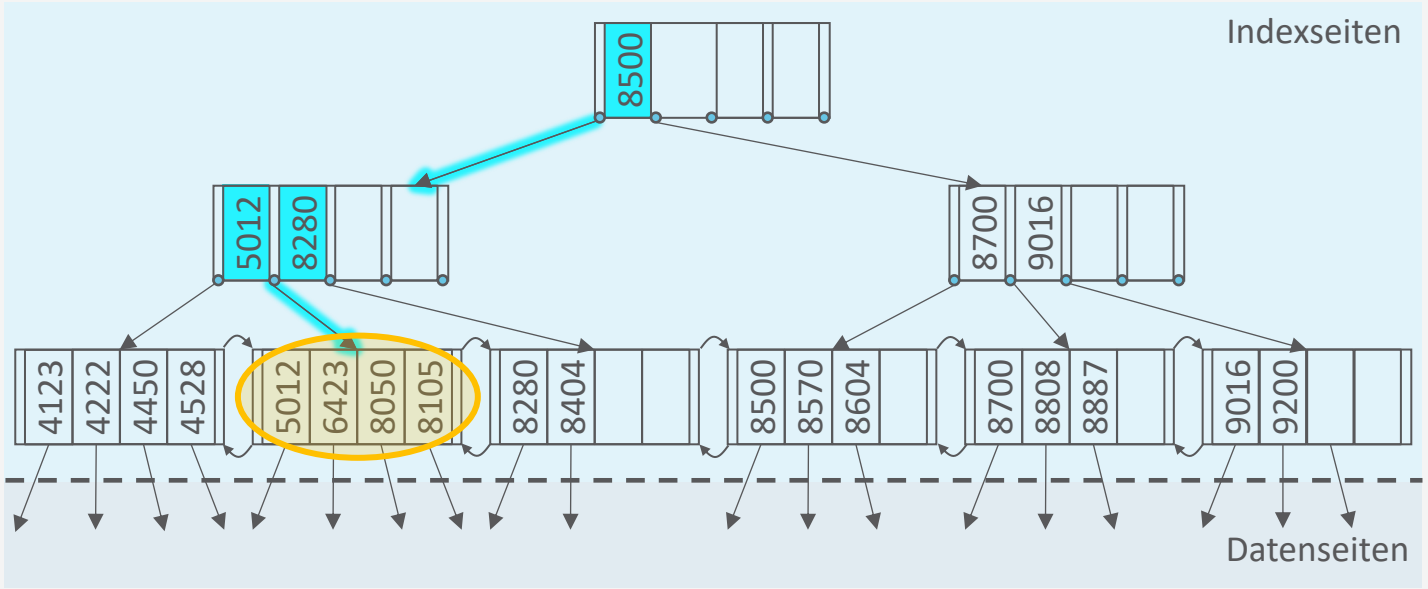

Sperren und B⁺-Baum-Indexe

- B⁺-Baum-Operationen
  - Für die Suche erfolgt ein Top-Down-Zugriff
  - Für Aktualisierungen
    - Suche
    - Daten in Blatt eintragen / löschen
      - Ggf. Aufspaltungen / Merge von Knoten nach oben
- Nach 2PL
  - Müssen Lese/Schreib-Sperren auf dem Weg nach unten akquiriert werden (Konversion provoziert ggf. Deadlocks)
  - Müssen alle Sperren bis zum Ende gehalten werden

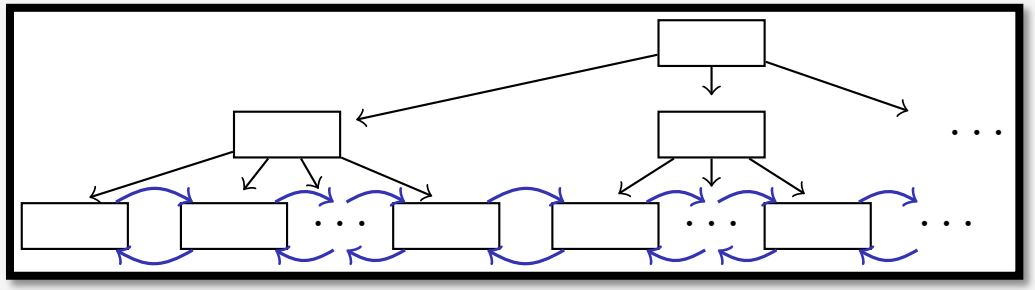

→ Reduziert die Nebenläufigkeit drastisch

- Während des Indexzugriffs einer Transaktion müssen alle anderen Transaktionen warten, um die Sperre für die Wurzel des Index zu erhalten
- Wurzel wird zum Flaschenhals und serialisiert alle (Schreib-)Transaktionen

- 2PL nicht angemessen für B⁺-Bäume

Sperrprotokoll für B⁺-Bäume

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

  → Garantiert Serialisierbarkeit
- Und damit gilt:
  - Alle Transaktionen folgen Top-Down-Zugriffsmuster
  - Keine Transaktion kann dabei andere überholen
  - WTL-Protokoll ist deadlockfrei

Aufspaltungssicherheit

- Wir müssen auf dem Weg nach unten in den B+-Baum Schreibsperren wegen möglicher Aufspaltungen halten
- Allerdings kann man leicht prüfen, ob eine 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
  - Aufweichung des Zwei-Phasen-Sperrprotokolls

Sperrkopplungsprotokoll (Variante 1)

procedure read_lock(key)
    Place S lock on $root$
    $current \leftarrow root$
    while $current$ is not a leaf node **do**
        Find $child$ for key
        Place S lock on $child$
        Release S lock on $current$
        $current \leftarrow child$

procedure write_lock(key)
    Place X lock on $root$
    $current \leftarrow root$
    while $current$ is not a leaf node **do**
        Find $child$ for key
        Place X lock on $child$
        $current \leftarrow child$
        if $current$ is safe **then**
            Release all locks on ancestors of $current$

Erhöhung der Nebenläufigkeit

- Auch mit Sperrkopplung werden eine beträchtliche Anzahl von Sperren für innere Knoten benötigt
  - Mindert Nebenläufigkeit
- 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 während der Baumtraversierung nur Lesesperren akquiriert
    - Schreibsperre dann nur für das betreffende Blatt
  - Wenn die Annahme falsch ist, traversiere Indexbaum erneut unter Verwendung korrekter Schreibsperren

Sperrkopplungsprotokoll (Variante 2)

- Modifikationen nur für Schreibvorgänge

procedure optimistic_write_lock(key)
    Place S lock on $root$
    $current \leftarrow root$
    while $current$ is not a leaf node **do**
        Find $child$ for key
        if $child$ is a leaf **then**
            Place X lock on $child$
        else
            Place S lock on $child$
        Release lock on $current$
        $current \leftarrow child$
    if $current$ is unsafe **then**
        Release all locks and repeat with write_lock

procedure write_lock(key)
    Place X lock on $root$
    $current \leftarrow root$
    while $current$ is not a leaf node **do**
        Find $child$ for key
        Place X lock on $child$
        $current \leftarrow child$
        if $current$ is safe **then**
            Release all locks on ancestors of $current$

Diskussion

- 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 Nachteil von Variante 2 ist, dass im Falle einer Blattaufspaltung Arbeit verloren ist
- Es gibt viele Varianten dieser Sperrprotokolle

Zwischenzusammenfassung

- Binäre Sperren: Datenobjekt ist gesperrt oder nicht; sehr restriktiv
- Zwei-Phasen-Sperrprotokoll
  - Grundlegendes Modell für viele Protokolle, die auf Sperren basieren
  - Keine Sperre mehr anfordern, nachdem eine erste Sperre freigegeben worden ist
- Zeitstempelbasierte Protokolle
- Multiversionsprotokolle: Verschiedene Versionen eines Datenobjekts
  - Umsetzung: zeitstempelbasiert oder mit Sperren
- Optimistische Verfahren: Änderungen nur lokal durchführen; Validierung um Änderungen persistent zu machen
- Granularitäten, Vorhaben-Sperren, Isolationsmodi
- Sperren in Index-Strukturen

Architektur eines DBMS

- Speicherung
- Anfrageverarbeitung
- Transaktionsmanagement
  - Transaktionsverwaltung
  - Sperrverwaltung
    - Sperren, Sperrprotokolle
    - Isolationsmodi
  - Wiederherstellungsverwaltung

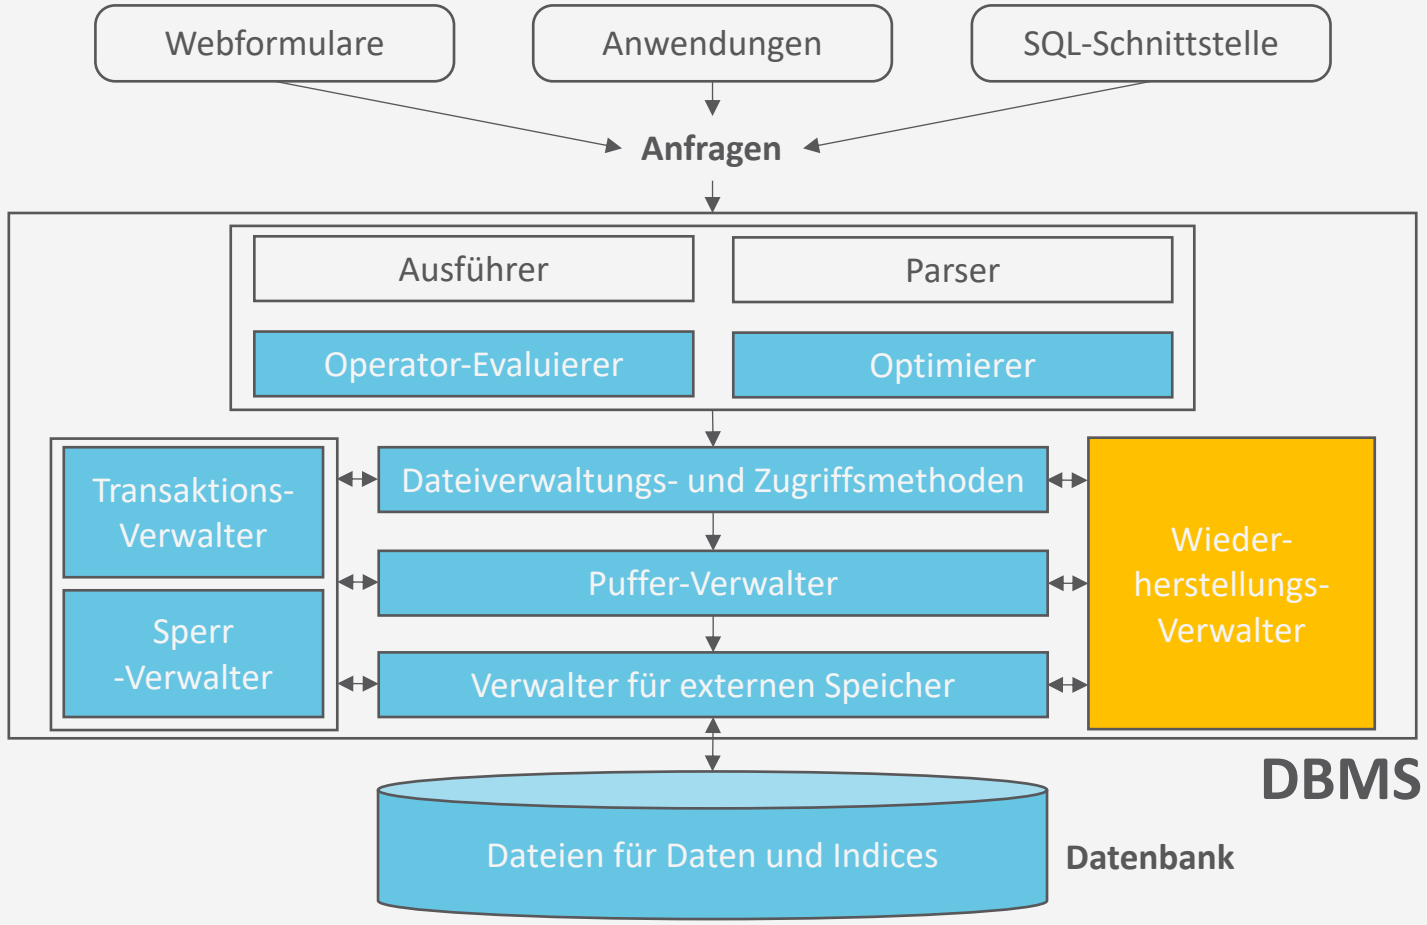

Überblick: 7. Transaktionen

A. Transaktionsverarbeitung
- Fehlersituationen
- Schedules: Korrektheit, Serialisierbarkeit, Äquivalenzen

B. Sperrverwaltung
- Sperren, Sperrprotokolle
- Deadlocks
- Weitere Methoden zur Mehrbenutzerkontrolle

C. Wiederherstellungsverwaltung
- Fehlersituationen
- Logging
- Recovery

TRANSAKTIONSFEHLER (1/3)

- Verschiedene Gründe, weshalb eine DB-Transaktion fehlschlagen kann
- Sieben typische Fehlerfälle
  - Mit in der Literatur uneinheitliche Bezeichnung
  - Meist in Kategorien untergliedert (z.B. System-, Medien-, Transaktionsfehler)

1. Systemabsturz [System- und Medienfehler]
   - Hardware-, Software- oder Netzwerkproblem tritt während der Transaktionsverarbeitung auf
   - Keine adäquate Handhabung durch die Software

   → „Systemabsturz“
2. Transaktionsabsturz [Transaktions-, System- und Medienfehler]
   - Einzelne Operationen schlagen fehl, z.B. aufgrund einer Division durch den Wert Null, aufgrund fehlerhafter Parameterwerte oder aus Programmfehlern
   - Benutzer bricht Transaktion (willkürlich) ab

WEITERE TRANSAKTIONSFEHLER (2/3)

3. Lokale Fehler: [Transaktionsfehler]
   - Während der Transaktionsausführung können Zustände auftreten, die einen Transaktionsabbruch notwendig machen
     - Beispiel: zur Transaktionsausführung benötigte Daten können nicht ermittelt werden
4. Speicherfehler: [Medienfehler]
   - Partieller oder vollständiger Ausfall eines Speichersystems

   → Lese-/Schreibfehler bei der Transaktionsausführung
5. „Katastrophen“: [Medienfehler]
   - Subsumierung verschiedener Ausnahmesituationen, z.B. physischer Verlust eines Datenträgers durch Brand oder Diebstahl
   - Ausnahmesituationen, die sich aus einer fehlerhaften Bedienung des Systems ergeben, wobei z.B. ein Datenträger versehentlich gelöscht wurde

WEITERE TRANSAKTIONSFEHLER (3/3)

6. Transaktionsannullierung: [kein klassischer Fehlerfall]
   - Ein bestimmter DB-Zustand kann dazu führen, dass eine Transaktion „aus inhaltlichen Gründen“ nicht weiter ausgeführt wird, falls z.B. kein genügend hohes Guthaben für eine Abbuchung vorliegt
7. Nebenläufigkeitskontrolle: [kein klassischer Fehlerfall]
   - Komponente zur Überwachung der nebenläufigen Transaktionsausführung veranlasst Unterbrechung (nicht Abbruch) einer Transaktion, um Interferenzen mit anderen Transaktionen zu vermeiden
     - Gestoppte Transaktion wird später wieder gestartet

- Die aufgezählten und weitere Fehlerfälle kann man durch nachfolgend beschriebene, einfache Basis-Mechanismen zu „reparieren“ versuchen

Beispiel: System- oder Medienfehler

- Transaktionen T_1, T_2, T_5 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, T_4 wurden noch nicht beendet
  → Atomarität: Alle Effekte müssen rückgängig gemacht werden (*undo*)

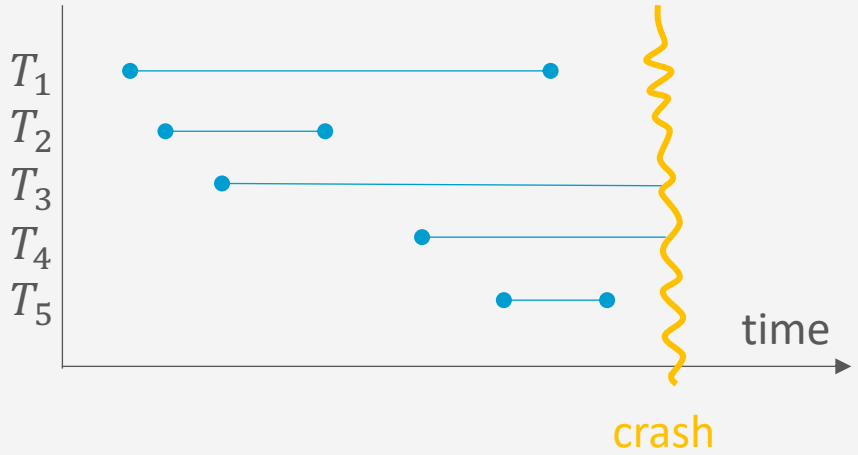

Wiederherstellungsverwaltung: Aufgabe

- Zentrale Komponente der Transaktionsverarbeitung
- Sichert Atomarität und Dauerhaftigkeit
- Koordiniert transaktionsübergreifend die Abarbeitung der DB-Operationen:
  - BEGIN_TRANSACTION und END_TRANSACTION
  - COMMIT und ABORT
- Bietet eigene Primitive für Recovery nach Fehlersituationen:
  - Warm restart
  - Cold restart
- Grundlage zur praktischen Umsetzung dieser Funktionalität sind Aufbau und Verwaltung eines Log-File

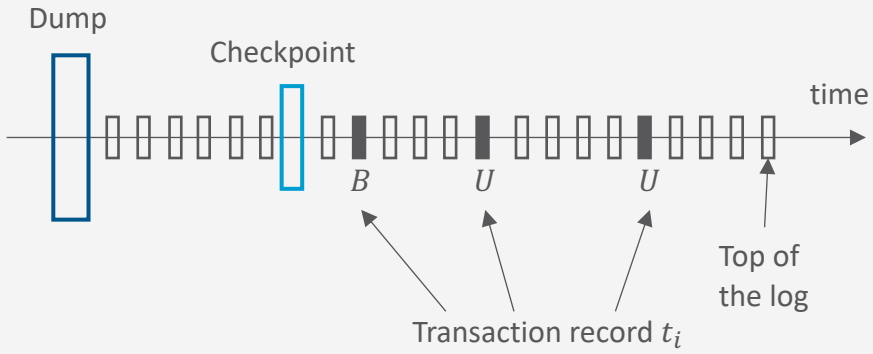

Logging

Wiederherstellungsverwaltung

Organisation des Log-File

- Sequentielle Struktur, die DB-Änderungen chronologisch speichert
  - Liegt auf persistentem Speicher
  - Verwaltung: Wiederherstellungsverwalter
- EOT und Commit fallen zusammen
  - Commit heißt jetzt erstmal nur logisches Ende (vorher EOT), aber nicht zwangsweise persistente Speicherung
    - Der Dateiverwaltung soll überlassen werden, wann was geschrieben wird
    - Transaktionen, die einen Commit Eintrag haben, sollen bei der Wiederherstellung wiederholt werden, wenn nicht im Speicher
- Zwei Typen von Log-Einträgen:
  1. Transaktionsbezogene Einträge:
     - BS / AS: Wert von X vor / nach T (*before / after state*)
     - BEGIN_TRANSACTION : $B(T)$
     - INSERT_ITEM : $I(T, X, AS)$
     - DELETE_ITEM : $D(T, X, BS)$
     - UPDATE_ITEM : $U(T, X, BS, AS)$
     - COMMIT : $C(T)$
     - ABORT : $A(T)$
  2. Systembezogene Einträge:
     - DUMP (vollständige DB-Kopie; eher selten)
     - CHECKPOINT (partielle Aktualisierung; häufig)

Organisation des Log-File

- Transaction Record:
  - Zusammenfassung der INSERT_ITEM-, UPDATE_ITEM- und DELETE_ITEM-Operationen einer einzelnen Transaktion
  - Beginnt mit (B)egin, endet mit (C)ommit oder (A)bort
  - Beispiel:

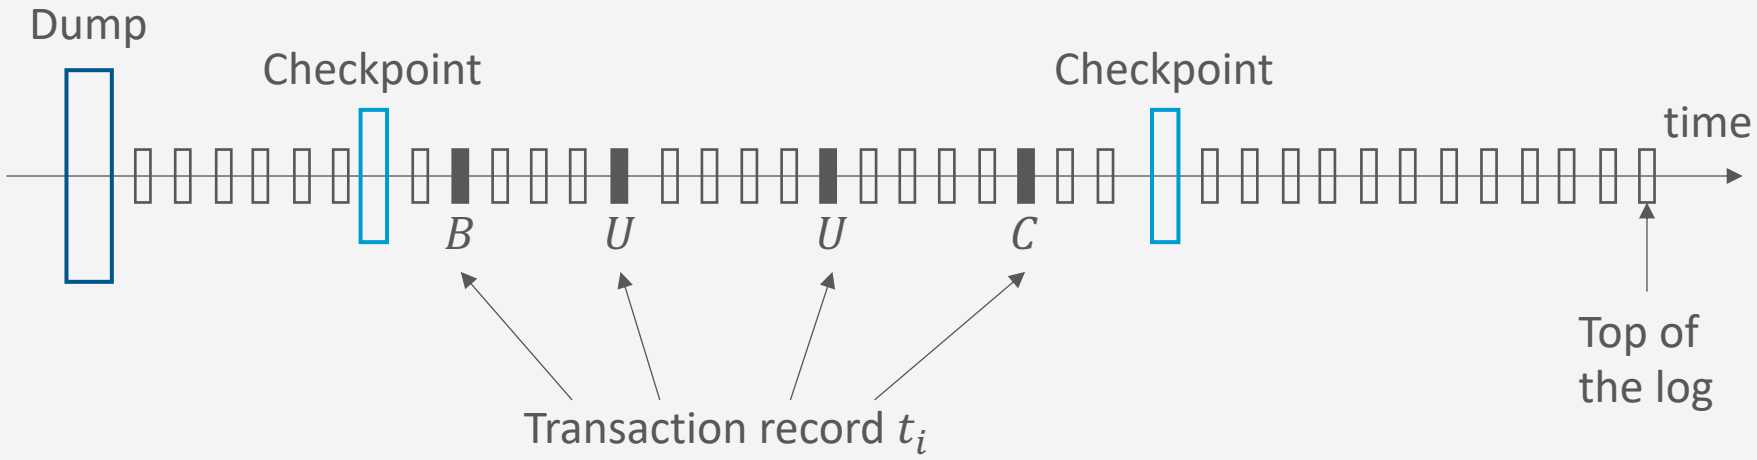

Log-Information COMMIT und Fehler

- COMMIT-Point einer Transaktion T bezeichnet den Zeitpunkt, an dem alle DB-Zugriffsoperationen von T erfolgreich ausgeführt und im Log erfasst wurden
  - Zu diesem Zeitpunkt gilt Transaktion als bestätigt, ihre Wirkung soll persistent in der DB gespeichert werden

  → [COMMIT, T]-Eintrag im Log wird generiert, als Zeichen der logischen, aber noch nicht physischen Beendigung der Transaktion
- Im Fehlerfall
  - Transaktionen T mit BEGIN_TRANSACTION und ohne COMMIT werden – soweit nötig – rückgängig gemacht → UNDO
  - Transaktionen T mit BEGIN_TRANSACTION und mit COMMIT können bzgl. ihrer Änderungsoperationen vollständig wiederholt werden, falls der DB-Zustand noch nicht persistent auf Platte gesichert wurde → REDO

UNDO

- Abbruch einer Transaktion T
- DB muss in Zustand vor Transaktionsausführung gebracht werden
- Log rückwärts bis zum Beginn von T durchsuchen, um Operationen von T zu identifizieren und betroffene Datenobjekte X zurückzusetzen
- Beispiel: UNDO für ein Datenobjekt X
  - UPDATE, DELETE: kopiere den Wert BS in X
  - INSERT: lösche das Objekt X

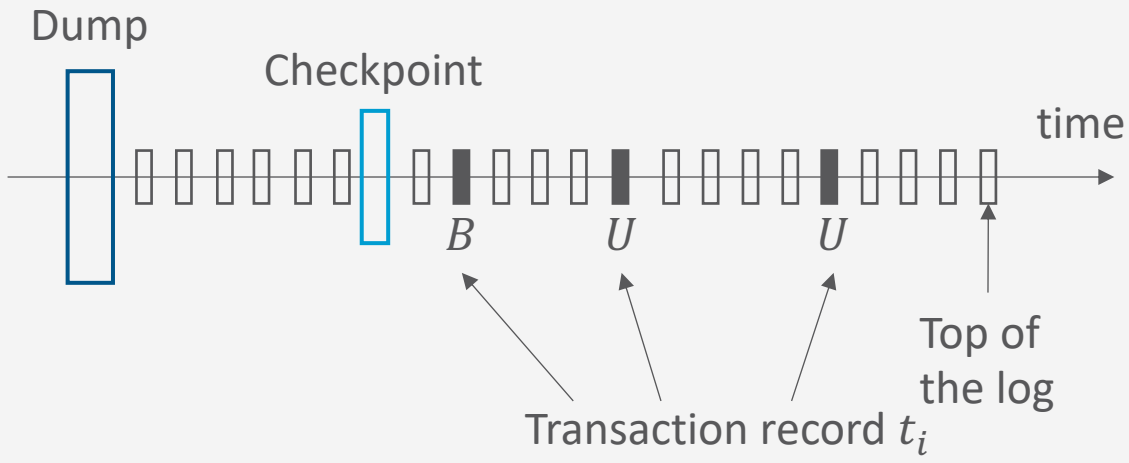

REDO

- Systemfehler in der DB
- Alle bestätigten Transaktionen T, die noch nicht im Hintergrundspeicher sind, müssen wiederholt werden
- Log vom Beginn von T vorwärts durchsucht und alle auftretenden Operationen erneut realisiert
- Beispiel: REDO für ein Datenobjekt X
  - INSERT, UPDATE:
    - Kopiere den Wert AS in X
  - DELETE:
    - Lösche das Objekt X

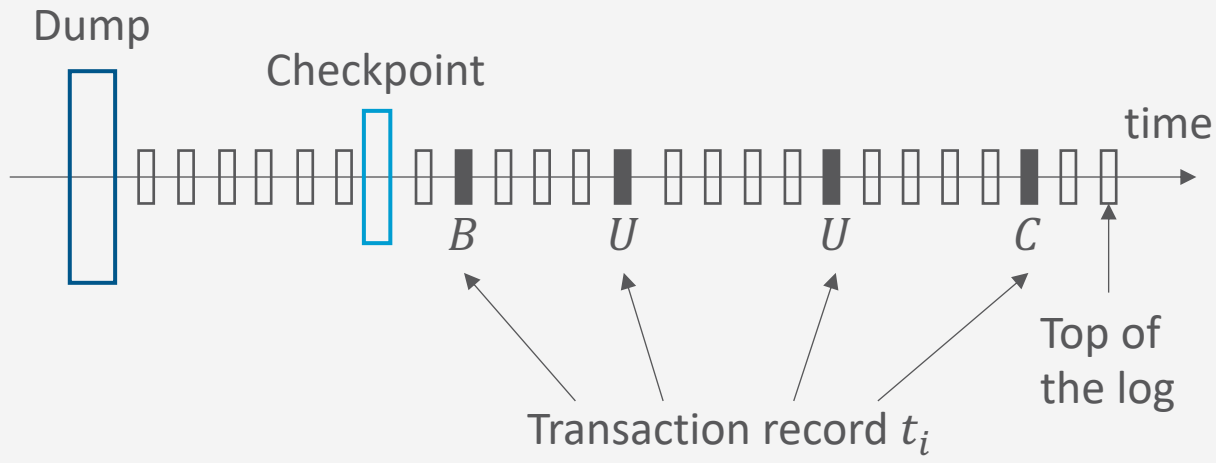

Log-Information: Sicherer Speicher

- Um während des DBMS-Betriebs eine verlässliche Grundlage für UNDO/REDO im Fehlerfall zu liefern, muss das Log – neben der Protokollierung im Hauptspeicher (intern) – auch verlässlich auf Platte (extern) gespeichert werden
  - Nach Systemabsturz können nur solche Log-Einträge bei der Fehlerbehandlung berücksichtigt werden, die bereits auf Platte gespeichert sind – Hauptspeicherinhalte stehen u.U. nicht mehr zur Verfügung
  - Nicht jeder Log-Eintrag wird direkt auch auf Platte gespeichert, um hohe Verzögerungszeiten beim Log-Zugriff zu vermeiden
- Forcewriting
  - Transaktion T kann erst dann ihren COMMIT-Point erreichen, wenn der T zugehörige Log-Inhalt verlässlich auf Platte gespeichert ist

Checkpoints

- Zeichnet alle aktiven Transaktionen auf
- Aktualisiert Hintergrundspeicher partiell aufgrund abgeschlossener Transaktionen
- Wird periodisch angestoßen
  - Währenddessen keine COMMIT-Anweisungen für aktive Transaktionen
- Dienst-Ende: es wird synchron (*force*) ein CHECKPOINT-Eintrag im Log-File generiert wird
  - DB-Veränderungen abgeschlossener Transaktionen dauerhaft in die DB einfügen
- Checkpoint-Eintrag:
  - $CK(T_1, T_2, T_3, \ldots, T_n)$, enthält die Identifier T_i der aktiven Transaktionen
- Bei einem Recovery-Vorgang muss dann nur bis zum letzten Checkpoint-Eintrag zurückgegangen werden und von dort an die aktiven Transaktionen abhandeln (UNDO/REDO)

DUMP

- Vollständige Kopie der DB
  - Backup
- Wird in der Regel erzeugt, wenn DB nicht operativ ist
  - (z.B. einmal pro Nacht)
- Wird im Allgemeinen im persistenten Speicher abgelegt
- Nach Erzeugung des DUMP entsprechender Eintrag im Log-File

Grundregeln für Log-Einträge

- Zwei Grundregeln:
  - Write-Ahead Log (WAL)
    BS-Teile der Log-Einträge müssen im Log-File gespeichert sein, bevor die entsprechende Operation auf der DB ausgeführt wird
  - Commit-Precedence (CP)
    AS-Teile der Log-Einträge müssen im Log-File gespeichert sein, bevor die Transaktion abgeschlossen wird
- Damit führt Verlust des Hauptspeichers nicht zu Datenverlust
- Mögliche Situationen
  - Aktualisierung auf Hintergrundspeicher vor dem COMMIT → Kein REDO bei Recovery nötig
  - COMMIT vor Aktualisierung auf Hintergrundspeicher → Kein UNDO bei Recovery nötig

Beispiele

Was geschieht bei Abbrüchen?

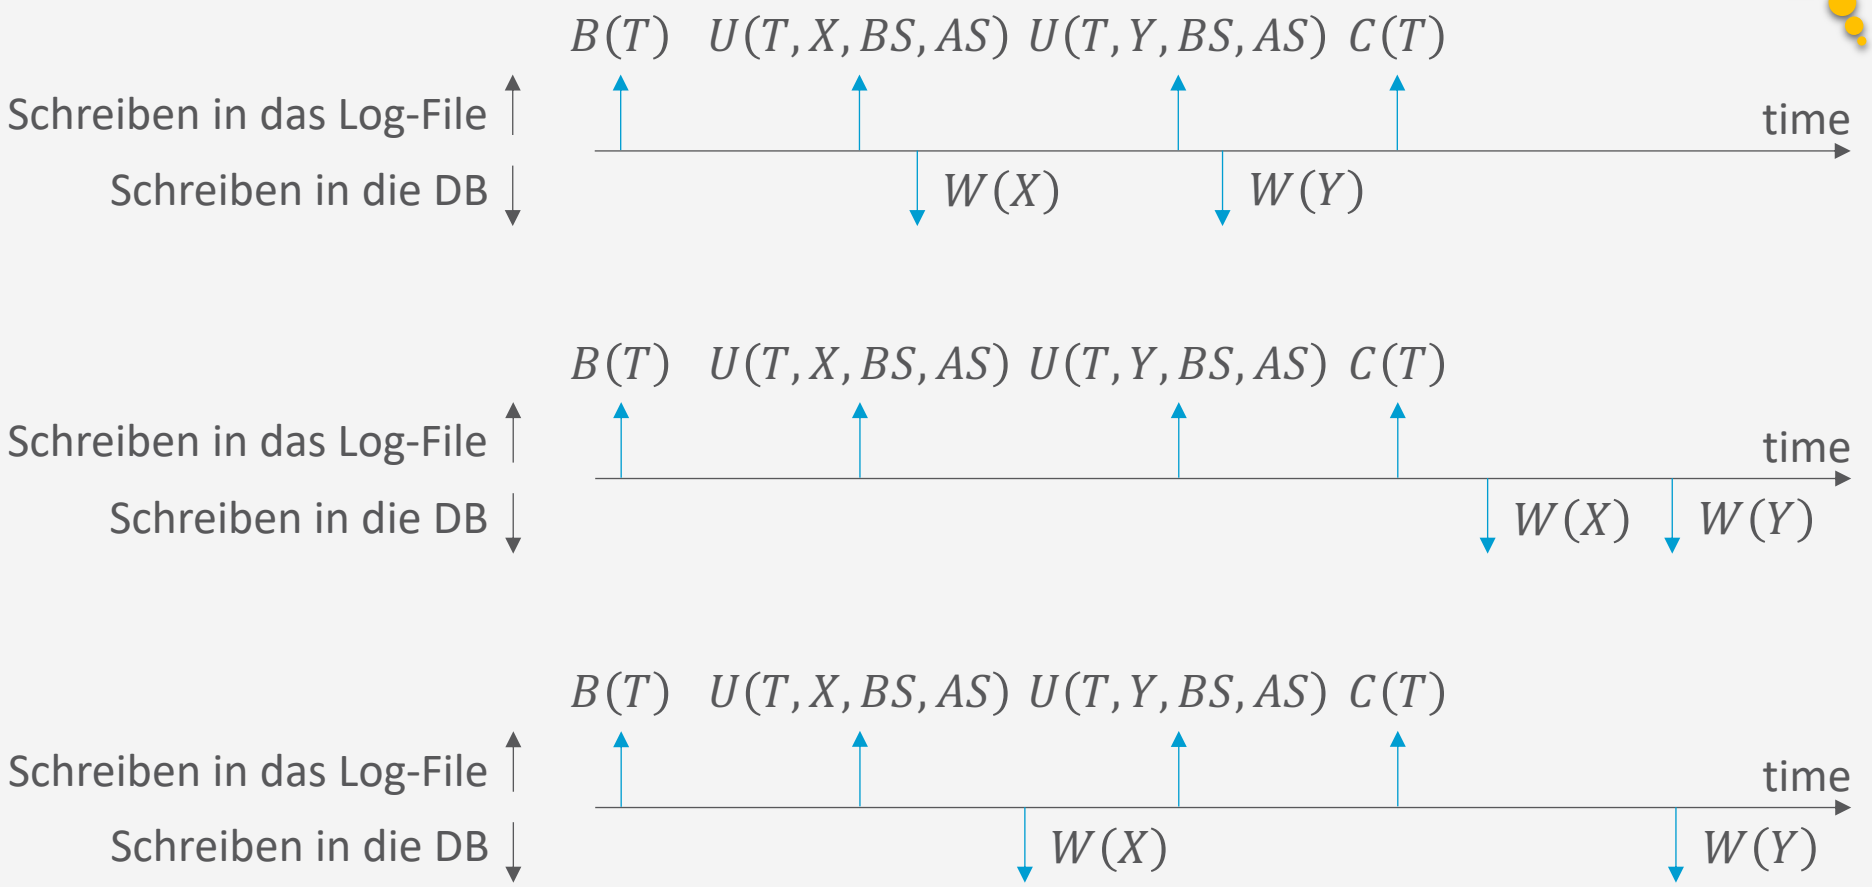

Recovery

Wiederherstellungsverwaltung

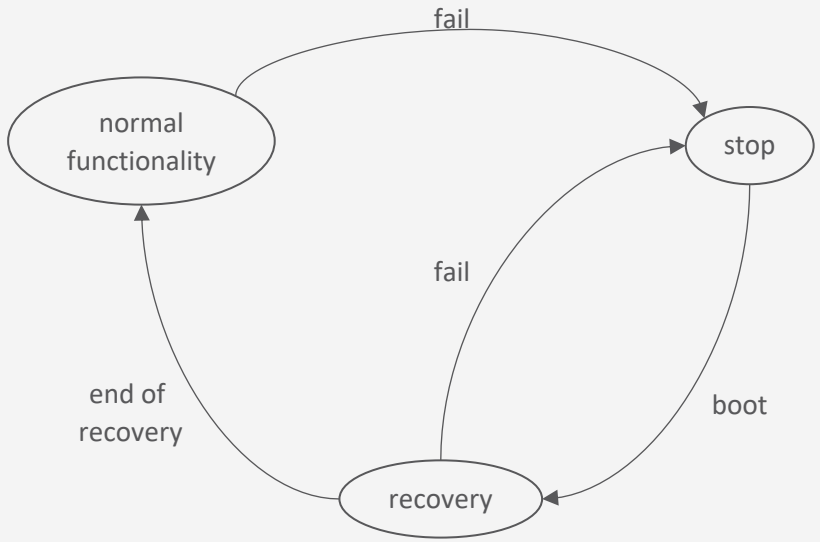

(Ideales) Fail-Stop-Model eines DBMS

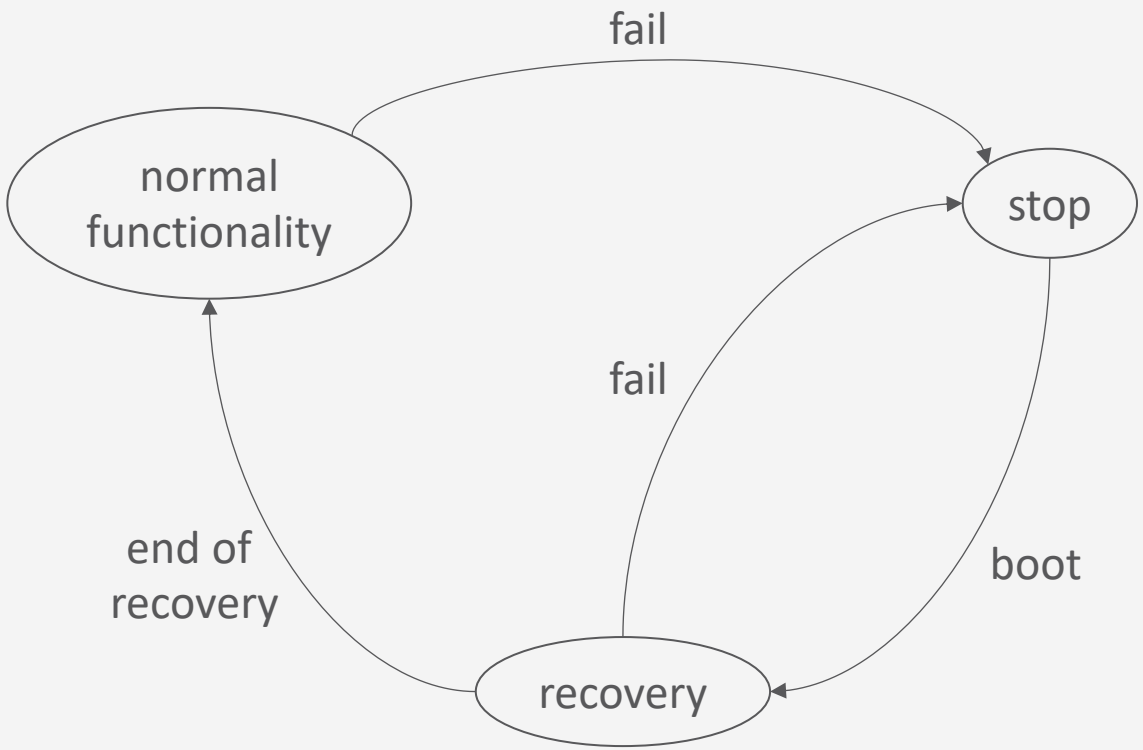

Boot: Warm / Cold Restart

- Fehlersituationen beim Datenmanagement …
  - Systemfehler
    - Softwarefehler (z.B. Betriebssystemfehler) oder
    - Fehler von Geräten (z.B. aufgrund von Fehlern in der Stromversorgung).
    - Hauptspeicher geht verloren, Hintergrundspeicher bleibt erhalten
  - Gerätefehler
    - Fehler des Hintergrundspeichers (z.B. aufgrund eines „Platten-Crashes“)
    - Hauptspeicher und Hintergrundspeicher gehen verloren
    - Stabiler Speicher bleibt erhalten (Band, RAID-System)
- Protokolle zum Restart des DBMS bzw. der DB
  - Warm Restart ist im Fall von Systemfehlern geeignet
  - Cold Restart ist im Fall von Gerätefehlern geeignet

Restart (Boot)

- Zustand von Transaktionen vor Stop
  - Abgeschlossen
    - Resultat abgeschlossener Transaktionen ist im stabilen Speicher gespeichert
  - COMMIT vorhanden, aber u.U. nicht abgeschlossen:
    - DB-Veränderungen der Transaktion müssen wiederholt werden
  - Kein COMMIT vorhanden
    - DB-Veränderungen der Transaktion müssen verworfen werden

Warm Restart

- Phase 1: Suche im Log-File die Position des jüngsten CHECKPOINT-Eintrags
- Phase 2: Bilde UNDO- und REDO-Menge
  - UNDO-Menge: Transaktionen, die verworfen werden müssen
  - REDO-Menge: Transaktionen, die reproduziert werden können
- Phase 3: Behandle Transaktionen der UNDO-Menge
  - Durchlaufe das Log-File zurück zur Position der ersten Operation der ältesten Transaktion aus der UNDO- *und* der REDO-Menge
  - Führe UNDO für alle Operationen der Transaktionen der UNDO-Menge aus
- Phase 4: Behandle Transaktionen der REDO Menge
  - Durchlaufe das Log-File vorwärts und führe REDO für alle Operationen der Transaktionen in der REDO-Menge aus
- Vorgehen sichert Atomarität und Dauerhaftigkeit

Cold Restart

- Phase 1:
  - Der aktuellste DUMP wird genutzt, um die verlorenen bzw. zerstörten Teile der DB wieder neu im Hintergrundspeicher anzulegen
- Phase 2:
  - Das Log-File wird vorwärts durchlaufen und die dort vermerkten Operationen werden auf der Rekonstruktion der DB neu ausgeführt
- Phase 3:
  - Ein Warm Restart wird initiiert
- Auch dieses Vorgehen sichert Atomarität und Dauerhaftigkeit

Zusammenfassung

- Fehlersituationen
  - System-, Medien-, Transaktionsfehler
  - Dauerhaftigkeit, Atomarität möglicherweise verletzt
- Logging
  - Log-Information
  - Konzept und Organisation von Log-Files
  - Inhalt und Nutzung bei Fehlern
- Recovery
  - Wiederherstellung eines DBMS
    - Warm restart (Systemfehler) unter Nutzung des letzten Checkpoints
    - Cold restart (Gerätefehler) unter Nutzung des letzten Dumps

Architektur eines DBMS

- Speicherung
- Anfrageverarbeitung
- Transaktionsmanagement
  - Transaktionsverwaltung
  - Sperrverwaltung
  - Wiederherstellungsverwaltung
    - Logging
      - Undo, Redo
      - Checkpoints, Dump
    - Recovery:
      - Warm / Cold Restart

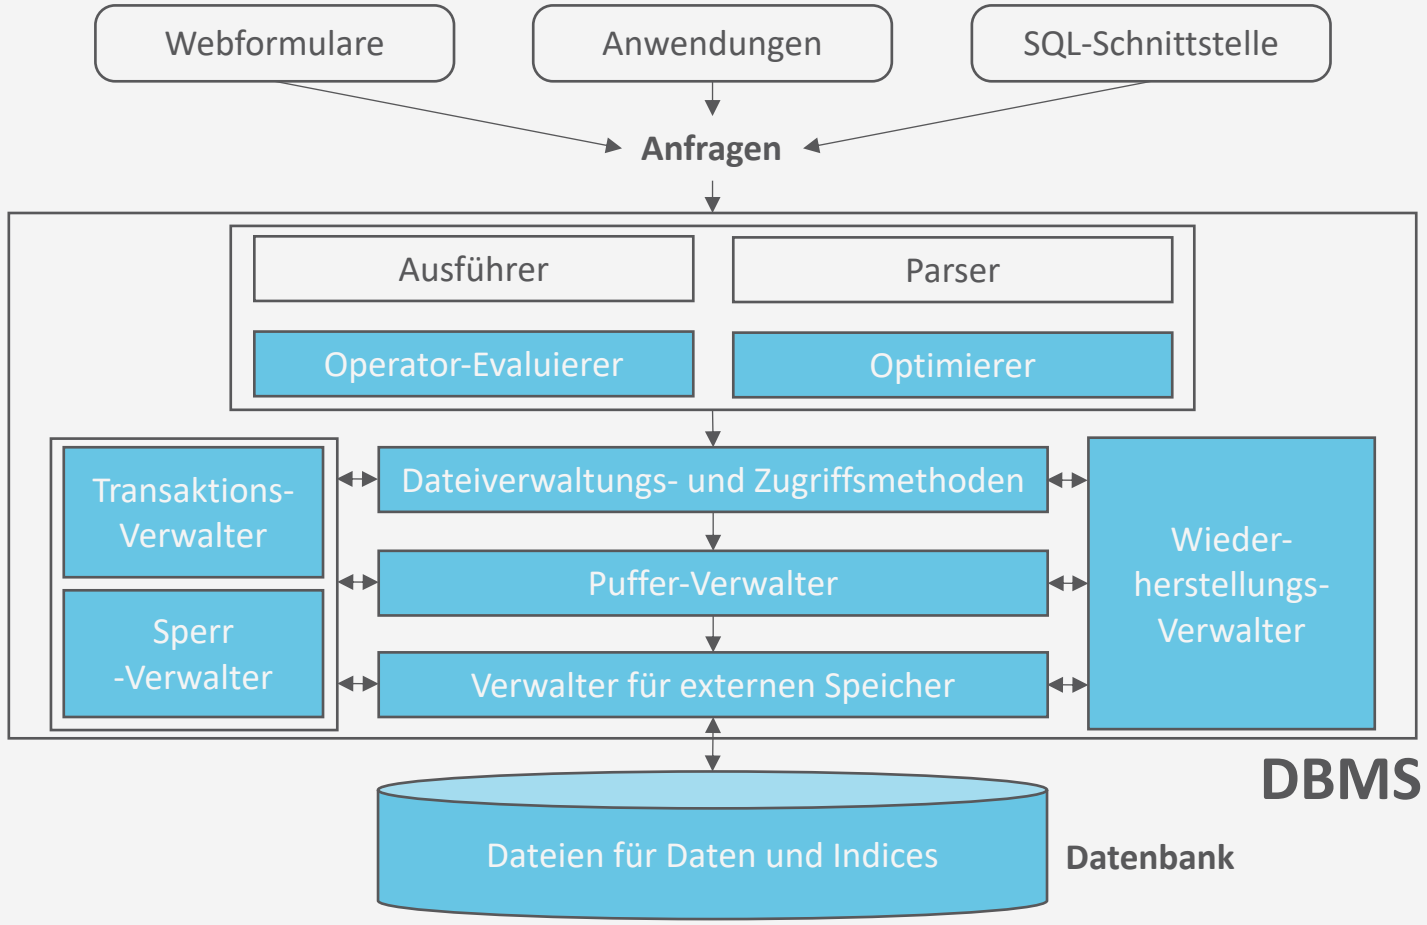

Überblick: 7. Transaktionen

A. Transaktionsverarbeitung
- Fehlersituationen
- Schedules: Korrektheit, Serialisierbarkeit, Äquivalenzen

B. Sperrverwaltung
- Sperren, Sperrprotokolle
- Deadlocks
- Weitere Methoden zur Mehrbenutzerkontrolle

C. Wiederherstellungsverwaltung
- Fehlersituationen
- Logging
- Recovery

→ Verteilte Datenbanken