Datenbanken: Nebenläufigkeitskontrolle durch Zeitstempel- und optimistische Verfahren

Stefan Halfpap, Ralf Teusner, Werner Sinzig, Michael Perscheid

26. Juni 2020

Vorlesungsinhalte/-aufbau

- Einführung zu Unternehmensanwendungen
- Grundlagen des IT-gestützten Rechnungswesens und der Planung
- Einführung zu relationalen Datenbanken und Anfrageverarbeitung
- Grundlagen von (spaltenorientierten) Hauptspeicherdatenbanken
- **Trends in Hauptspeicherdatenbanken**
- Klausur

Literatur und Empfehlung

- Avi Silberschatz „Database System Concepts“

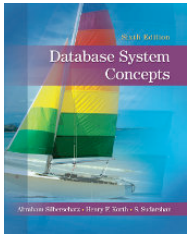

- Hector Garcia-Molina „Database Systems”

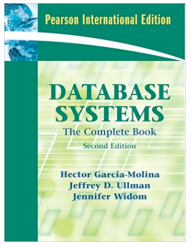

- Andy Pavlo „Database Systems“ – Timestamp Ordering & Multi Version Concurrency Control

  https://15445.courses.cs.cmu.edu/fall2018/slides/18-timestampordering.pdf

  https://15445.courses.cs.cmu.edu/fall2018/slides/19-multiversioning.pdf

Nebenläufigkeitskontrolle
Motivation

- Bisher: Fokus auf schnelle Anfragebearbeitung
- Aber: Haupteigenschaft von relationalen DBs sind **konsistente**/korrekte Anfrageergebnisse, auch bei nebenläufigen Anfragen und trotz Auftreten von Fehlern (insbesondere wichtig für Unternehmensanwendungen, z.B. in der Buchführung)

  Durch **Nebenläufigkeitskontrolle** und Loggen + Wiederherstellung

Nebenläufigkeitskontrolle
Transaktionen

- Konsistenz ist im DB-Kontext über Transaktionen definiert

- Transaktion: Ausführung einer Folge von (einer oder mehrerer) Operationen
  - Elementare Änderungseinheit in einer Datenbank
  - Erfüllen (abhängig vom Isolationslevel) ACID Kriterien
    - Atomicity
    - Consistency
    - Isolation
    - Durability

Nebenläufigkeitskontrolle
Serialisierbarkeit

- Gegeben ein konsistenter Datenbankzustand: eine isoliert ausgeführte Transaktion führt zu einem konsistenten Datenbankzustand
  - **Commit**: erfolgreiche Ausführung aller Änderungen
  - **Abort**: Abbruch durch Nutzer oder DBMS; inklusive Rückgängigmachung aller Änderungen

- Aber **serielle Ausführung** von Transaktionen in den meisten Fällen **nicht praktikabel**
  - Begrenzter Vorteil durch parallele Ausführung (Intra- vs. Inter-Query-Parallelisierung)
  - Lange laufende Transaktionen blockieren kurze

→ Ziel: korrekte/**serialisierbare Ausführung** von nebenläufigen Transaktionen
Serialisierbare Ausführung(sreihenfolge) führt zu gleichem Ergebnis wie serielle Ausführung

Nebenläufigkeitskontrolle
Varianten

Ziel: Serialisierbarkeit

- Wir brauchen einen Weg um Datenbankoperationen von nebenläufigen Transaktionen zu kontrollieren/steuern/synchronisieren

→ **Nebenläufigkeitskontrolle**

- Klassische Variante: Locks/Sperren: **2PL** (2 phase locking) 2-Phasen-Sperrprotokolle
  - Sperrphase (growing phase) gefolgt von Freigabephase (shrinking phase)
  - Lock-Typen (exklusives vs. geteiltes)
  - Deadlock-Verhinderung oder Erkennung + Wiederherstellung notwendig
  - → Reihenfolge von (in Konflikt stehenden) Transaktionen wird zur **Ausführungszeit** (durch die Ausführungszeit) bestimmt

DBS 1

- **Hier: alternative Varianten**

Nebenläufigkeitskontrolle
Alternativen zu 2PL

- **Zeitstempelverfahren** (Timestamp Ordering)
  Idee: Bestimme Ausführungsreihenfolge zum **Transaktionsbeginn**
  - Basisvariante
  - Multiversion Concurrency Control (MVCC)

- **Optimistische Nebenläufigkeitskontr**olle
  Idee: validiere Transaktionen nach der Ausführung; Reihenfolge wird durch den **Validierungszeitpunkt** bestimmt

Nebenläufigkeitskontrolle
Zeitstempelverfahren - Basisvariante

Idee:

- Weise jeder Transaktion zum Beginn einen eindeutigen, aufsteigenden Zeitstempel zu
- Der **Zeitstempel markiert den logischen Ausführungszeitpunkt**

→ bestimmt die logische Reihenfolge der Transaktionen → Serialisierbarkeit

Praktische Umsetzung:

- Transaktion T benötigt Zeitstempel **TS(T)**, z.B. durch Systemuhr oder logischen Zähler
- Datenelement I benötigt zwei Zeitstempel, die aktualisiert werden müssen
  - **W-TS(I)** speichert den größten Zeitstempel einer Transaktion, die das Element erfolgreich geschrieben hat
  - **R-TS(I)** speichert den größten Zeitstempel einer Transaktion, die das Element erfolgreich gelesen hat

Nebenläufigkeitskontrolle
Zeitstempelverfahren – Basisvariante – Beispiel 1

T1	T2	TS
READ(A)		1
	READ(A)	2
	WRITE(A)	3
READ(B)		4
	READ(B)	5
	WRITE(B)	6

TS(T1) = 1

TS(T2) = 2

Element I	R-TS(I)	W-TS(I)
A	$0 \rightarrow_1 1 \rightarrow_2 2$	$0 \rightarrow_3 2$
B	$0 \rightarrow_4 1 \rightarrow_5 2$	$0 \rightarrow_6 2$

Nebenläufigkeitskontrolle
Zeitstempelverfahren – Basisvariante - Protokoll

Zeitstempelverfahren müssen sicherstellen, dass in Konflikt stehende Operationen in der Reihenfolge ihrer Zeitstempel ausgeführt werden

Leseoperation: Transaktion T möchte Element I lesen

- Fall 1: TS(T) < W-TS(I)
  - I wurde bereits von eine späteren Transaktion verändert (geschrieben)
  - Leseoperation ist nicht möglich und T muss abbrechen
- Fall 2: TS(T) >= W-TS(I)
  - Leseoperation ist möglich und wird ausgeführt
  - R-TS(I) = max(R-TS(I), TS(T))

Nebenläufigkeitskontrolle
Zeitstempelverfahren – Basisvariante – Beispiel 2

T1	T2	TS
READ(A)		1
	WRITE(B)	2
READ(B)		3

TS(T1) = 1

TS(T2) = 2

TS(T1) == 1 < 2 == W-TS(B)
Leseoperation ist nicht möglich

Element I	R-TS(I)	W-TS(I)
A	$0 \rightarrow_1 1$	0
B	0	$0 \rightarrow_2 2$

Nebenläufigkeitskontrolle
Zeitstempelverfahren – Basisvariante - Protokoll

Schreiboperation: Transaktion T möchte Element I schreiben

- Fall 1: TS(T) < R-TS(I)
  - I wurde bereits von eine späteren Transaktion gelesen
  - Schreiboperation ist nicht möglich und T muss abbrechen
- Fall 2: TS(T) < W-TS(I)
  - I wurde von einer späteren Transaktion überschrieben
  - Variante 1: Schreiboperation ist veraltet und wird abgebrochen
  - Variante 2: Schreiboperation ist unnötig und wird ignoriert (Thomas‘ Write Rule)
- Fall 3: ansonsten
  - Schreiboperation ist möglich und wird ausgeführt
  - W-TS(I) = TS(T)

Nebenläufigkeitskontrolle
Zeitstempelverfahren – Basisvariante – Beispiel 3

T1	T2	TS
READ(A)		1
	READ(A)	2
WRITE(A)		3

TS(T1) = 1

TS(T2) = 2

TS(T1) == 1 < 2 == R-TS(A)
Schreiboperation ist nicht möglich

Element I	R-TS(I)	W-TS(I)
A	$0 \rightarrow_1 1 \rightarrow_2 2$	0

Nebenläufigkeitskontrolle
Zeitstempelverfahren – Basisvariante – Beispiel 4

T1	T2	TS
READ(A)		1
	WRITE(B)	2
WRITE(B)		3

TS(T1) = 1

TS(T2) = 2

TS(T1) == 1 < 2 == W-TS(B)
Schreiboperation ist veraltet, kann aber ignoriert werden

Element I	R-TS(I)	W-TS(I)
A	$0 \rightarrow_1 1$	0
B	0	$0 \rightarrow_2 2$

Nebenläufigkeitskontrolle
Zeitstempelverfahren – Basisvariante - Protokoll

Abgebrochene Transaktionen

- Müssen Änderungen Rückgängig machen
- Bekommen neuen Zeitstempel
- Starten von vorne

Achtung: Basisvariante erlaubt nicht wiederherstellbare Reihenfolgen von Operationen, insbesondere durch das Lesen von uncommitteten Änderungen

Folgende Erweiterungen sind möglich:

- Variante 1: Alle Schreiboperationen atomar am Ende der Transaktion durchführen
- Variante 2: Transaktionen warten mit dem Lesen von uncommitteten Änderungen
- Variante 3: Spätere Überprüfung nach dem Lesen uncommitteter Änderungen

Nebenläufigkeitskontrolle
Zeitstempelverfahren – Basisvariante – Beispiel 5

T1	T2	TS
WRITE(A)		1
	READ(A)	2
ABORT		3

TS(T1) = 1

TS(T2) = 2

T1 kann abbrechen, obwohl T2 die neue uncommittete Version von Element A bereits gelesen hat

Element I	R-TS(I)	W-TS(I)
A	$0 \rightarrow_2 2$	$0 \rightarrow_1 1$

Nebenläufigkeitskontrolle
Zeitstempelverfahren – Basisvariante - Beobachtungen

- **Mehraufwand** durch Aktualisierungen der Zeitstempel
- Lang laufende Transaktionen können wiederholt abbrechen
  (Mit der Dauer einer Transaktion steigt die Wahrscheinlichkeit, dass die Transaktion veränderte Elemente einer neueren Transaktionen lesen möchte)

- Im Falle vieler lesender Transaktionen ist die Anzahl der Konflikte niedrig

→ Idee: Optimiere für den Fall ohne Konflikte – **Optimistische** Nebenläufigkeitskontrolle
(als Gegenteil der beiden pessimistischen Verfahren: 2PL und Zeitstempelverfahren)

Umsetzung: Nebenläufigkeitskontrolle durch Validierung (spätere Überprüfung)

Nebenläufigkeitskontrolle durch Validierung

2 oder 3 Phasen pro Transaktion

- Phase 1: Lesephase
  - Speichere die Menge der gelesenen und geschriebenen Elemente lokal
- Phase 2: Validierungsphase
  - Überprüfe zum Commit-Zeitpunkt, ob es Konflikte mit anderen Transaktionen gibt
  - Fall 1: erfolgreiche Validierung: beginne mit der Schreibphase
  - Fall 2: starte die Transaktion ansonsten neu
- (optionale) Phase 3: Schreibphase
  - Wende lokale Änderungen auf Datenbank an

Nebenläufigkeitskontrolle durch Validierung - Protokoll

Praktische Umsetzung:

- Alle Transaktionen müssen die Phasen in der gezeigten Reihenfolge durchlaufen
- Phasen nebenläufiger Transaktionen können überlappen
- Validierung muss Zeiträume der Phasen kennen

→ Speichere pro Transaktion drei Zeitstempel

- **START(T)** speichert Beginn der Transaktion
- **VAL(T)** speichert Beginn der Validierungsphase (/ Ende der Lesephase)
- **FIN(T)** speichert Ende der Schreibphase

Die Reihenfolge der Transaktionen ist durch die Validierungszeitstempel VAL(T) bestimmt

Nebenläufigkeitskontrolle durch Validierung - Protokoll

Validierungstests für Transaktion T_i mit allen vorherigen Transaktionen T_k mit $VAL(T_k)<VAL(T_i)$ muss folgende Bedingungen erfüllen

- Fall 1: $FIN(T_k) < START(T_i)$
  Validierung mit T_k trivial, da T_k vor Beginn von T_i beendet war
- Fall 2: ansonsten
  Keine Überlappung der geschriebenen Elemente von T_k mit den gelesenen Elementen von T_i

Nebenläufigkeitskontrolle durch Validierung – Beispiel

T1	T2	TS	
READ(A)		1	
	WRITE(B)	2	lokal
READ(B)		3	
VALIDATE		4	VAL(T1) == FIN(T1) = 4; Validierung trivial, da keine Transaktion vor T1
	READ(A)	5	
	VALIDATE	6	VAL(T2) = 6; Validierung trivial, da T1 nicht schreibt
	WRITE	7	global; FIN(T2) = 7

Nebenläufigkeitskontrolle
Multiversion Concurrency Control

Bisher: Serialisierbarkeit durch Verschieben/Sperren von Operationen
oder Transaktionsabbruch:

- Leseoperation muss warten, da der Wert noch nicht geschrieben oder committet ist
- Transaktion muss abbrechen, da zu lesender Wert bereits überschrieben wurde

Idee: Vermeide diese Probleme durch das Aufbewahren alter Versionen
der geänderten Elemente

DB speichert mehrere physische Versionen von einem logischen Element, z.B. Tupel

Nebenläufigkeitskontrolle
Multiversion Concurrency Control

DB speichert mehrere physische Versionen von einem logischen Element, z.B. Tupel

- Änderungen eines Elements erzeugen eine neue Version
  (siehe 08_DB_Weitere_Optimierungen - Insert-Only-Ansatz)
- Transaktionen lesen die neueste Version, die zum Transaktionsstart existierte

→ Leseoperationen blockieren nicht Schreiboperationen

→ Schreiboperationen blockieren nicht Leseoperationen

+ Snapshot-Isolation (und Zeitreise-Queries)

+ Möglicherweise gesetzlich vorgeschrieben

- Speicherverbrauch

- Höhere Scan-Kosten

siehe 08_DB_Weitere_Optimierungen

Nebenläufigkeitskontrolle
Multiversion Concurrency Control - Protokoll

Anpassungen an Basisprotokoll

- Datenelement I hat (potenziell) mehrere Versionen mit je zwei Zeitstempeln
  - **W-TS(I_T)** / BEGIN-TS(I_T) speichert den Zeitstempel der erstellenden Transaktion TS(T)
    wird genutzt um die passende Version für Leseoperationen zu finden
  - **END-TS(I_T)** speichert, falls gesetzt, den Beginn-Zeitstempel der neuen Version
    wird genutzt um die passende Version für Leseoperationen zu finden
  - **R-TS(I_T)** funktioniert analog zum Basisprotokoll
    wird genutzt um unmögliche Schreiboperationen abzulehnen

- Nicht mehr benötigte Versionen können gelöscht werden

Nebenläufigkeitskontrolle
Multiversion Concurrency Control – Beispiel

T1	T2	TS
READ(A)		1
	WRITE(B)	2
READ(B)		3

TS(T1) = 1

TS(T2) = 2; B_2 wird erzeugt

Version B_0 wird gelesen

Element I	R-TS(I)	W-TS(I)	END-TS(I)
A	$0 \rightarrow_1 1$	0	∞
B_0	$0 \rightarrow_3 1$	0	$\infty \rightarrow_2 2$
$\rightarrow_2 B_2$	$\rightarrow_2 2$	$\rightarrow_2 2$	$\rightarrow_2 \infty$

Nebenläufigkeitskontrolle
Multiversion Concurrency Control - Designentscheidungen

„MVCC is more than just a concurrency control protocol.

It completely affects how the DBMS manages transactions and the database."

Andy Pavlo „Multi Version Concurrency Control" Vorlesung
https://15445.courses.cs.cmu.edu/fall2018/slides/19-multiversioning.pdf

MVCC Implementierungen erfordern mehrere Designentscheidungen:

- Nebenläufigkeitsprotokoll: es existieren auch 2PL- und optimistische Varianten
- Versionsspeicherung: ob und wie einzelne Versionen verlinkt sind

  (effizientes Finden der richtigen Version ist insbesondere für transaktionale Workloads wichtig)
- Speicherbereinigung: wann und wie werden alte Versionen erkannt und gelöscht
- Indexverwaltung: auf welche Versionen verweisen Indexe

Nebenläufigkeitskontrolle
Beobachtungen

- Bisher betrachtete Operationen: Daten lesen und aktualisieren (feste Menge von Datenelementen)
- INSERTS und DELETES erzeugen weitere Probleme, z.B. Phantom-Problem

Prädikat-Locking und wiederholter Scan zum Commit als Techniken um damit umzugehen

Aber: Serialisierbarkeit limitiert Nebenläufigkeit stark und damit Performanz

- Schwächere Konsistenzlevel als Alternativen
- Insbesondere ist das Standard-(oder sogar höchste)Isolationslevel von Datenbanken nicht immer Serialisierbarkeit

http://www.bailis.org/blog/when-is-acid-acid-rarely/

Nebenläufigkeitskontrolle
SQL-92 Isolationslevel (Überblick)

	Lesen uncommitteter Änderungen	Nicht wiederholbares Lesen	Phantom
Serializable	**Unmöglich**	**Unmöglich**	**Unmöglich**
Repeatable Read	**Unmöglich**	**Unmöglich**	**Möglich**
Read Commited	**Unmöglich**	**Möglich**	**Möglich**
Read Uncommitted	**Möglich**	**Möglich**	**Möglich**

Zusammenfassung

- Zeitstempel- und optimistische Verfahren zur Nebenläufigkeitskontrolle sind Alternativen zu 2PL um konsistente Anfrageergebnisse zu gewährleisten
  - Zeitstempelverfahren: Zeitstempel definiert die Ausführungsreihenfolge
  - Optimistische Verfahren: Validierungszeitpunkt definiert die Ausführungsreihenfolge
- Multiversion Concurrency Control verhindert Transaktionsverzögerungen und –abbrüche durch das Speichern älterer Versionen von Datenelementen