5. Synchronisation[1]

- **Anomalien im Mehrbenutzerbetrieb**
- **Synchronisation von Transaktionen**
  - Ablaufpläne, Modellannahmen
  - Korrektheitskriterium
- **Theorie der Serialisierbarkeit**
  - Serialisierbare Historien
  - Klassen von Historien
- **Zweiphasen-Sperrprotokolle**
  - RX-Protokoll, RUX-Protokoll
  - Hierarchische Sperrverfahren
  - Deadlock-Behandlung
- **Konsistenzebenen**
- **Optimistische Synchronisation**
  - Eigenschaften
  - BOCC, FOCC
- **Optimierungen**
  - RAX, RAC, Mehrversionen-Verfahren
  - Zeitstempel-Verfahren
  - Prädikatssperren
  - Spezielle Synchronisationsprotokolle
- **Leistungsanalyse und Bewertung**

---

1. Thomasian, A.: Concurrency Control: Methods, Performance, and Analysis, in: ACM Computing Surveys 30:1, 1998, 70-119.

Dining Philosophers

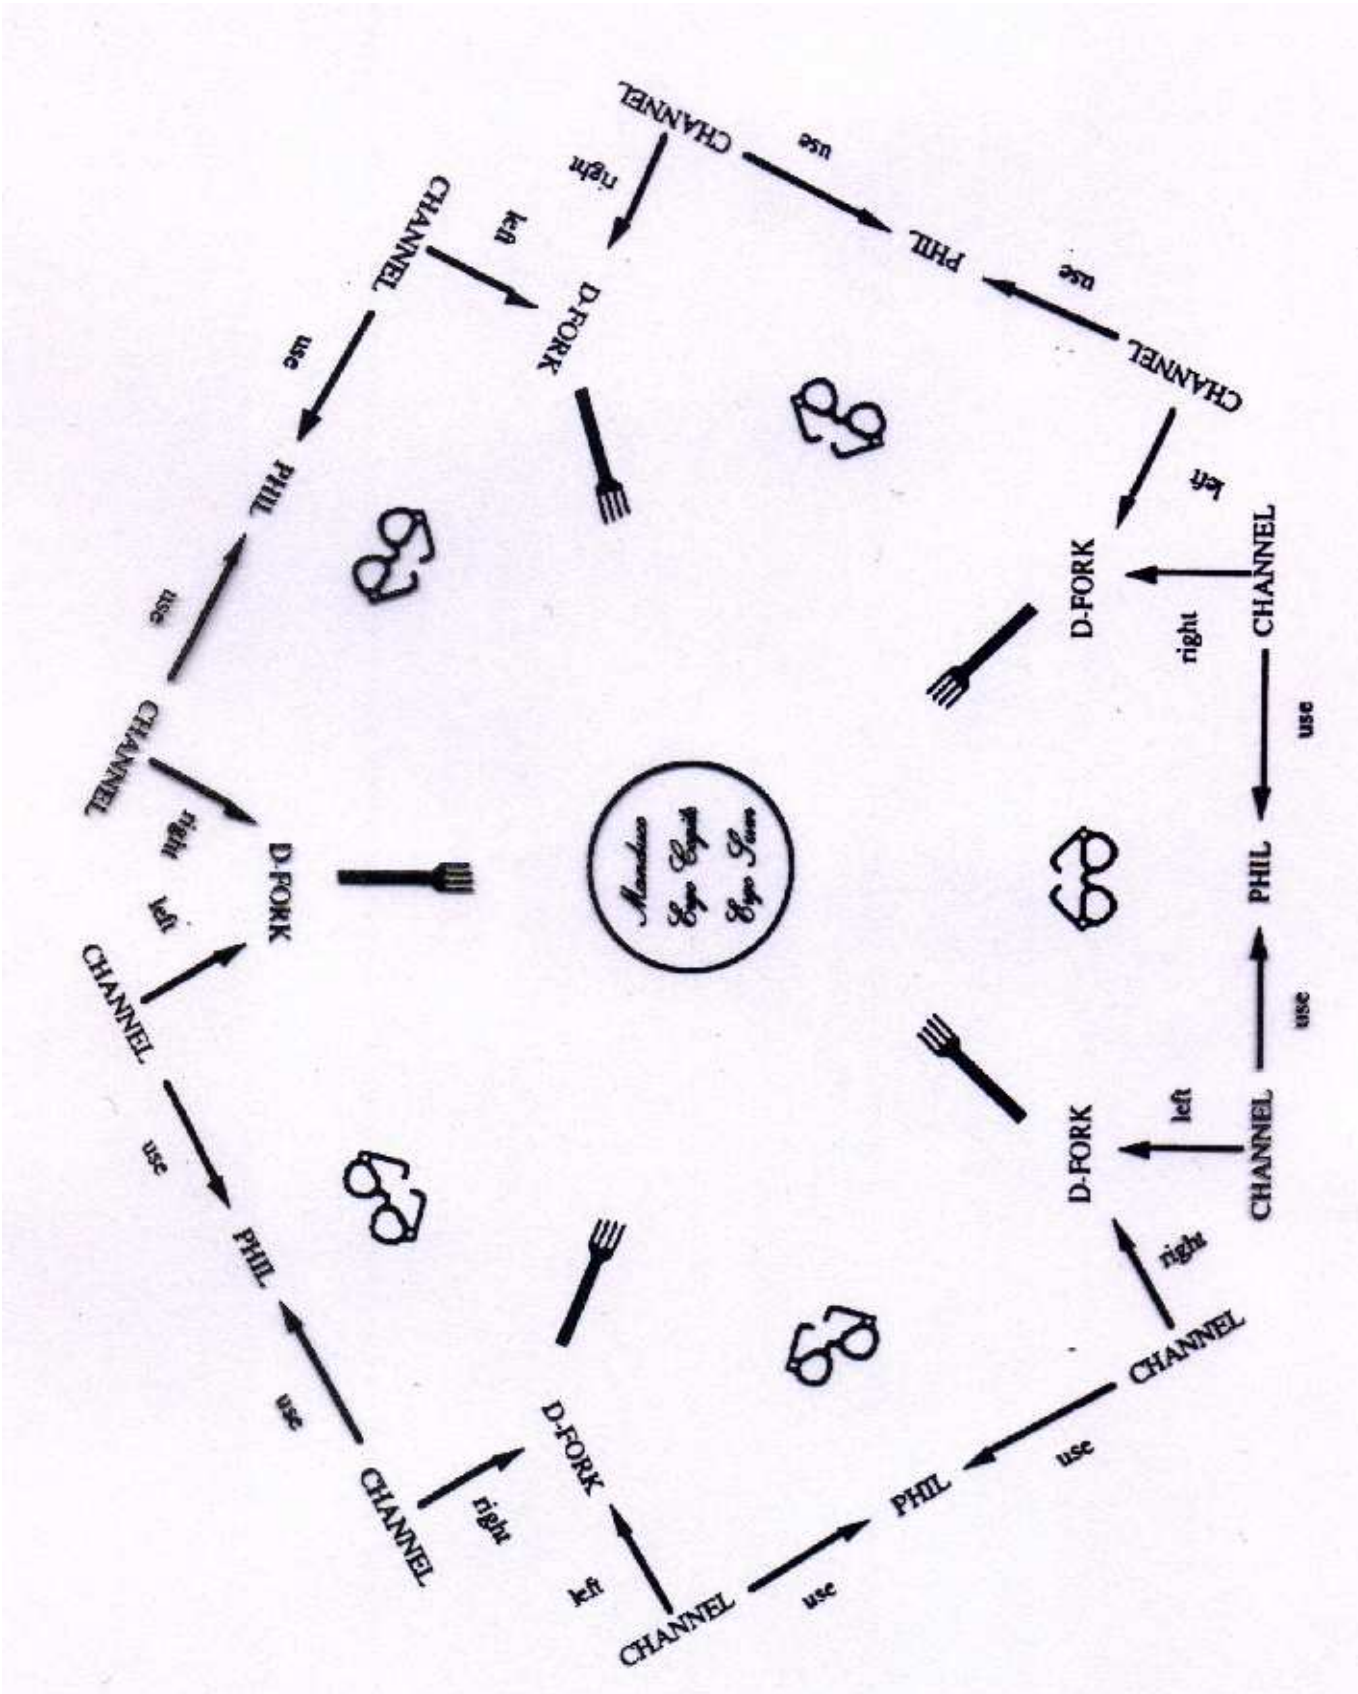
CHANNEL
use
PHIL
use
CHANNEL
left
D-FORK
right

Warum Mehrbenutzerbetrieb?

- **Ausführung von Transaktionen**

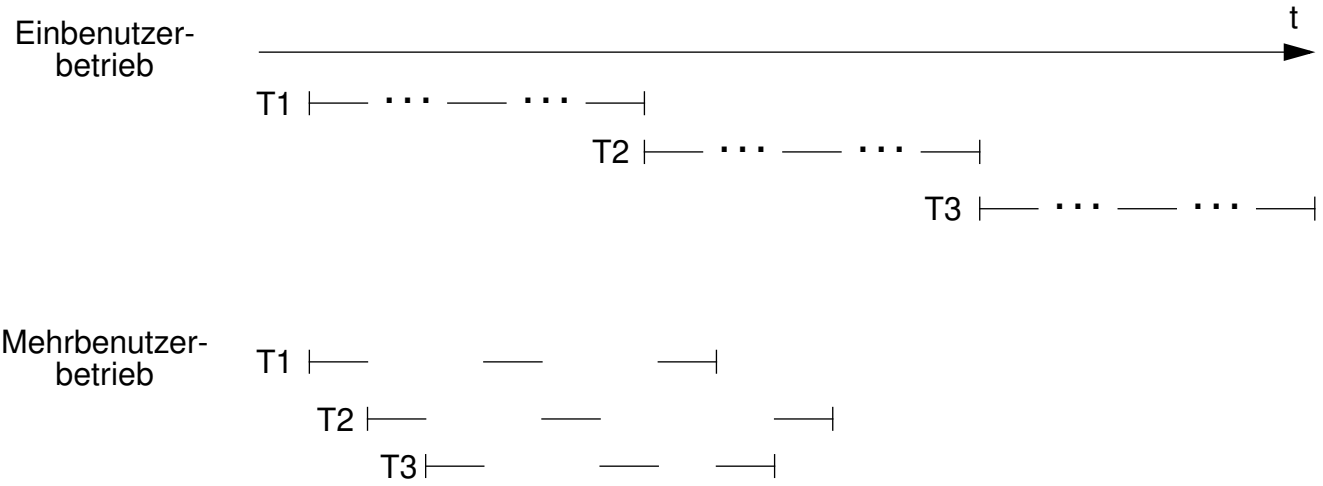

  - CPU-Nutzung während TA-Unterbrechungen
    - E/A
    - Denkzeiten bei Mehrschritt-TA
    - Kommunikationsvorgänge in verteilten Systemen
  - bei langen TA zu große Wartezeiten für andere TA (Scheduling-Fairneß)

Anomalien im unkontrollierten Mehrbenutzerbetrieb

1. Abhängigkeit von nicht freigegebenen Änderungen
   (dirty read, dirty overwrite)
2. Verlorengegangene Änderung *(lost update)*
3. Inkonsistente Analyse *(non-repeatable read)*
4. Phantom-Problem
5. Integritätsverletzung durch Mehrbenutzer-Anomalie
6. Instabilität von Cursorn

➥ **nur durch Änderungs-TA verursacht**

Unkontrollierter Mehrbenutzerbetrieb

- **Abhängigkeit von nicht freigegebenen Änderungen**

T1	T2
read (A);	
A := A + 100	
write (A);	
	read (A);
	read (B);
	B := B + A;
	write (B);
	commit;
abort;	

  - Geänderte, aber noch nicht freigegebene Daten werden als „schmutzig“ bezeichnet (dirty data), da die TA ihre Änderungen bis Commit (einseitig) zurücknehmen kann
  - Schmutzige Daten dürfen von anderen TAs nicht in „kritischen” Operationen benutzt werden

- **Verlorengegangene Änderung (Lost Update)**

T1	T2	A in DB
read (A);		
	read (A);	
A := A - 1;		
write (A);		
	A := A - 1;	
	write (A);	

  - **Verlorengegangene Änderungen sind auszuschließen!**

Inkonsistente Analyse (Non-repeatable Read)

Das wiederholte Lesen einer gegebenen Folge von Daten führt auf verschiedene Ergebnisse:

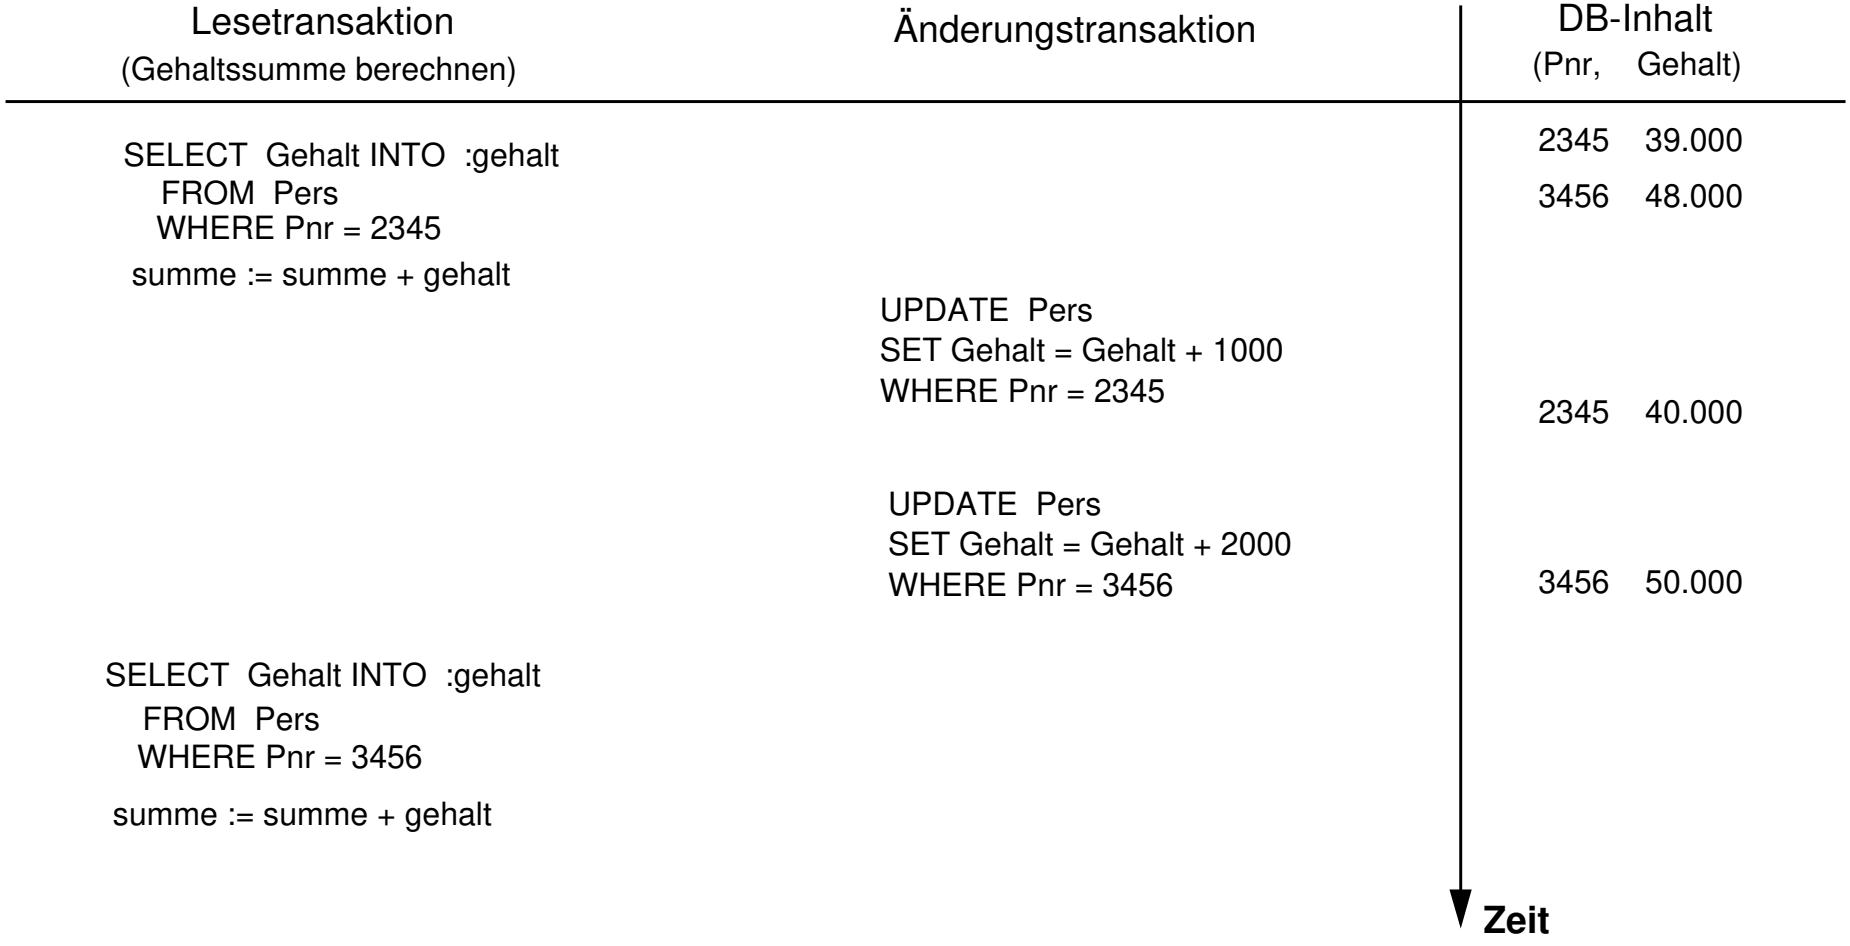

Phantom-Problem

Einfügungen oder Löschungen können Leser zu falschen Schlußfolgerungen verleiten:

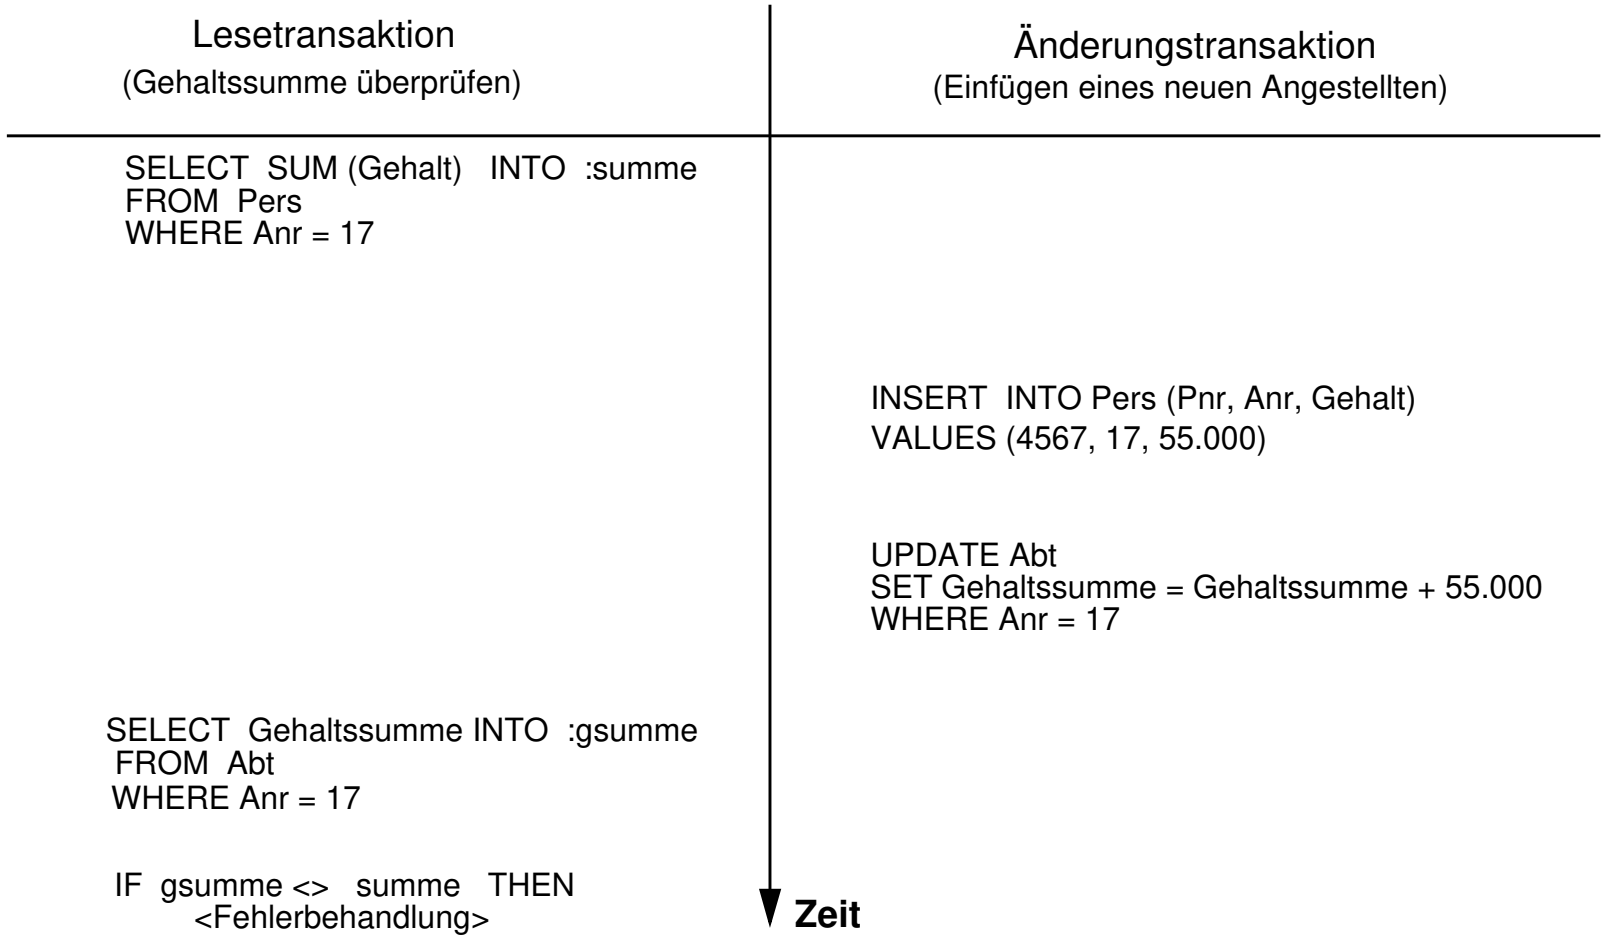

Unkontrollierter Mehrbenutzerbetrieb (2)

- **Integritätsverletzung durch Mehrbenutzer-Anomalie**
  - Integritätsbedingung: A = B
  - T1 := (A := A + 10; B := B + 10)
    T2 := (A := A ∗ 2; B := B ∗ 2)
  - **Probleme bei verschränktem Ablauf**

T1	T2	A	B
read (A); A := A + 10; write (A);			
	read (A); A := A ∗ 2; write (A); read (B) B := B ∗ 2; write (B);		
read (B); B := B + 10; write (B);			

  ➥ **Synchronisation (Sperren) einzelner Datensätze reicht nicht aus!**

- **Cursor-Referenzen**
  - Zwischen dem Finden eines Objektes mit Eigenschaft P und dem Lesen seiner Daten wird P nach P' verändert

T1	T2
Positioniere Cursor C auf nächstes Objekt (A) mit Eigenschaft P	
	Verändere P → P' bei A
Lies laufendes Objekt	

  ➥ **Cursor-Stabilität sollte gewährleistet werden!**

Synchronisation von Transaktionen

- **TRANSAKTION:** Ein Programm T mit DML-Anweisungen,
  das folgende Eigenschaft erfüllt:

  Wenn T **allein** auf einer konsistenten DB ausgeführt wird, dann terminiert T (irgendwann) und hinterläßt die DB in einem konsistenten Zustand.
  (Während der TA-Verarbeitung gibt es keine Konsistenzgarantien!)

- **Ablaufpläne für 3 Transaktionen**

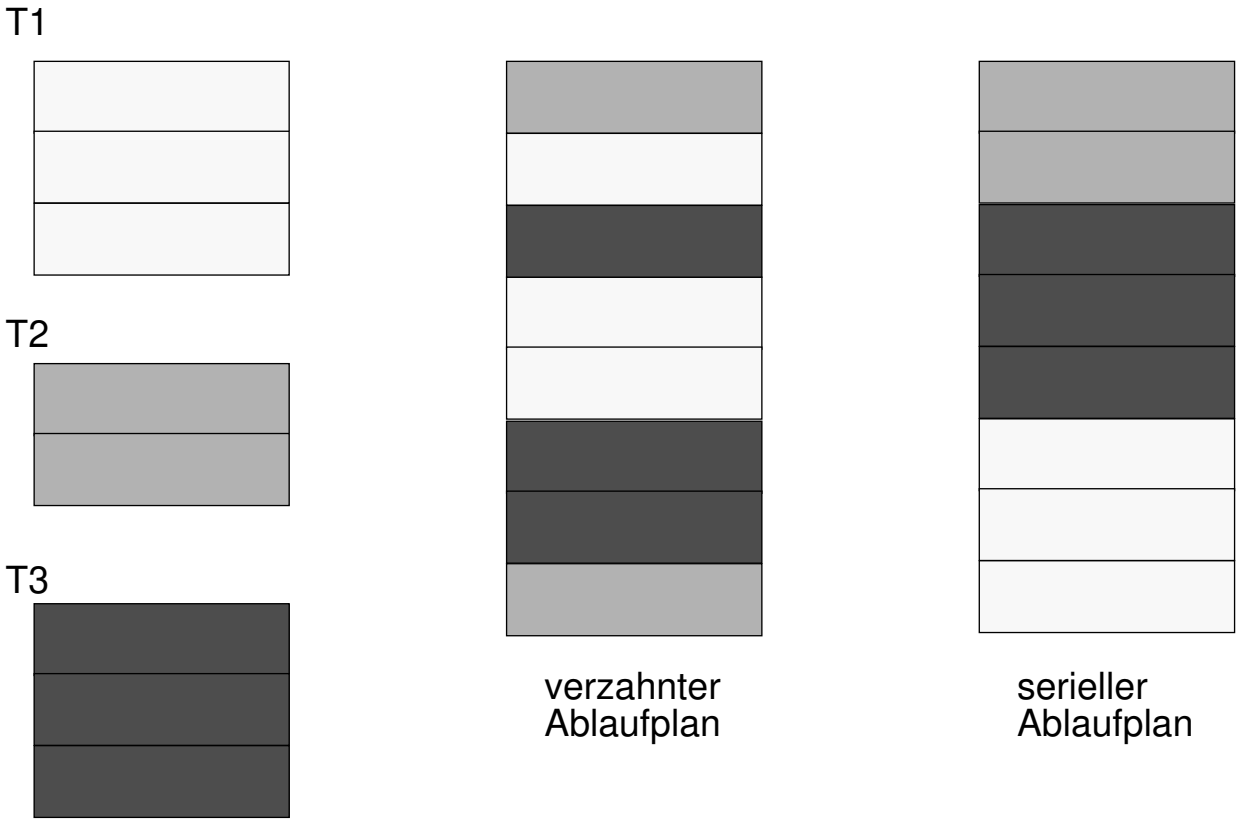

  ➥ Wenn Transaktionen seriell ausgeführt werden, dann bleibt die Konsistenz der DB erhalten.

- **Ziel der Synchronisation:**

  logischer Einbenutzerbetrieb,
  d.h. Vermeidung aller Mehrbenutzeranomalien

  ➥ **Wann ist die parallele Ausführung von n Transaktionen auf gemeinsamen Daten korrekt?**

Synchronisation von Transaktionen (2)

- **Beispiel für einige Ausführungsvarianten**

Ausführung 1		Ausführung 2		Ausführung 3	
T1	T2	T1	T2	T1	T2
read (A)		read (A)		read (A)	
A - 1			read (B)	A - 1	
write (A)		A - 1			read (B)
read (B)			B - 2	write (A)	
B + 1		write (A)			B - 2
write (B)			write (B)	read (B)	
	read (B)	read (B)			write (B)
	B - 2		read (C)	B + 1	
	write (B)	B + 1			read (C)
	read (C)		C + 2	write (B)	
	C + 2	write (B)			C + 2
	write (C)		write (C)		write (C)

➥ **Bei serieller Ausführung bleibt der Wert von A + B + C unverändert!**

- **Was ist das Ergebnis der verschiedenen Ausführungsvarianten?**

	A	B	C	A + B + C
initialer Wert				
nach T1; T2				
nach Ausf. 2				
nach Ausf. 3				
nach T2; T1				

- **Ziel:** Äquivalenz der Ergebnisse von verzahnten Ausführungen zu einer der möglichen seriellen Ausführungen

Synchronisation - Modellannahmen

- **Modellbildung**

  für die Synchronisation

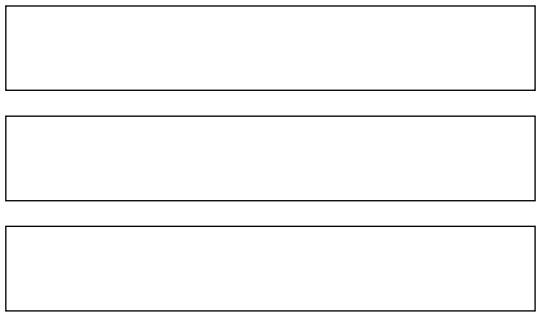

- **Read/Write-Modell**
  - DB ist Menge von unteilbaren, uninterpretierten Datenobjekten (z. B. Seiten)
  - DB-Anweisungen lassen sich nachbilden durch atomare Lese- und Schreiboperationen auf Objekten:
    - $r_i(A)$, $w_i(A)$ zum Lesen bzw. Schreiben des Datenobjekts A
    - c_i , a_i zur Durchführung eines **commit** bzw. **abort**
  - **Transaktion** wird modelliert als eine endliche Folge von Operationen p_i:

    $T = p_1\, p_2\, p_3 \ldots p_n$ mit $p_i \in \{r(x_i), w(x_i)\}$
  - Eine vollständige TA hat als letzte Operation entweder einen Abbruch a oder ein Commit c

    $T = p_1 \ldots p_n\, a$ oder $T = p_1 \ldots p_n\, c$

  ➥ **Für eine TA T_i werden diese Operationen mit r_i, w_i, c_i oder a_i bezeichnet, um sie zuordnen zu können**

- **Die Ablauffolge von TA mit ihren Operationen kann durch einen *Schedule* (Ablaufplan) beschrieben werden:**

  Beispiel:
  $r_1(A), r_2(A), r_3(B), w_1(A), w_3(B), r_1(B), c_1, r_3(A), w_2(A), a_2, w_3(C), c_3, \ldots$

Korrektheitskriterium der Synchronisation

- **Serieller Ablauf von Transaktionen**

TA = {T1, T2, T3}

DB = {A, B, C}

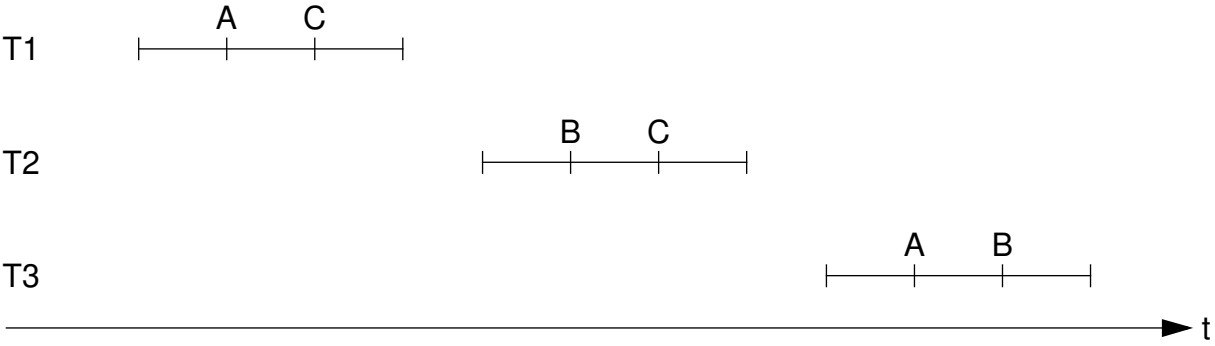

Ausführungsreihenfolge:

- **T1 | T2 bedeutet:**

  T1 sieht keine Änderungen von T2 und
  T2 sieht alle Änderungen von T1

- **Formales Korrektheitskriterium: *Serialisierbarkeit*:**

> Die parallele Ausführung einer Menge von TA ist **serialisierbar**,
> wenn es eine serielle Ausführung derselben TA-Menge gibt,
> die den **gleichen DB-Zustand**
> und die **gleichen Ausgabewerte**
> wie die ursprüngliche Ausführung erzielt.

- **Hintergrund:**
  - Serielle Ablaufpläne sind korrekt!
  - Jeder Ablaufplan, der denselben Effekt wie ein serieller erzielt, ist akzeptierbar

Konsistenzerhaltende Ablaufpläne

- Die TA T1-T3 müssen so synchronisiert werden, daß der resultierende Zustand der DB gleich dem ist, der bei der seriellen Ausführung in einer der folgenden Sequenzen zustande gekommen wäre:

T1, T2, T3	T2, T1, T3	T3, T1, T2
T1, T3, T2	T2, T3, T1	T3, T2, T1

- Bei n TA gibt es n! (hier 3! = 6) mögliche serielle Ablaufpläne
- **Serielle Ablaufpläne können verschiedene Ergebnisse haben!**

  Abbuchung/Einzahlung auf Konto: TA1: - 5000; TA2: + 2000

Konto	Stand = 2000	Limit = 2000

- **Nicht alle seriellen Ablaufpläne sind möglich!**

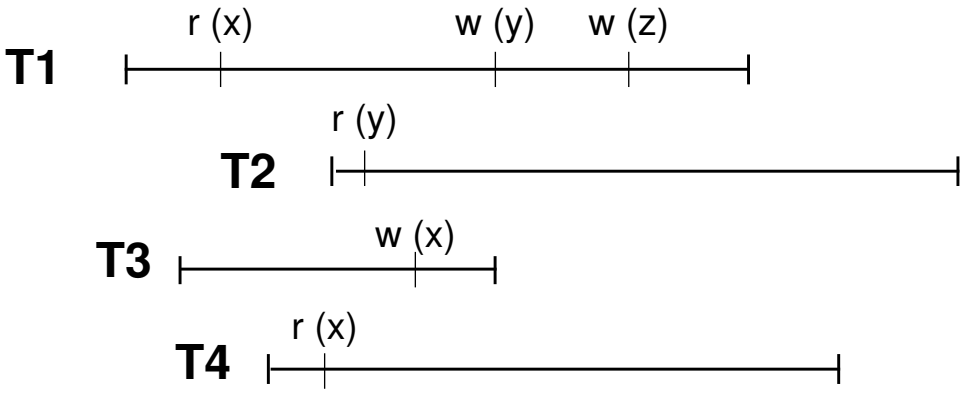

- **Sinnvolle Einschränkungen**

1. **Reihenfolgeerhaltende Serialisierbarkeit:**

   Jede TA sollte wenigstens alle Änderungen sehen, die bei ihrem Start (BOT) bereits beendet waren

2. **Chronologieerhaltende Serialisierbarkeit:**

   Jede TA sollte stets die aktuellste Objektversion sehen

Theorie der Serialisierbarkeit[1]

- **Ablauf einer Transaktion**
  - Häufigste Annahme: streng sequentielle Reihenfolge der Operationen
  - Serialisierbarkeitstheorie läßt sich auch auf Basis einer partiellen Ordnung ($<_i$) entwickeln
  - TA-Abschluß: **abort** oder **commit** - aber nicht beides!
- **Konsistenzanforderungen an eine TA**
  - Falls T_i ein **abort** durchführt, müssen alle anderen Operationen $p_i(A)$ vor a_i ausgeführt werden: $p_i(A) <_i a_i$
  - Analoges gilt für das **commit:** $p_i(A) <_i c_i$
  - Wenn T_i ein Datum A liest und auch schreibt, ist die **Reihenfolge festzulegen**:

    $r_i(A) <_i w_i(A)$ oder $w_i(A) <_i r_i(A)$

- **Beispiel: Überweisungs-TA T1** (von K1 nach K2)

$r_1(K1)$	oder	$r_1(K1)$	$r_1(K2)$
$w_1(K1)$		$w_1(K1)$	$w_1(K2)$
$r_1(K2)$			c_1
$w_1(K2)$			
c_1			

  - Totale Ordnung: $r_1(K1) \rightarrow w_1(K1) \rightarrow r_1(K2) \rightarrow w_1(K2) \rightarrow c_1$
  - Partielle Ordnung

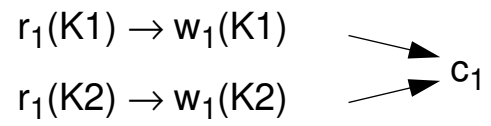

1. Bernstein, P.A., Hadzilacos, V., Goodman, N.: Concurrency Control and Recovery in Database Systems, Addison-Wesley Publ. Comp., 1987 (http://research.microsoft.com/pubs/ccontrol/)

Theorie der Serialisierbarkeit (2)

- **Historie (Schedule)**
  - Unter einer Historie versteht man den Ablauf einer (verzahnten) Ausführung mehrerer TA
  - Sie spezifiziert die Reihenfolge, in der die Elementaroperationen verschiedener TA ausgeführt werden
    - Einprozessorsystem: totale Ordnung
    - Mehrprozessorsystem: parallele Ausführung einiger Operationen möglich ➥ partielle Ordnung

- **Konfliktoperationen:**

  Kritisch sind Operationen verschiedener Transaktionen
  auf **denselben DB-Daten,**
  wenn diese Operationen **nicht reihenfolgeunabhängig** sind!

- **Was sind Konfliktoperationen?**
  - $r_i(A)$ und $r_j(A)$: Reihenfolge ist irrelevant

    ➥ **kein Konflikt!**

  - $r_i(A)$ und $w_j(A)$: Reihenfolge ist relevant und festzulegen.

    Entweder $r_i(A) \rightarrow w_j(A)$

    ➥ **R/W-Konflikt!**

    oder $w_j(A) \rightarrow r_i(A)$

    ➥ **W/R-Konflikt!**

  - $w_i(A)$ und $r_j(A)$: analog

  - $w_i(A)$ und $w_j(A)$: Reihenfolge ist relevant und festzulegen

    ➥ **W/W-Konflikt!**

Theorie der Serialisierbarkeit (3)

- **Beschränkung auf Konflikt-Serialisierbarkeit[1]**

- **Historie H für eine Menge von TA {T1, ..., Tn}**
  ist eine Menge von Elementaroperationen mit partieller Ordnung $<_H$,
  so daß gilt:

  1. $H = \bigcup_{i=1}^{n} T_i$

  2. $<_H$ ist verträglich mit allen $<_i$-Ordnungen, d.h.

     $<_H \supseteq \bigcup_{i=1}^{n} <_i$

  3. Für zwei Konfliktoperationen $p, q \in H$ gilt entweder
     $p <_H q$

     oder

     $q <_H p$

---

1. In der Literatur werden verschiedene Formen der Serialisierbarkeit, also der Äquivalenz zu einer seriellen Historie, definiert. Die **Final-State-Serialisierbarkeit** (FSR) besitzt die geringsten Einschränkungen. Intuitiv sind zwei Historien (mit der gleichen Menge von Operationen) final-state-äquivalent, wenn sie jeweils denselben Endzustand für einen gegebenen Anfangszustand herstellen. Die **View-Serialisierbarkeit** (VSR) schränkt FSR weiter ein. Die hier behandelte **Konflikt-Serialisierbarkeit** (CSR) ist für praktische Anwendungen die wichtigste. Sie ist effizient überprüfbar und unterscheidet sich bereits dadurch wesentlich von den beiden anderen Serialisierbarkeitsbegriffen.
   Es gilt: CSR $\subset$ VSR $\subset$ FSR

Theorie der Serialisierbarkeit (4)

- **Beispiel-Historie für 3 TA**

$$
\begin{array}{llllllll}
 & & r_2(A) & \rightarrow & w_2(B) & \rightarrow & w_2(C) & \rightarrow & c_2 \\
 & & \uparrow & & \uparrow & & \uparrow & & \\
H = & r_3(B) & \rightarrow & w_3(A) & \rightarrow & w_3(B) & \rightarrow & w_3(C) & \rightarrow & c_3 \\
 & & \uparrow & & & & & & \\
 & r_1(A) & \rightarrow & w_1(A) & \rightarrow & c_1 & & & &
\end{array}
$$

- Reihenfolge konfliktfreier Operationen (zwischen TA) wird nicht spezifiziert

- Mögliche totale Ordnung[1]

$$H_1 = r_1(A) \rightarrow r_3(B) \rightarrow w_1(A) \rightarrow w_3(A) \rightarrow c_1 \rightarrow r_2(A) \rightarrow w_3(B) \rightarrow$$

$$w_3(C) \rightarrow c_3 \rightarrow w_2(B) \rightarrow w_2(C) \rightarrow c_2$$

1. Alternative Schreibweise bei einer totalen Ordnung: Weglassen der $\rightarrow$

Theorie der Serialisierbarkeit (5)

- **Äquivalenz zweier Historien**
  - Zwei Historien H und H' sind äquivalent, wenn sie die Konfliktoperationen der nicht abgebrochenen TA in derselben Reihenfolge ausführen:

    $H \equiv H'$, wenn $p_i <_H q_j$, dann auch $p_i <_{H'} q_j$

  - **Anordnung** der **konfliktfreien** Operationen ist **irrelevant**
  - **Reihenfolge** der Operationen **innerhalb** einer TA bleibt **invariant**

- **Beispiel**

$$
\begin{array}{lccccccc}
 & & & r_2(A) & \rightarrow & w_2(B) & \rightarrow & c_2 \\
 & & & \uparrow & & \uparrow & & \\
H = & r_1(A) & \rightarrow & w_1(A) & \rightarrow & w_1(B) & \rightarrow & c_1
\end{array}
$$

  - Totale Ordnung

$H_1 = r_1(A) \rightarrow w_1(A) \rightarrow r_2(A) \rightarrow w_1(B) \rightarrow c_1 \rightarrow w_2(B) \rightarrow c_2$

$H2 = r_1(A) \rightarrow w_1(A) \rightarrow w_1(B) \rightarrow c_1 \rightarrow r_2(A) \rightarrow w_2(B) \rightarrow c_2$

$H1 \equiv H_2$ (ist seriell)

Serialisierbare Historie

- **Eine Historie H ist serialisierbar, wenn sie äquivalent zu einer seriellen Historie H_s ist**

  - Einführung eines Serialisierbarkeitsgraphen SG(H)
    - Konstruktion des SG(H) über den erfolgreich abgeschlossenen TA
    - Konfliktoperationen p_i, q_j aus H mit $p_i <_H q_j$ fügen eine Kante $T_i \rightarrow T_j$ in SG(H) ein, falls nicht schon vorhanden

  - Beispiel-Historie

$$
H = \begin{array}{ccccccc}
r_1(A) & \rightarrow & w_1(A) & \rightarrow & w_1(B) & \rightarrow & c_1 \\
 & & \uparrow & & \uparrow & & \\
 & & r_2(A) & \rightarrow & w_2(B) & \rightarrow & c_2 \\
 & & \downarrow & & & & \\
r_3(A) & \rightarrow & w_3(A) & \rightarrow & c_3 & &
\end{array}
$$

  - Zugehöriger Serialisierbarkeitsgraph

    SG(H):

- **Serialisierbarkeitstheorem**
  Eine Historie H ist genau dann serialisierbar, wenn der zugehörige SG(H) azyklisch ist

  ➥ **Topologische Sortierung!**

Serialisierbare Historie (2)

- **Historie**

  H =

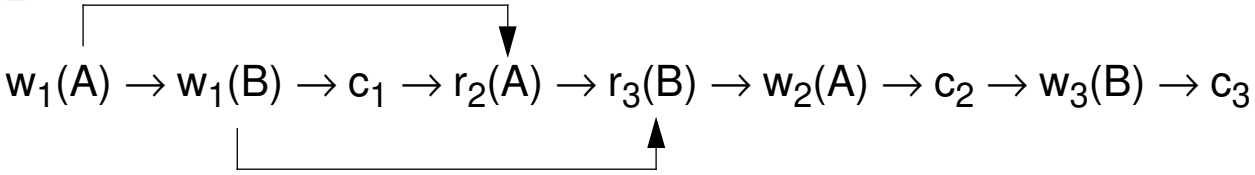

- **Serialisierbarkeitsgraph**

  SG(H) :

- **Topologische Ordnungen**

  $H_s^1 = w_1(A) \rightarrow w_1(B) \rightarrow c_1 \rightarrow r_2(A) \rightarrow w_2(A) \rightarrow c_2 \rightarrow r_3(B) \rightarrow w_3(B) \rightarrow c_3$

  $H_s^1 = T1 \mid T2 \mid T3$

  $H_s^2 = w_1(A) \rightarrow w_1(B) \rightarrow c_1 \rightarrow r_3(B) \rightarrow w_3(B) \rightarrow c_3 \rightarrow r_2(A) \rightarrow w_2(A) \rightarrow c_2$

  $H_s^2 = T1 \mid T3 \mid T2$

  $H \equiv H_s^1 \equiv H_s^2$

Serialisierbare Historie (3)

- **Anforderungen an im DBMS zugelassene Historien (Schedules)**
  - Serialisierbarkeit ist eine Minimalanforderung
  - TA T_j sollte zu jedem Zeitpunkt vor Commit lokal rücksetzbar sein
    - andere mit Commit abgeschlossene T_i dürfen nicht betroffen sein
    - kritisch sind Schreib-/Leseabhängigkeiten
      $w_j(A) \rightarrow ... \rightarrow r_i(A)$

- **Serialisierbarkeitstheorie:**
  Gebräuchliche Klassenbeziehungen[1]
  - SR: serialisierbare Historien
  - RC: rücksetzbare Historien
  - ACA: Historien ohne kaskadierendes Rücksetzen
  - ST: strikte Historien

1. Weikum, G., Vossen, G.: Transactional Information Systems, Morgan Kaufmann, 2001, unterscheidet unter Berücksichtigung von VSR und FSR 10 Klassen von serialisierbaren Historien.

Rücksetzbare Historie

- **T_i liest von T_j in H, wenn gilt**

  1. T_j schreibt mindestens ein Datum A, das T_i nachfolgend liest:

     $w_j(A) <_H r_i(A)$

  2. T_j wird (zumindest) nicht vor dem Lesevorgang von T_i zurückgesetzt:

     $a_j </_H r_i(A)$

  3. Alle anderen zwischenzeitlichen Schreibvorgänge auf A durch andere TA T_k werden vor dem Lesen durch T_i zurückgesetzt.

     Falls

     $w_j(A) <_H w_k(A) <_H r_i(A)$,

     muß auch

     $a_k <_H r_i(A)$ gelten.

     $H = ... w_j(A) \rightarrow ... \rightarrow w_k(A) \rightarrow ... a_k \rightarrow ... \rightarrow r_i(A)$

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

  $c_j <_H c_i$

  $H = ... w_j(A) \rightarrow r_i(A) \rightarrow w_i(B) \rightarrow c_j \rightarrow ... \rightarrow a_i\ (c_i)$

Historie ohne kaskadierendes Rücksetzen

- **Kaskadierendes Rücksetzen**

Schritt	T1	T2	T3	T4	T5
0.	. . .				
1.	$w_1(A)$				
2.		$r_2(A)$			
3.		$w_2(B)$			
4.			$r_3(B)$		
5.			$w_3(C)$		
6.				$r_4(C)$	
7.				$w_4(D)$	
8.					$r_5(D)$
9.	a_1 (**abort**)				

➥ **In der Theorie ist ACID garantierbar! Aber . . .**

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

$$c_j <_H r_i(A)$$

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

➥ **Änderungen dürfen erst nach Commit freigegeben werden**

Klassen von Historien

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

  Wenn

  $w_j(A) <_H o_i(A)$ (mit $o_i = r_i$ oder $o_i = w_i$),

  dann muß gelten:

  $c_j <_H o_i(A)$ oder $a_j <_H o_i(A)$

- **Beziehungen zwischen den Klassen**

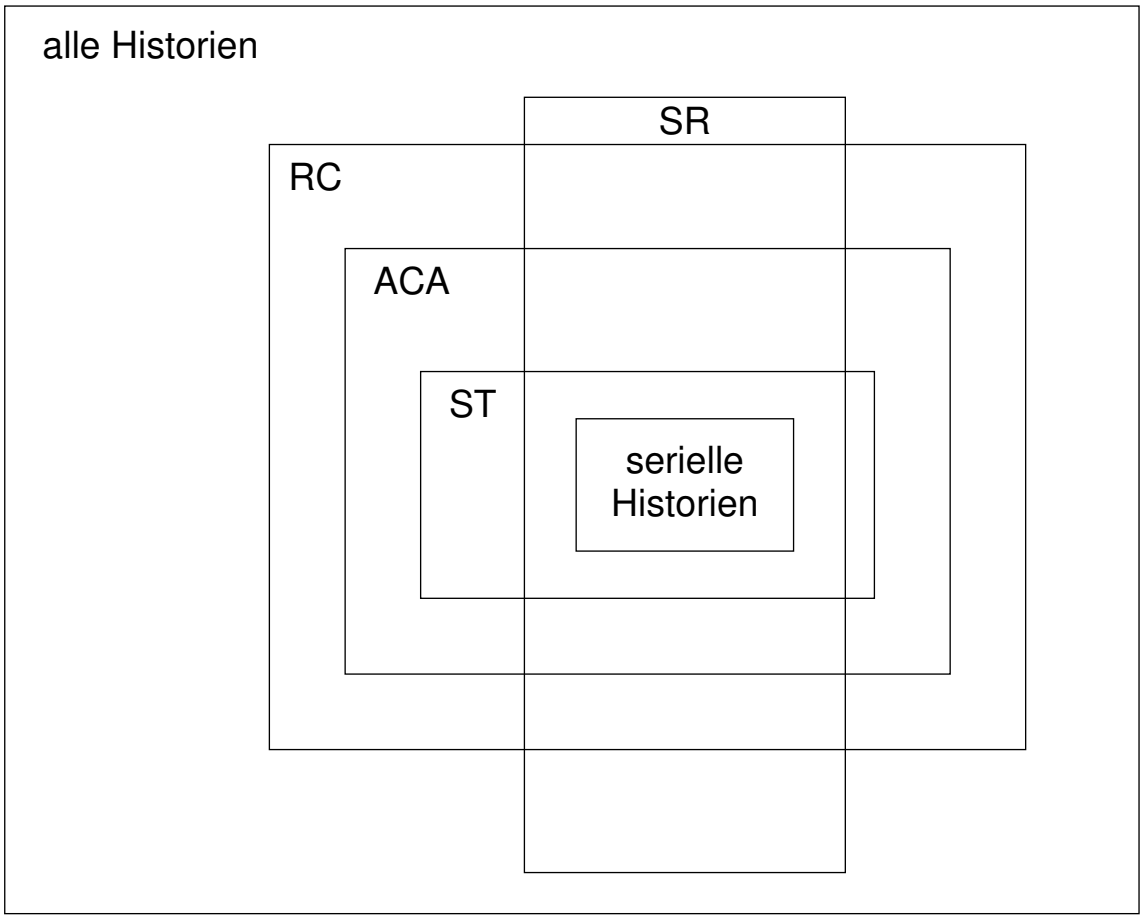

➥ **Schlußfolgerungen?**

Klassen von Historien (2)

- **Beispiele**

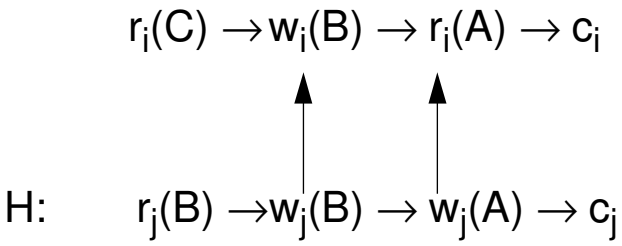

H_{SR}: $r_i(C) \rightarrow r_j(B) \rightarrow w_j(B) \rightarrow w_i(B) \rightarrow w_j(A) \rightarrow r_i(A) \rightarrow c_i \rightarrow c_j$

H_{RC}: $r_i(C) \rightarrow r_j(B) \rightarrow w_j(B) \rightarrow w_i(B) \rightarrow w_j(A) \rightarrow r_i(A) \rightarrow c_j \rightarrow c_i$

H_{ACA}: $r_i(C) \rightarrow r_j(B) \rightarrow w_j(B) \rightarrow w_i(B) \rightarrow w_j(A) \rightarrow c_j \rightarrow r_i(A) \rightarrow c_i$

H_{ST}: $r_i(C) \rightarrow r_j(B) \rightarrow w_j(B) \rightarrow w_j(A) \rightarrow c_j \rightarrow w_i(B) \rightarrow r_i(A) \rightarrow c_i$

H_S: $r_j(B) \rightarrow w_j(B) \rightarrow w_j(A) \rightarrow c_j \rightarrow r_i(C) \rightarrow w_i(B) \rightarrow r_i(A) \rightarrow c_i$

Einbettung des DB-Schedulers

- **Stark vereinfachtes Modell**

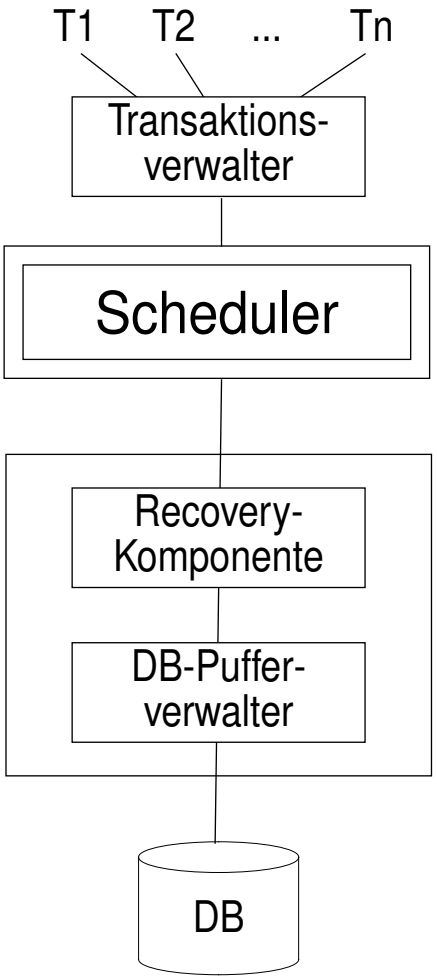

- **Welche Aufgaben hat der Scheduler?**
  - als Komponente der Transaktionsverwaltung zuständig für **I** von **ACID**
  - kontrolliert die beim TA-Ablauf auftretenden Konfliktoperationen (R/W, W/R, W/W) und garantiert insbesondere, daß nur „serialisierbare“ TA erfolgreich beendet werden
  - Nicht serialisierbare TA müssen verhindert werden.
    Dazu ist eine Kooperation mit der Recovery-Komponente erforderlich (Rücksetzen von TA)

  ➥ **garantiert „vernünftige” Schedules:**

Synchronisationsverfahren

- **Zur Realisierung der Synchronisation gibt es viele Verfahren**
  - **Pessimistische Verfahren:** Bei einer Konfliktoperation blockieren sie den Zugriff auf das Objekt.
  - **Optimistische Verfahren:** Erst bei Commit wird überprüft, ob die TA serialisierbar ist
  - **Versionsverfahren:** Keine Behinderung der Leser durch Schreiber
  - **Zeitstempelverfahren:** Überprüfung der Serialisierbarkeit am Objekt
  - **Prädikatssperren:** Es wird die Menge der möglichen Objekte, die das Prädikat erfüllen, gesperrt
  - **Spezielle Synchronisationsverfahren:** Nutzung der Semantik von Änderungen
  - . . .

  ➥ **Sperrverfahren sind pessimistisch und universell einsetzbar.**

- **Sperrbasierte Synchronisation**
  - Sperren stellen während des laufenden Betriebs sicher, daß die resultierende Historie serialisierbar bleibt
  - Es gibt mehrere Varianten

Historische Entwicklung von Synchronisationsverfahren

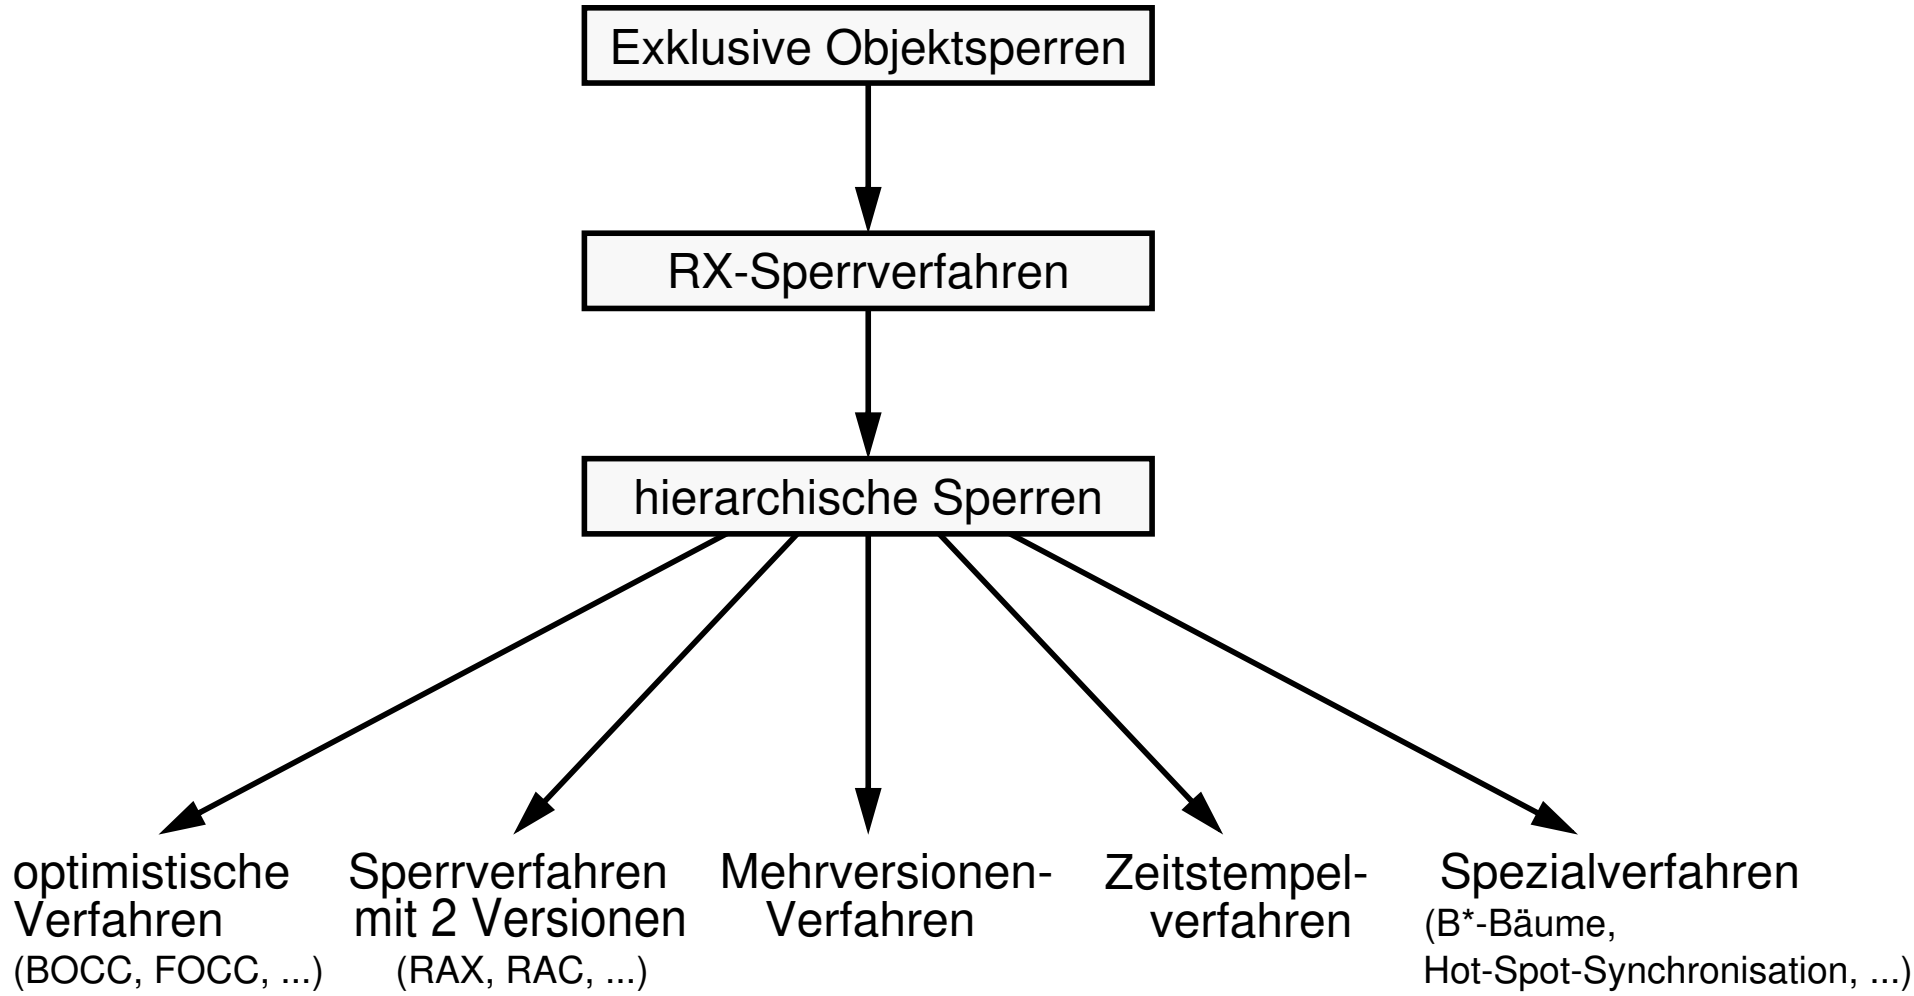

RX-Sperrverfahren

- **Sperrmodi**
  - Sperrmodus des Objektes: NL (no lock), R (read), X (exclusive)
  - Sperranforderung einer Transaktion: R, X
- **Kompatibilitätsmatrix:**

angeforderter Modus der TA \ aktueller Modus des Objekts	NL	R	X
R	+	+	-
X	+	-	-

  - Falls Sperre nicht gewährt werden kann, muß die anfordernde TA warten, bis das Objekt freigegeben wird (Commit/Abort der die Sperre besitzenden TA)
  - Wartebeziehungen werden in einem Wait-for-Graph (WfG) verwaltet

- **Ablauf von Transaktionen**

T1	T2	a	b	Bem.
		NL	NL	
lock (a, X)		X		
. . .				
	lock (b, R)		R	
	. . .			
lock (b, R)			R	
	lock (a, R)	X		T2 wartet, WfG:
. . .				
unlock (a)		NL --> R		T2 wecken
. . .	. . .			
unlock(b)			R	

Zweiphasen-Sperrprotokolle[1]

- **Einhaltung folgender Regeln gewährleistet Serialisierbarkeit:**
  1. Vor jedem Objektzugriff muß Sperre mit ausreichendem Modus angefordert werden
  2. Gesetzte Sperren anderer TA sind zu beachten
  3. Eine TA darf nicht mehrere Sperren für ein Objekt anfordern
  4. ***Zweiphasigkeit:***
     - Anfordern von Sperren erfolgt in einer *Wachstumsphase*
     - Freigabe der Sperren in *Schrumpfungsphase*
     - Sperrfreigabe kann erst beginnen, wenn alle benötigten Sperren gehalten werden
  5. Spätestens bei Commit sind alle Sperren freizugeben

- **Beispiel für ein 2PL-Protokoll** (2PL: two-phase locking)

BOT
lock (a, X)
. . .
lock (b, R)
. . .
lock (c, X)
. . .
unlock (b)
unlock (c)
unlock (a)
Commit

An der SQL-Schnittstelle ist die Sperranforderung und -freigabe nicht sichtbar!

1. Eswaran, K.P. et al.: The notions of consistency and predicate locks in a data base system, in: Comm. ACM 19:11, 1976, 624-633

Zweiphasen-Sperrprotokolle (2)

- **Formen der Zweiphasigkeit**

Sperranforderung und -freigabe

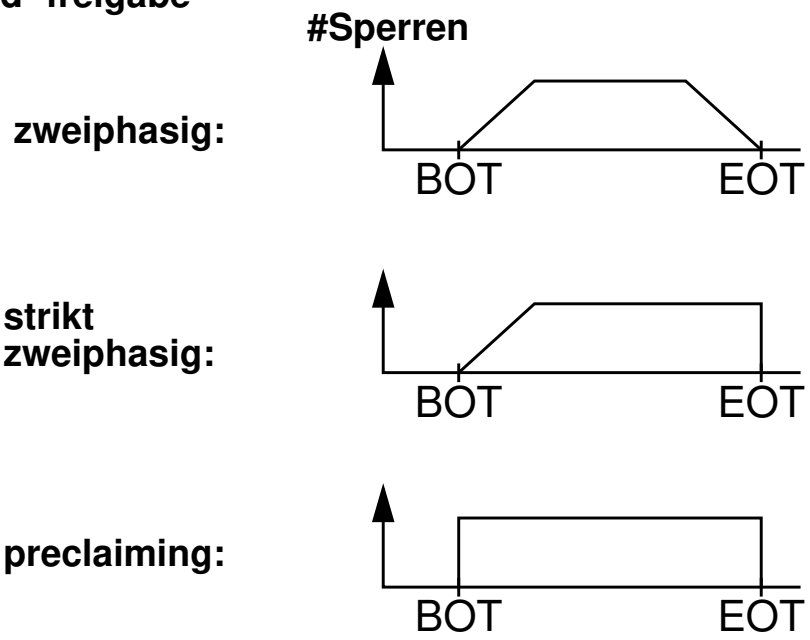

- **Anwendung des 2PL-Protokolls**

T1	T2	Bem.
BOT		
lock (a, X)		
read (a)		
write (a)		
	BOT	
	lock (a, X)	T2 wartet: WfG
lock (b, X)		
read (b)		
unlock (a)		T2 wecken
	read (a)	
	write (a)	
	unlock (a)	
	commit	
unlock (b)		

➥ Praktischer Einsatz erfordert **striktes 2PL-Protokoll**!

Verklemmungen (Deadlocks)

- **Striktes 2PL-Protokoll**
  - gibt alle Sperren erst bei Commit frei und
  - verhindert dadurch kaskadierendes Rücksetzen

➥ Auftreten von Verklemmungen ist **inhärent** und kann bei pessimistischen Methoden (blockierende Verfahren) nicht vermieden werden.

- **Nicht-serialisierbare Historie**

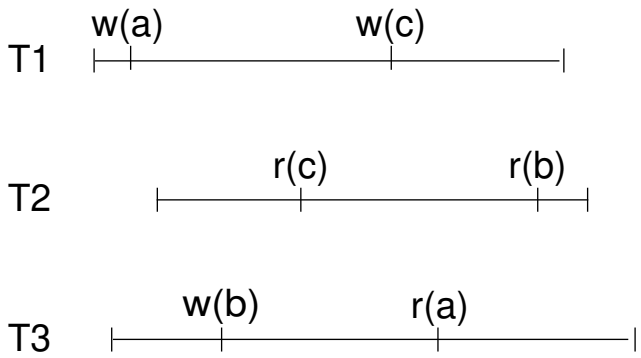

SG

- **RX-Verfahren verhindert** das Auftreten einer nicht-serialisierbaren Historie, **aber nicht (immer) Deadlocks**

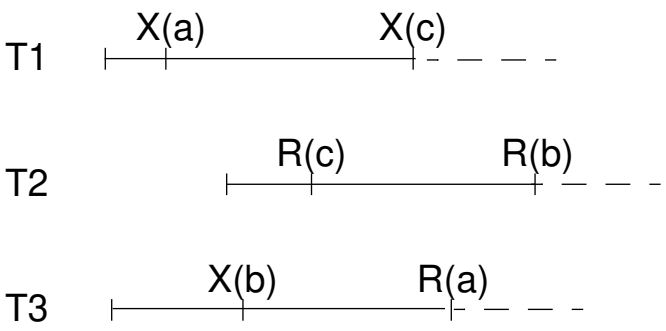

WfG

RUX-Sperrverfahren

- **Forderung**
  - Wahl des gemäß der Operation schwächst möglichen Sperrmodus
  - Möglichkeit der Sperrkonversion (upgrading), falls stärkerer Sperrmodus erforderlich
  - Anwendung: viele Objekte sind zu lesen, aber nur wenige zu aktualisieren

- **Problem: Sperrkonversionen**

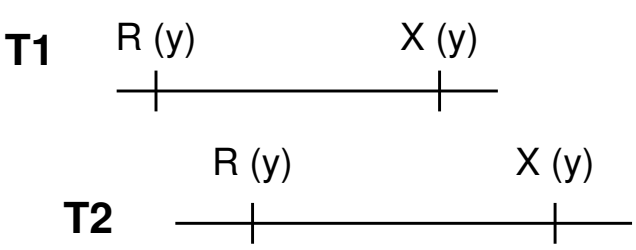

- **Erweitertes Sperrverfahren:**
  - Ziel: Verhinderung von Konversions-Deadlocks
  - U-Sperre für Lesen mit Änderungsabsicht (Prüfmodus)
  - bei Änderung Konversion U → X, andernfalls U → R (downgrading)

- **Wirkungsweise**

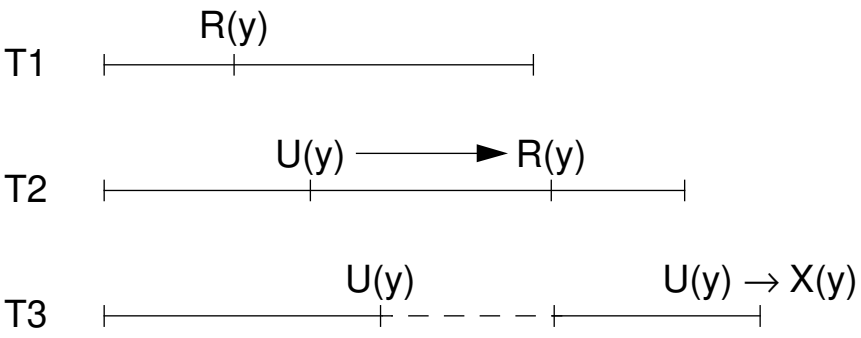

RUX-Sperrverfahren (2)

- **Symmetrische Variante**
  - Was bewirkt eine Symmetrie bei U?

	R	U	X
R	+	+	-
U	+	-	-
X	-	-	-

- **Beispiel**

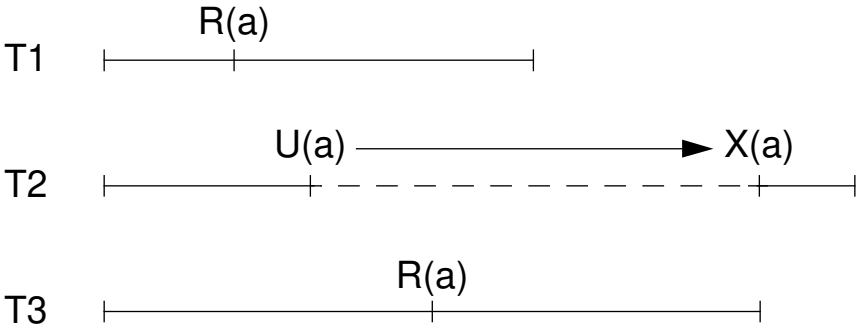

- **Unsymmetrie bei U**

	R	U	X
R	+	-	-
U	+	-	-
X	-	-	-

  - u. a. in DB2 eingesetzt

- **Beispiel**

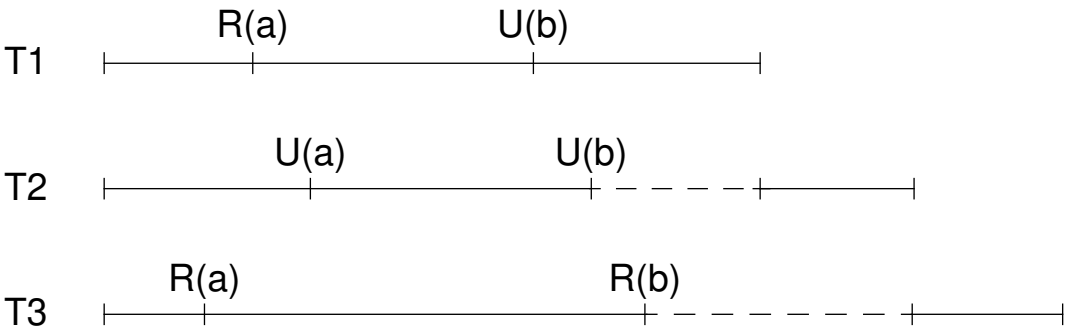

Hierarchische Sperrverfahren

- **Sperrgranulat bestimmt Parallelität/Aufwand:**

  Feines Granulat reduziert Sperrkonflikte, jedoch sind viele Sperren anzufordern und zu verwalten

- **Hierarchische Verfahren erlauben Flexibilität bei Wahl des Granulates ('multigranularity locking'), z. B. Synchronisation**
  - langer TA auf Tabellenebene
  - kurzer TA auf Zeilenebene

- Kommerzielle DBS unterstützen zumeist mindestens 2-stufige Objekthierarchie, z. B.

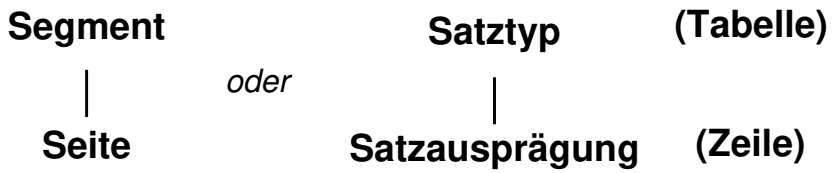

- Verfahren nicht auf reine Hierarchien beschränkt, sondern auch auf halbgeordnete Objektmengen erweiterbar (siehe auch objektorientierte DBS).

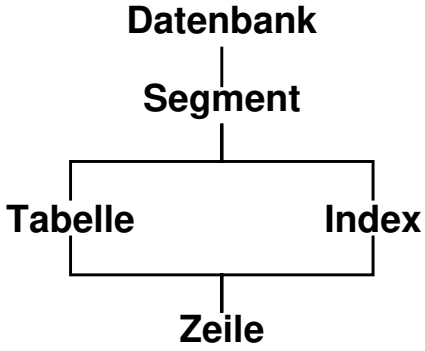

- Verfahren erheblich komplexer als einfache Sperrverfahren (mehr Sperrmodi, Konversionen, Deadlock-Behandlung, ...)

Beispiel einer Sperrhierarchie

Datenbank

Dateien (Segmente)

Satztypen (Tabellen)

Sätze (Zeilen)

Wieviel Aufwand zum Sperren von

- 1 Satz
- k Sätzen
- 1 Satztyp

Hierarchische Sperrverfahren: Anwartschaftssperren

- **Mit R- und X-Sperre werden alle Nachfolgerknoten implizit mitgesperrt**

  ➥ Einsparungen möglich

- **Alle Vorgängerknoten sind ebenfalls zu sperren, um Unverträglichkeiten zu vermeiden**

  ➥ Verwendung von Anwartschaftssperren ('intention locks')

- **Allgemeine Anwartschaftssperre (I-Sperre)**

	I	R	X
I	+	-	-
R	-	+	-
X	-	-	-

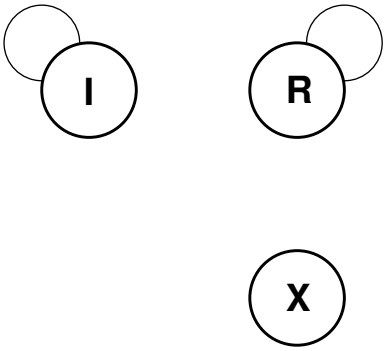

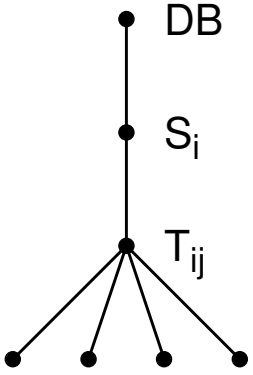

- Unverträglichkeit von I- und R-Sperren: zu restriktiv!

  ➥ zwei Arten von Anwartschaftssperren (IR und IX)

Anwartschaftssperren (2)

- **Anwartschaftssperren für Leser und Schreiber**

	IR	IX	R	X
IR	+	+	+	-
IX	+	+	-	-
R	+	-	+	-
X	-	-	-	-

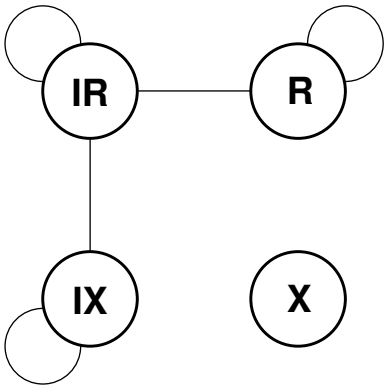

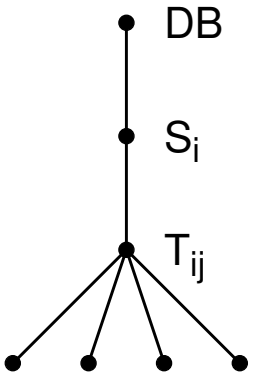

- IR-Sperre (intent read), falls auf untergeordneten Objekten nur lesend zugegriffen wird, sonst IX-Sperre

- Weitere Verfeinerung sinnvoll, um den Fall zu unterstützen, wo alle Sätze eines Satztyps gelesen und nur einige davon geändert werden sollen
  - X-Sperre auf Satztyp sehr restriktiv
  - IX-Sperre auf Satztyp verlangt Sperren jedes Satzes

  ➥ neuer Typ von Anwartschaftssperre: **RIX = R + IX**
  - sperrt das Objekt in R-Modus und verlangt
  - X-Sperren auf tieferer Hierarchieebene nur für zu ändernde Objekte

Anwartschaftssperren (3)

- **Vollständiges Protokoll der Anwartschaftssperren**
  - RIX gibt ein Leserecht auf den Knoten und seine Nachfolger. Weiterhin ist damit das Recht verbunden, auf Nachfolger-Knoten IX, U und X-Sperren anzufordern.
  - U gewährt ein Leserecht auf den Knoten und seine Nachfolger. Dieser Modus repräsentiert die Absicht, den Knoten in der Zukunft zu verändern. Bei Änderung Konversion U $\rightarrow$ X, sonst U $\rightarrow$ R.

	IR	IX	R	RIX	U	X
IR	+	+	+	+	-	-
IX	+	+	-	-	-	-
R	+	-	+	-	-	-
RIX	+	-	-	-	-	-
U	-	-	+	-	-	-
X	-	-	-	-	-	-

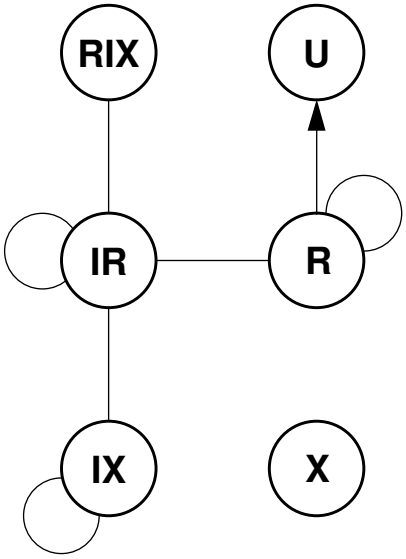

- **'Sperrdisziplin' erforderlich**
  - Sperranforderungen von der Wurzel zu den Blättern
  - Bevor T eine R- oder IR-Sperre für einen Knoten anfordert, muß sie für alle Vorgängerknoten IX- oder IR-Sperren besitzen
  - Bei einer X-, U-, RIX- oder IX-Anforderung müssen alle Vorgängerknoten in RIX oder IX gehalten werden
  - Sperrfreigaben von den Blättern zu der Wurzel
  - Bei EOT sind alle Sperren freizugeben

Hierarchische Sperrverfahren: Beispiele

- **IR- und IX-Modus**
  - TA1 liest t_1 in T1
  - a) TA2 ändert Zeile in T2
  - b) TA3 liest T1

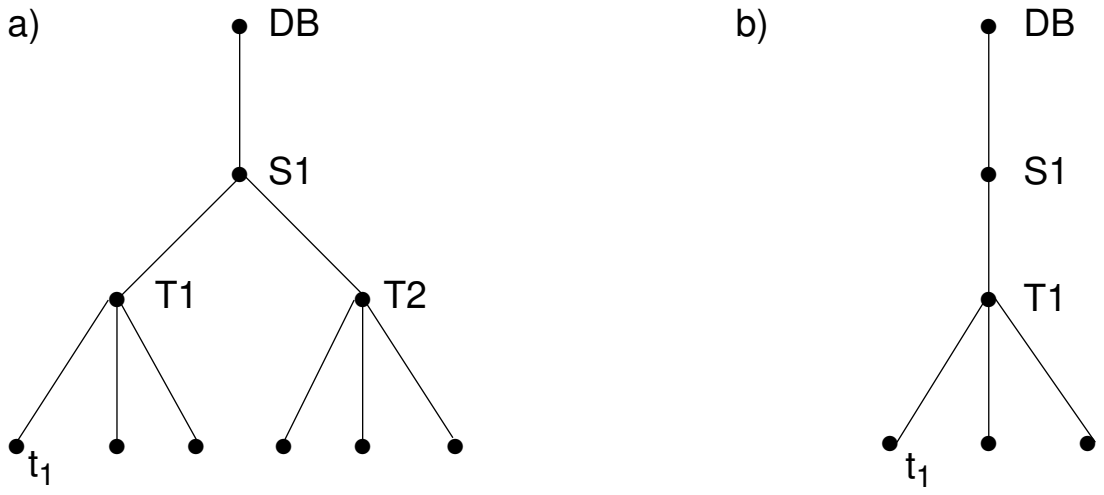

- **RIX-Modus**
  - TA1 liest alle Zeilen von T1 und ändert t_3
  - a) TA2 liest T1
  - b) TA3 liest t_2 in T1

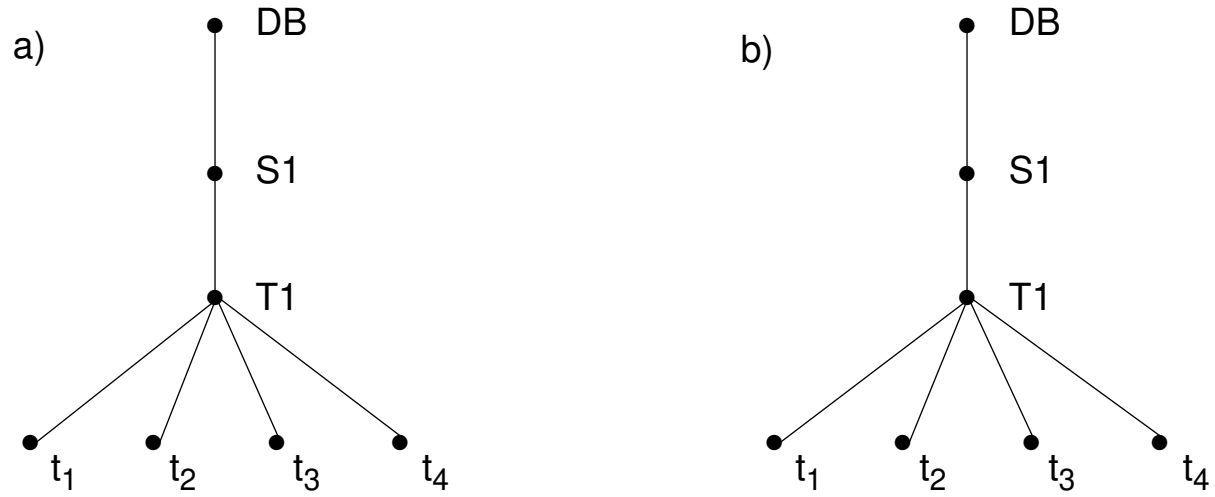

Hierarchische Sperren in OODBS

- **Übertragung der Idee hierarchischer Sperren auf Klassenhierarchie**
  - Einsatz von Anwartschaftssperren
  - Reduktion des Sperraufwandes innerhalb von Generalisierungs- und Aggregationshierarchien

- **Generalisierungshierarchie**

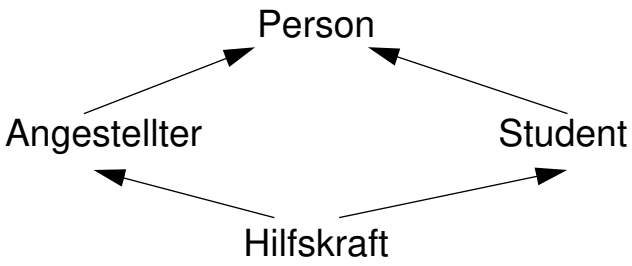

  ➥ **Probleme durch Mehrfachvererbung**

- **Aggregationshierarchie**

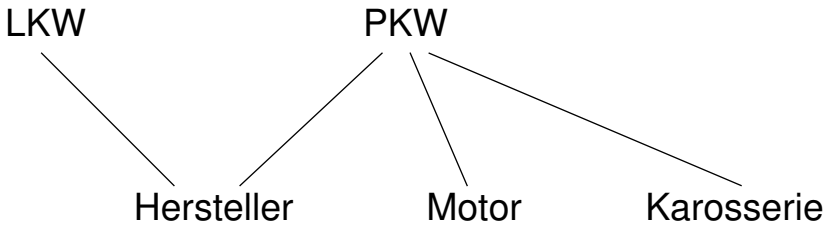

  ➥ **Probleme durch gemeinsam genutzte Komponentenobjekte**

  - Explizites Sperren aller Teilobjekte sehr aufwendig!

Deadlock-Behandlung

- **Voraussetzungen für Deadlock:**

1. paralleler Zugriff
2. exklusive Zugriffsanforderungen
3. anfordernde TA besitzt bereits Objekte/Sperren
4. keine vorzeitige Freigabe von Objekten/Sperren
   (non-preemption)
5. zyklische Wartebeziehung zwischen zwei oder mehr TA

- **Lösungsmöglichkeiten:**

1. Timeout-Verfahren

- TA wird nach festgelegter Wartezeit auf Sperre zurückgesetzt
- problematische Bestimmung des Timeout-Wertes

2. Deadlock-Verhütung *(Prevention)*

- *keine Laufzeitunterstützung* zur Deadlock-Behandlung erforderlich
- Beispiel: *Preclaiming* (in DBS i. allg. nicht praktikabel)

3. Deadlock-Vermeidung *(Avoidance)*

- Potentielle Deadlocks werden im voraus erkannt und durch entsprechende Maßnahmen vermieden

  $\Rightarrow$ *Laufzeitunterstützung nötig*

4. Deadlock-Erkennung *(Detection)*

Deadlock-Erkennung

- Explizites Führen eines **Wartegraphen** *(wait-for graph)* und **Zyklensuche** zur Erkennung von Verklemmungen

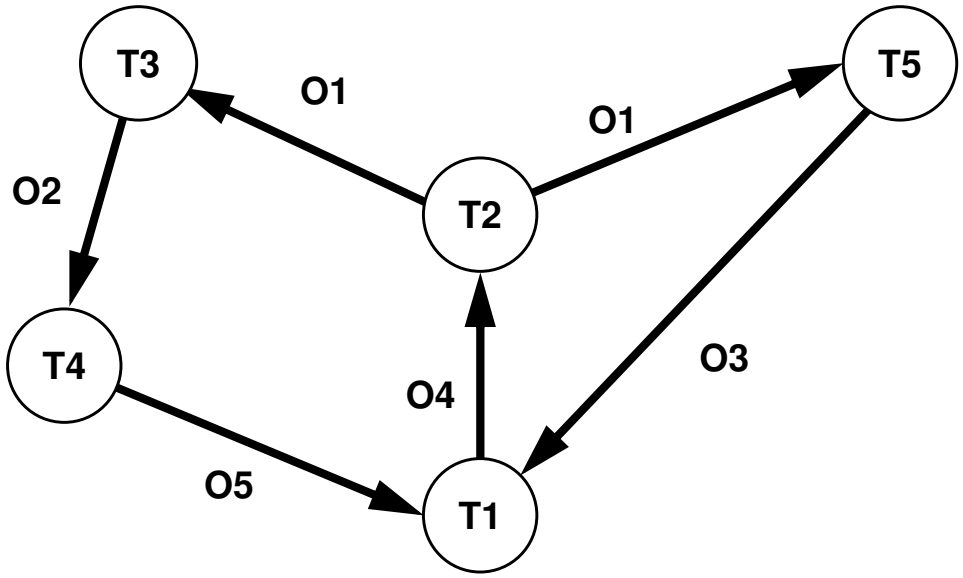

- **Deadlock-Auflösung** durch Zurücksetzen einer oder mehrerer am Zyklus beteiligter TA

  (z. B. Verursacher oder „billigste" TA zurücksetzen)

- **Zyklensuche** entweder
  - bei jedem Sperrkonflikt bzw.
  - verzögert (z. B. über Timeout gesteuert)

Sperrverfahren in Datenbanksystemen

- **Aufgabe von Sperrverfahren:** Vermeidung von Anomalien, indem man
  - zu ändernde Objekte dem Zugriff aller anderen Transaktionen entzieht
  - zu lesende Objekte vor Änderungen schützt

- **Standardverfahren:** Hierarchisches Zweiphasen-Sperrprotokoll
  - mehrere Sperrgranulate
  - Verringerung der Anzahl der Sperranforderungen

- **Häufig beobachtete Probleme** bei Sperren
  - Zweiphasigkeit führt häufig zu langen Wartezeiten (starke Serialisierung)
  - **Um Durchsatzziel zu erreichen:**
    mehr aktive TA → mehr gesperrte Objekte → höhere Konflikt-WS → längere Sperrwartezeiten, höhere Deadlock-Raten → **noch mehr** aktive TA
  - Häufig berührte Objekte können zu Engpässen („hot spots") werden
  - Eigenschaften des Schemas können „high-traffic objects" erzeugen

- **Einführung von Konsistenzebenen**
  zur Reduktion des Blockierungspotentials: Programmierdisziplin gefordert!

- **Optimierungen!?**
  - Optimistische Verfahren: Verzicht auf Sperren, dafür Validierung
  - Änderungen auf privaten Objektkopien (verkürzte Dauer exklusiver Sperren)
  - Nutzung mehrerer Objektversionen
  - Zeitstempelverfahren (lokale Prüfung, vor allem im verteilten Fall)
  - Prädikatssperren, Präzisionssperren
  - spezialisierte Sperren

Konsistenzebenen

- **Serialisierbare Abläufe**
  - gewährleisten „automatisch“ Korrektheit des Mehrbenutzerbetriebs
  - erzwingen u. U. lange Blockierungszeiten paralleler Transaktionen
  - „Schwächere“ Konsistenzebene bei der Synchronisation von Leseoperationen erlaubt höhere Parallelitätsgrade und Reduktion von Blockierungen, erfordert aber Programmierdisziplin!

    ➥ **Inkaufnahme von Anomalien reduziert die TA-Behinderungen**

- **Konsistenzebenen** (basierend auf verkürzte Sperrdauern)

Ebene 3: Transaktion T sieht Konsistenzebene 3, wenn gilt:

a) T verändert keine schmutzigen Daten anderer Transaktionen

b) T gibt keine Änderungen vor EOT frei

c) T liest keine schmutzigen Daten anderer Transaktionen

d) Von T gelesene Daten werden durch andere Transaktionen erst nach EOT von T verändert

Ebene 2: Transaktion T sieht Konsistenzebene 2, wenn sie die Bedingungen a, b und c erfüllt

Ebene 1: Transaktion T sieht Konsistenzebene 1, wenn sie die Bedingungen a und b erfüllt

Ebene 0: Transaktion T sieht Konsistenzebene 0, wenn sie nur Bedingung a erfüllt

Konsistenzebenen (2)

- **RX-Sperrverfahren und Konsistenzebenen:**
  (Beispiele für nur ein Objekt O)

KE0: kurze X, keine R

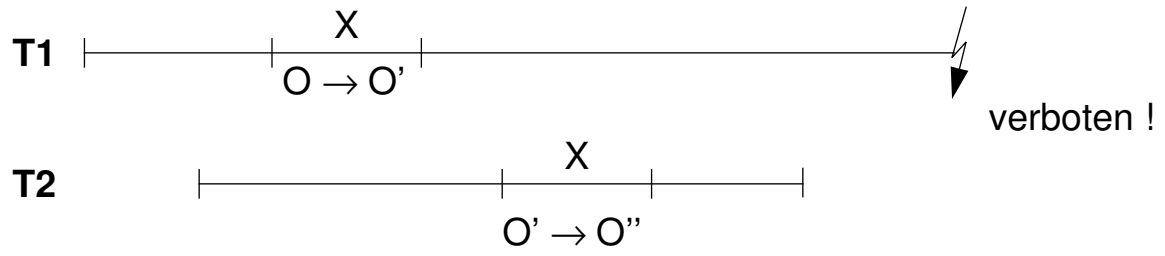

KE1: lange X, keine R

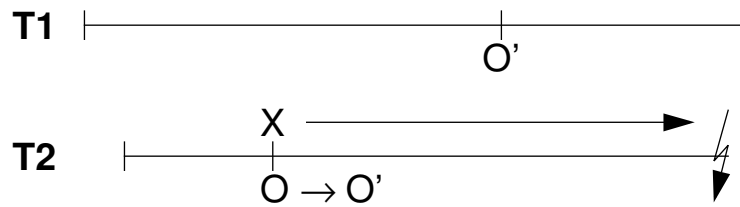

KE2: lange X, kurze R

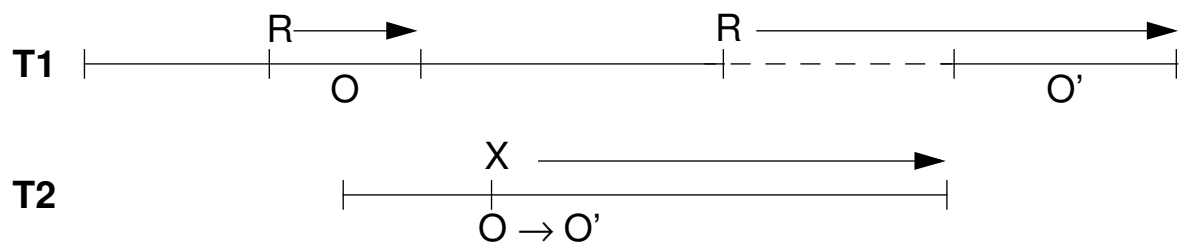

KE3: lange X, lange R

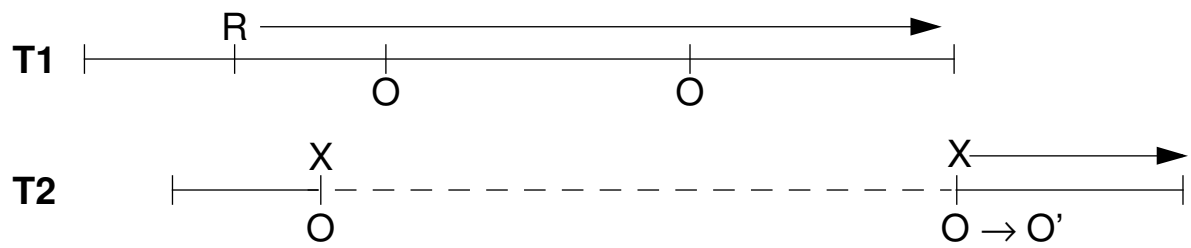

Konsistenzebenen (3)

- ***Konsistenzebene 3*** (eigentlich KE 2,99)**:**
  - wünschenswert, jedoch oft viele Sperrkonflikte wegen langer Schreib- und Lesesperren

- ***Konsistenzebene 2:***
  - nur lange Schreibsperren, jedoch kurze Lesesperren
  - *'unrepeatable read'* möglich

- ***Konsistenzebene 1:***
  - lange Schreibsperren, keine Lesesperren
  - *'dirty read'* (und 'lost update') möglich

- ***Konsistenzebene 0:***
  - kurze Schreibsperren ('Chaos')

  ➥ Kommerzielle DBS empfehlen meist Konsistenzebene 2

- **Wahlangebot**

  Einige DBS (DB2, Tandem NonStop SQL, ...) bieten Wahlmöglichkeit zwischen:
  - 'repeatable read' (KE 3) und
  - 'cursor stability' (KE 2)

  Einige DBS bieten auch *BROWSE-Funktion*,
  d. h. Lesen ohne Setzen von Sperren (KE 1)

Konsistenzebenen (4)

- SQL erlaubt Wahl zwischen **vier Konsistenzebenen** (Isolation Level)
- **Konsistenzebenen sind durch die Anomalien bestimmt,** die jeweils in Kauf genommen werden:
  - Abgeschwächte Konsistenzanforderungen betreffen nur Leseoperationen!
  - **Lost Update** muß generell vermieden werden, d. h., W/W-Abhängigkeiten müssen stets beachtet werden

Konsistenz-ebene	**Anomalie**		
	Dirty Read	Non-Repeatable Read	Phantome
Read Uncommitted	**+**	**+**	**+**
Read Committed	**-**	**+**	**+**
Repeatable Read	**-**	**-**	**+**
Serializable	**-**	**-**	**-**

  - Default ist **Serialisierbarkeit** (serializable)

Konsistenzebenen (5)

- **SQL-Anweisung zum Setzen der Konsistenzebene:**

```
SET TRANSACTION  [mode] [ISOLATION LEVEL level]
```

  - Transaktionsmodus: READ WRITE (Default) bzw. READ ONLY
  - **Beispiel:**
    SET TRANSACTION READ ONLY, ISOLATION LEVEL READ COMMITTED
  - READ UNCOMMITTED für Änderungstransaktionen unzulässig

- **Was ist der Unterschied zwischen KE3 und “Serializable”?**
  - **Repeatable Read**
    Sperren von vorhandenen Objekten

  - **Serializable**
    garantiert Abwesenheit von Phantomen

Optimistische Synchronisation (OCC)

- **3-phasige Verarbeitung:**

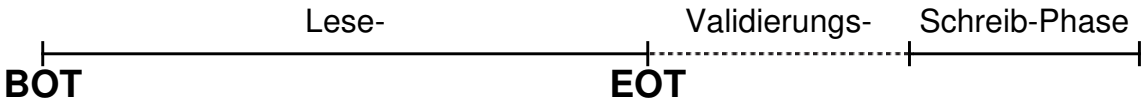

- **Lesephase**
  - eigentliche TA-Verarbeitung
  - Änderungen einer Transaktion werden in privatem Puffer durchgeführt

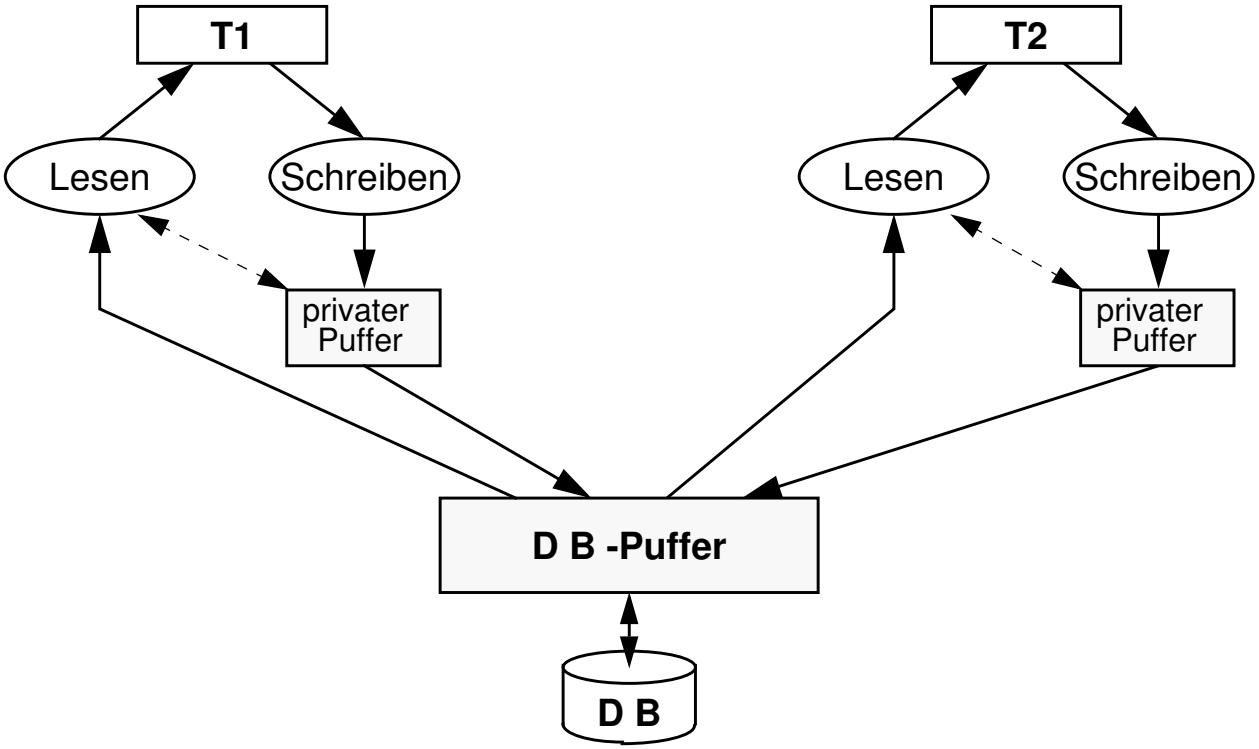

- **Validierungsphase**
  - Überprüfung, ob ein Lese-/Schreib- oder Schreib-/Schreib-Konflikt mit einer der parallel ablaufenden Transaktionen passiert ist
  - Konfliktauflösung durch Zurücksetzen von Transaktionen
- **Schreibphase**
  - nur bei positiver Validierung
  - Lese-Transaktion ist ohne Zusatzaufwand beendet
  - Schreib-Transaktion schreibt hinreichende Log-Information und propagiert ihre Änderungen

Optimistische Synchronisation (2)

- **Grundannahme: geringe Konfliktwahrscheinlichkeit**

- **Allgemeine Eigenschaften von OCC:**
  + einfache TA-Rücksetzung
  + keine Deadlocks
  + potentiell höhere Parallelität als bei Sperrverfahren
  - mehr Rücksetzungen als bei Sperrverfahren
  - Gefahr des „Verhungerns” von TA

- **Durchführung der Validierungen:**
  Pro Transaktion werden geführt
  - Read-Set (RS) und
  - Write-Set (WS)

- **Forderung:**

  Eine TA kann nur erfolgreich validieren, wenn sie alle Änderungen von zuvor validierten TA gesehen hat

  ➥ Validierungsreihenfolge bestimmt Serialisierungsreihenfolge

- **Validierungsstrategien:**
  - **Backward Oriented (BOCC):**

    Validierung gegenüber bereits beendeten (Änderungs-) TA
  - **Forward Oriented (FOCC):**

    Validierung gegenüber laufenden TA

B O C C

- Erstes publizierte Verfahren zur optimistischen Synchronisation[1]

- **Validierung von Transaktion T:**

  BOCC-Test gegenüber allen Änderungs-TA T_j, die seit BOT von T erfolgreich validiert haben:

  IF $RS(T) \cap WS(T_j) \neq \emptyset$ THEN ABORT T
  ELSE SCHREIBPHASE

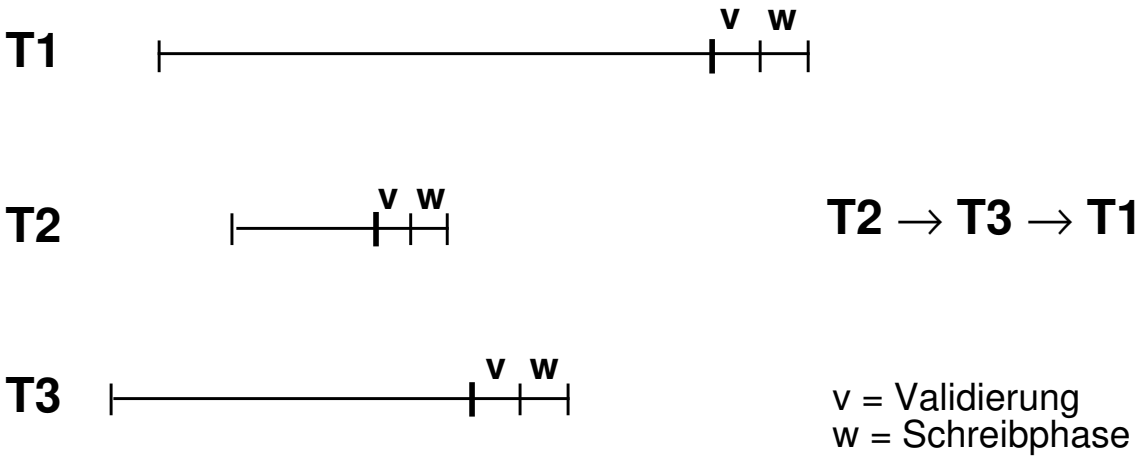

- **Nachteile/Probleme:**
  - unnötige Rücksetzungen wegen ungenauer Konfliktanalyse
  - Aufbewahren der Write-Sets beendeter TA erforderlich
  - hohe Anzahl von Vergleichen bei Validierung
  - Rücksetzung erst bei EOT ➥ viel unnötige Arbeit
  - Nur die validierende TA kann zurückgesetzt werden
    ➥ Gefahr von 'starvation'
  - hohes Rücksetzrisiko für lange TA und bei Hot-Spots

---

1. Kung, H.T., Robinson, J.T.: On optimistic method for concurrency control, in: ACM Trans. on Database Systems 6:2, 1981, 213-226

B O C C (2)

- **Ablaufbeispiel**

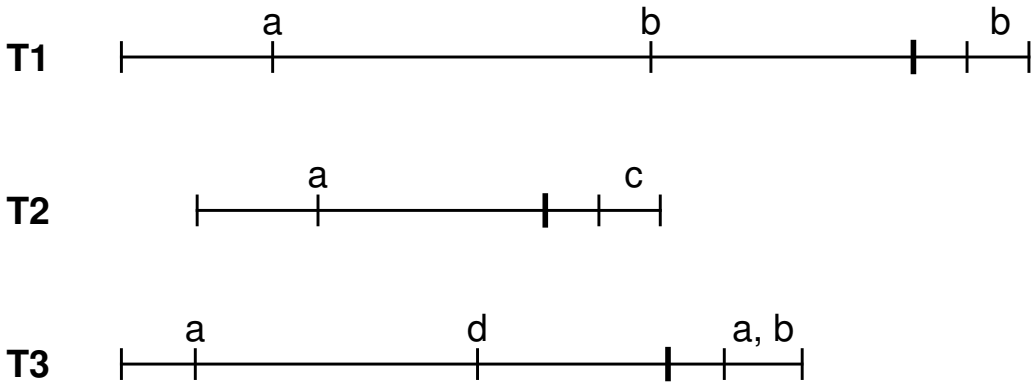

➥ Validierung von T1:

1. RS(T1) ∩ WS(T2) =
2. R1(T1) ∩ WS(T3) =

- **Optimierung von BOCC**

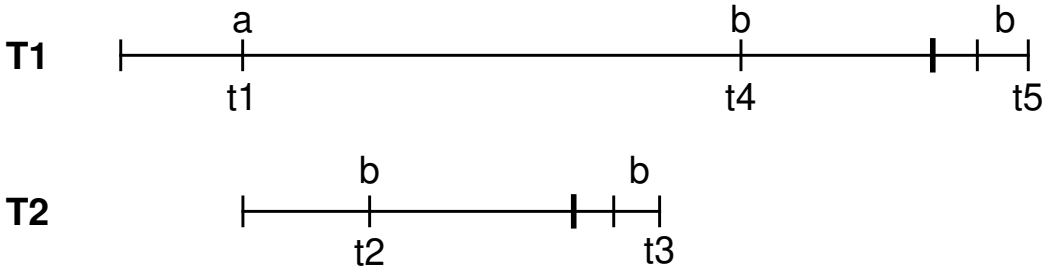

Zeitstempel in WS (Schreibzeitpunkt) und in RS (erste Referenz)

➥ Validierung von T1:

T1 : RS

T2 : WS

RS(T1) ∩ WS(T2) =

Zusätzliche Prüfung

Write(T2) = Ref(T1) =

F O C C[1]

- Nur Änderungs-TA validieren gegenüber laufenden TA T_i

- **Validierungstest:** $WS(T) \cap RS(T_j) \stackrel{!}{=} \varnothing$

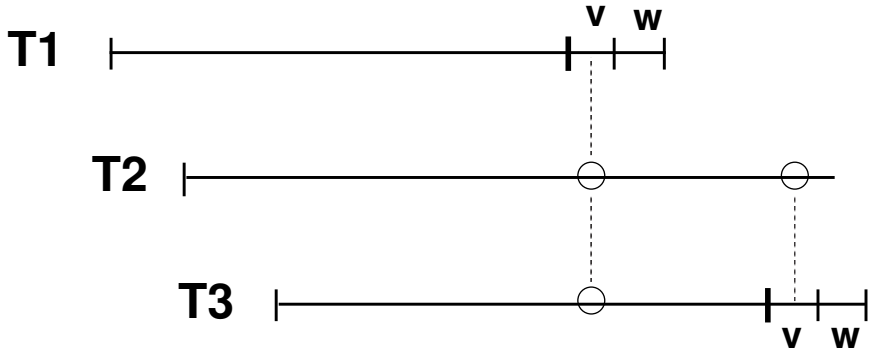

- **Vorteile:**
  - Wahlmöglichkeit des Opfers (Kill, Abort, Prioritäten, ...)
  - keine unnötigen Rücksetzungen
  - frühzeitige Rücksetzung möglich
    ➥ Einsparen unnötiger Arbeit
  - keine Aufbewahrung von Write-Sets,
    geringerer Validierungsaufwand als bei BOCC

- **Probleme:**
  - Während Validierungs- und Schreibphase müssen die Objekte von WS (T) „gesperrt" sein, damit sich die zu prüfenden RS (T_i) nicht ändern
    (keine Deadlocks damit möglich)
  - immer noch hohe Rücksetzrate möglich
  - Es kann immer nur einer TA Durchkommen definitiv zugesichert werden

1. Härder, T.: Observations on optimistic concurrency control schemes, Information Systems 9:2, 1984, 111-120

F O C C (2)

- **Ablaufbeispiel**

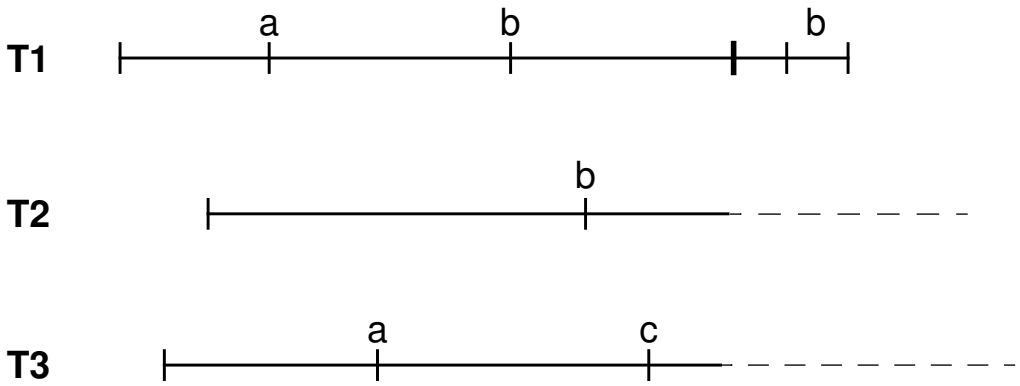

➥ Validierung von T1:

1. WS(T1) ∩ RS(T2) =

2. WS(T1) ∩ RS(T3) =

- **Mögliche Lösungen**

Sperrverfahren mit Versionen (RAX)

- **Kompatibilitätsmatrix:**

	R	A	X
R	+	⊕	-
A	⊕	-	-
X	-	-	-

- **Ablaufbeispiel**

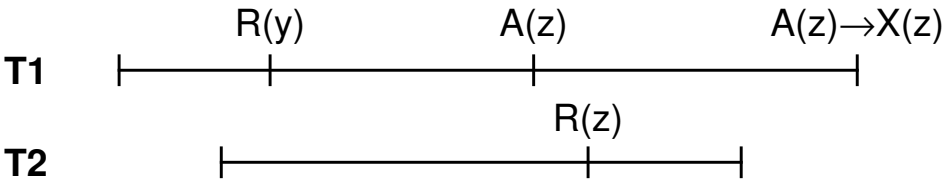

RAX: T2 → T1

- **Änderungen erfolgen in temporärer Objektkopie**

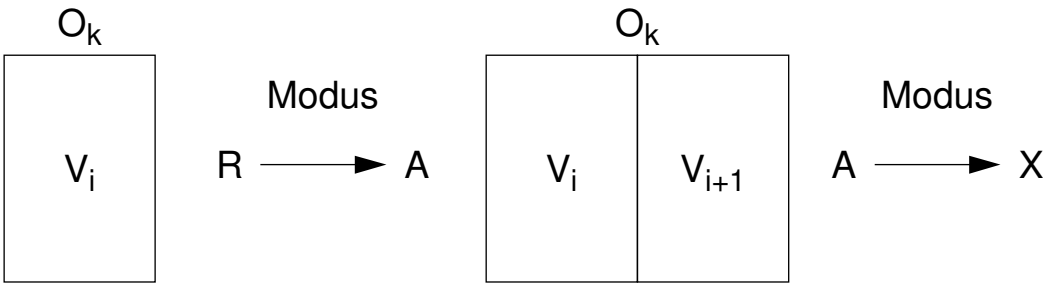

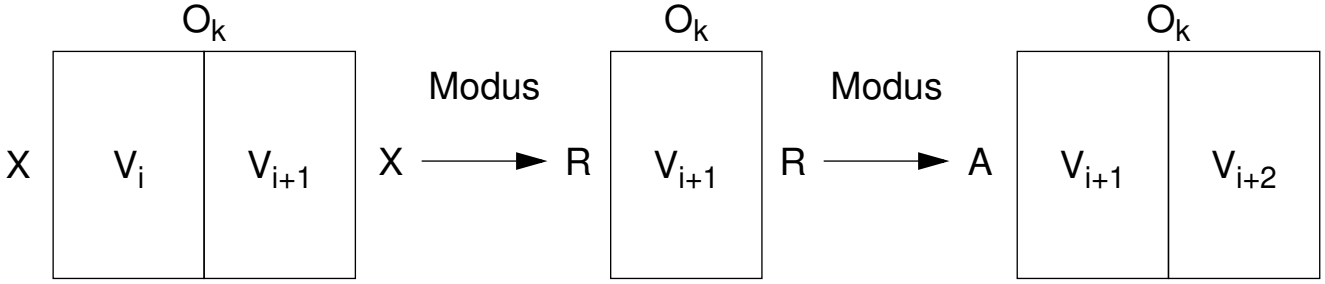

RAX (2)

- **Eigenschaften von RAX**
  - Paralleles Lesen der gültigen Version wird zugelassen
  - Schreiben wird nach wie vor serialisiert (A-Sperre)
  - Bei EOT Konversion der A- nach X-Sperren, ggf. auf Freigabe von Lesesperren warten (Deadlock-Gefahr)
  - Höhere Parallelität als beim RX-Verfahren, jedoch i. allg. andere Serialisierungsreihenfolge:

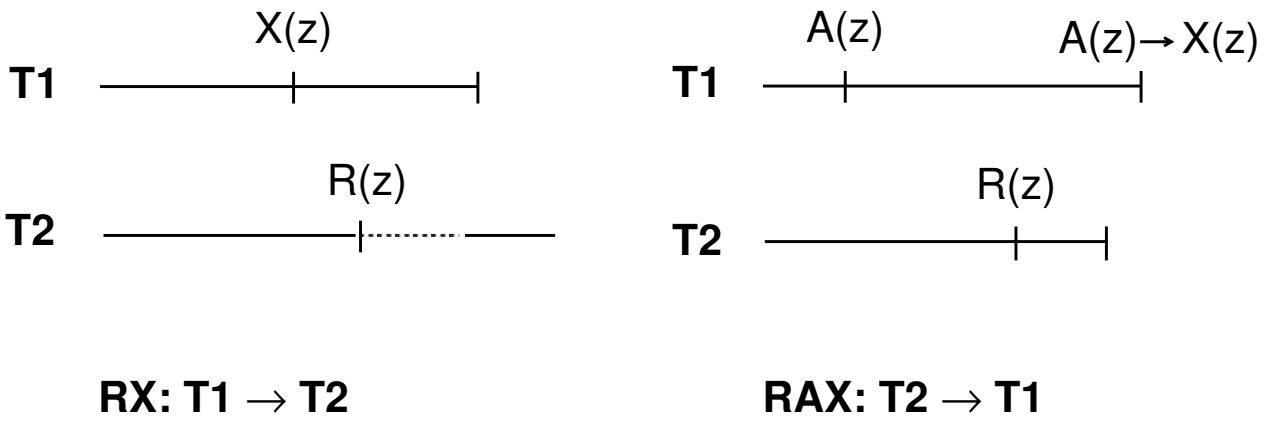

RX: T1 → T2 **RAX: T2 → T1**

- **Nachteile**
  - Neue Version wird für neu ankommende Leser erst verfügbar, wenn alte Version aufgegeben werden kann
  - Starke Behinderungen von Update-TA durch (lange) Leser möglich

➥ Bei TA-Mix von langen Lesern und kurzen Schreibern auf gemeinsamen Objekten bringt RAX keinen großen Vorteil

Sperrverfahren mit Versionen (RAC)

- **Kompatibilitätsmatrix:**

	R	A	C
R	+	+	⊕
A	+	-	-
C	⊕	-	-

- **Ablaufbeispiel**

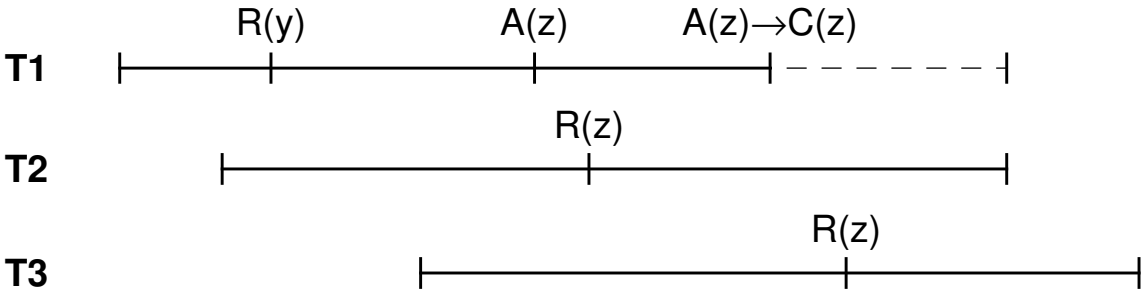

RAC: $T2 \rightarrow T1 \rightarrow T3$ (1)

- **Änderungen erfolgen ebenfalls in temporärer Objektkopie**

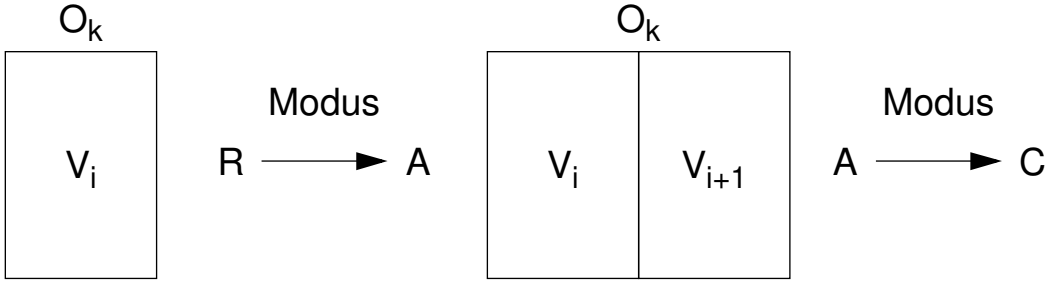

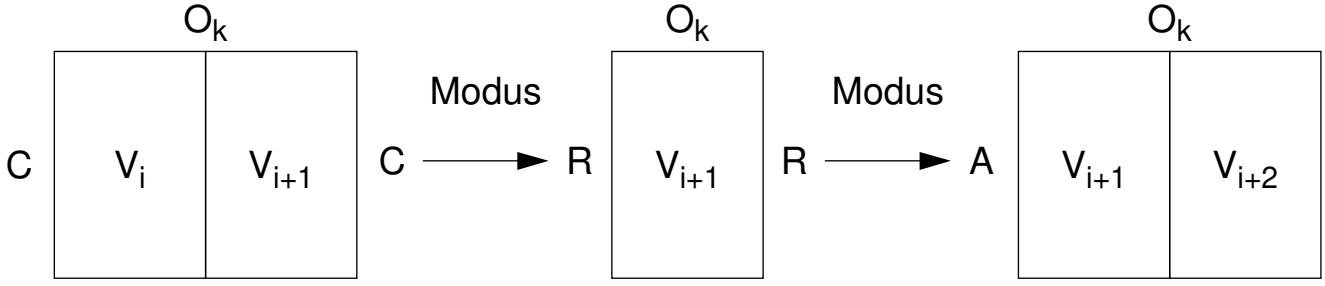

RAC (2)

- **Eigenschaften von RAC**
  - Änderungen werden nach wie vor serialisiert (A-Sperre erforderlich)
  - Bei EOT Konversion von A $\rightarrow$ C-Sperre
  - Maximal 2 Versionen, da C-Sperren mit sich selbst und mit A-Sperren unverträglich sind
  - C-Sperre zeigt Existenz **zweier gültiger Objektversionen** an

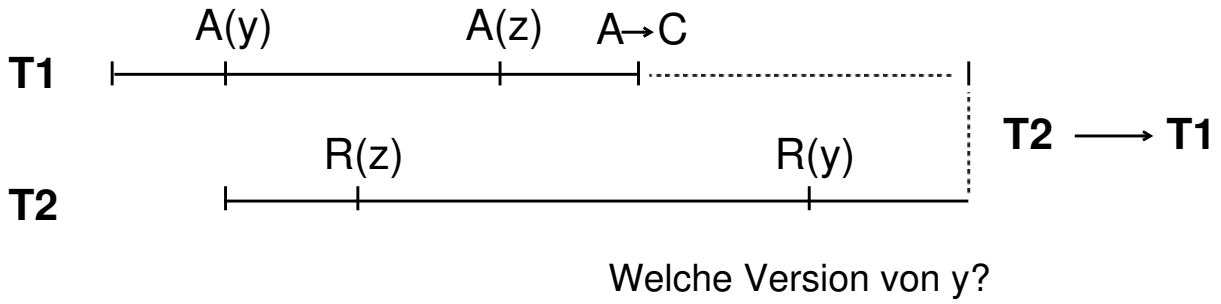

  ➥ Kein Warten auf Freigabe von Lesesperren auf alter Version (R- und C-Modus sind verträglich)

- **Nachteile**
  - RAC ist nicht chronologieerhaltend
  - Verwaltung komplexer Abhängigkeiten (z. B. über Abhängigkeitsgraphen)
    ➥ kompexere Sperrverwaltung
  - Leseanforderungen bewirken nie Blockierung/Rücksetzung, jedoch: **Auswahl der „richtigen" Version erforderlich**
  - Änderungs-TA, die auf C-Sperre laufen, müssen warten, bis **alle Leser** der alten Version beendet, weil nur 2 Versionen

  ➥ ***ABHILFE:*** allgemeines Mehrversionen-Verfahren

Mehrversionen-Verfahren

- **Änderungs-TA erzeugen neue Objektversionen**
  - Es kann immer nur eine neue Version pro Objekt erzeugt werden
  - Sie wird bei EOT der TA freigegeben
- **Lese-TA sehen den bei ihrem BOT gültigen DB-Zustand**
  - Sie greifen immer auf die jüngsten Objektversionen zu, die bei ihrem BOT freigegeben waren
  - Sie setzen und beachten keine Sperren
  - Es gibt eine Blockierungen und Rücksetzungen für Lese-TA, dafür ggf. Zugriff auf veraltete Objektversionen
- **Beispiel für Objekt O_k**

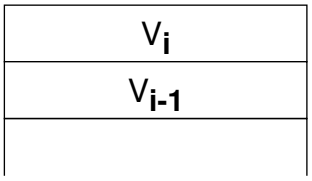

Zeitliche Reihenfolge der Zugriffe auf O_k

T_j (BOT)	➥	V_i (aktuelle Version)
T_m(X)	➥	Erzeugen V_{i+1}
T_n(X)	➥	Verzögern bis T_m(EOT)
T_m(EOT)	➥	Freigeben V_{i+1}
T_n(X)	➥	Erzeugen V_{i+2}
T_j (Ref)	➥	V_i
T_n(EOT)	➥	Freigeben V_{i+2}

Mehrversionen-Verfahren (2)

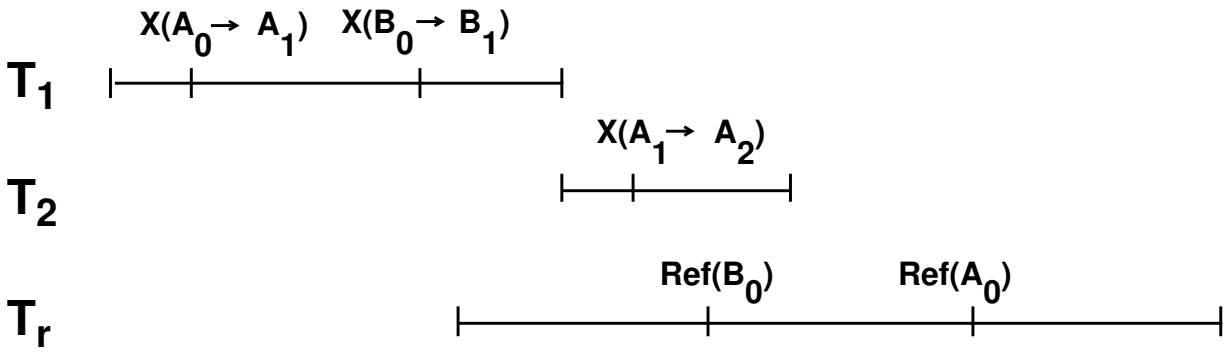

- **Konsequenz**
  - Lese-TA werden bei der Synchronisation nicht mehr berücksichtigt
  - Änderungs-TA werden untereinander über ein allgemeines Verfahren (Sperren, OCC, . . .) synchronisiert

➥ **deutlich weniger Synchronisationskonflikte**

- **Zusätzlicher Speicher- und Wartungsaufwand**
  - Versionenpoolverwaltung, Garbage Collection
  - Auffinden von Versionen

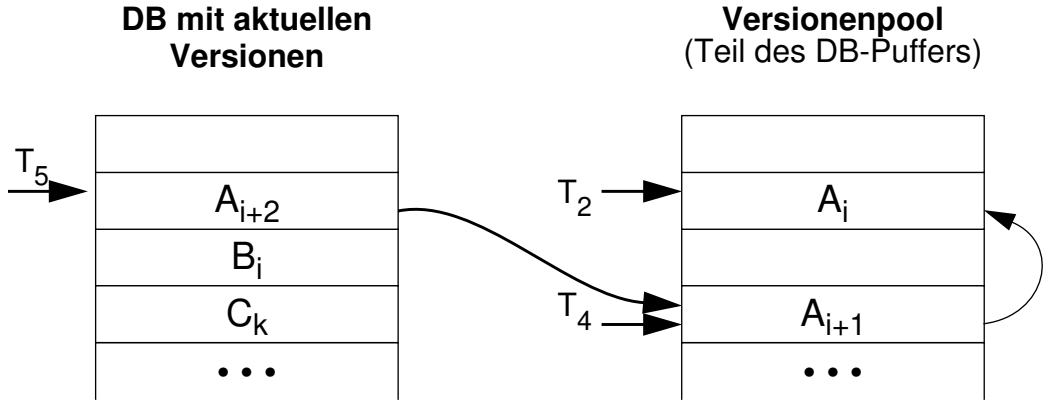

  - Speicherplatzoptimierung: Versionen auf Satzebene, Einsatz von Komprimierungstechniken

- Verfahren bereits in einigen **kommerziellen DBVS** eingesetzt (Oracle, RDB)

Zeitstempelverfahren

- **Grundsätzliche Idee**
  - TA bekommt bei BOT einen systemweit eindeutigen Zeitstempel; er legt die Serialisierbarkeitsreihenfolge fest
  - TA hinterläßt den Wert ihres Zeitstempels bei jedem Objekt O_i, auf das sie zugreift
  - Prüfung der Serialisierbarkeit ist sehr einfach (Zeitstempelvergleich)

    ➥ Bei allen Objektzugriffen muß die Zeitstempelreihenfolge (Timestamp Ordering (TO)) eingehalten werden

- **Prinzipielle Arbeitsweise**
  - Vergabe von eindeutigen TA-IDs (Zeitstempel ts der TA) in aufsteigender Reihenfolge
  - „Stempeln" des Objektes O bei Zugriffen von T_i : $TS(O) := ts(T_i)$
  - **Konfliktprüfung:**

    if $ts(T_i) < TS(O)$ then ABORT
    else verarbeite;

    ➥ Wenn eine Transaktion „zu spät" kommt, wird sie zurückgesetzt und muß wiederholt werden

T7: **O_k** $TS(O_k) = 10$

O_n $TS(O_n) = 5$

O_m $TS(O_m) = 3$

Zeitstempelverfahren (2)

- **Zugriffsfolge auf Objekt O** (nur ein allgemeiner Zeitstempel TS):

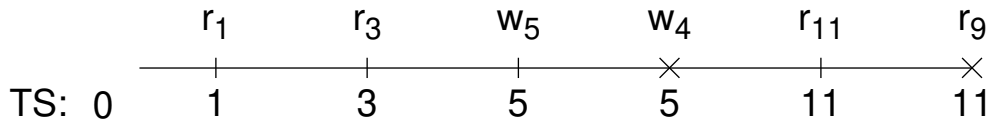

  ➥ kein Konflikt bei r_9!

- **Verfeinerung: 2 Zeitstempel pro Objekt**
  - Erhöhung beim Schreiben: WTS
  - Erhöhung beim Lesen: RTS
  - **Regeln** für T_i und O (Abk. $ts(T_i) = i$)

R1: $r_i \wedge (i \geq WTS(O)) \Rightarrow$ if $RTS(O) < i$ then $RTS(O) := i$; Lesen

R2: $w_i \wedge (i \geq RTS(O)) \wedge (i \geq WTS(O)) \Rightarrow WTS(O) := i$; Ändern

R3: $w_i \wedge (i \geq RTS(O)) \wedge (i < WTS(O)) \Rightarrow$ kein Konflikt *(blind update)* – kein Schreiben – weiter[1]

R4: $w_i \wedge (i < RTS(O)) \Rightarrow$ Zurücksetzen

R5: $r_i \wedge (i < WTS(O)) \Rightarrow$ Zurücksetzen

- **Zugriffsfolge auf Objekt O:**

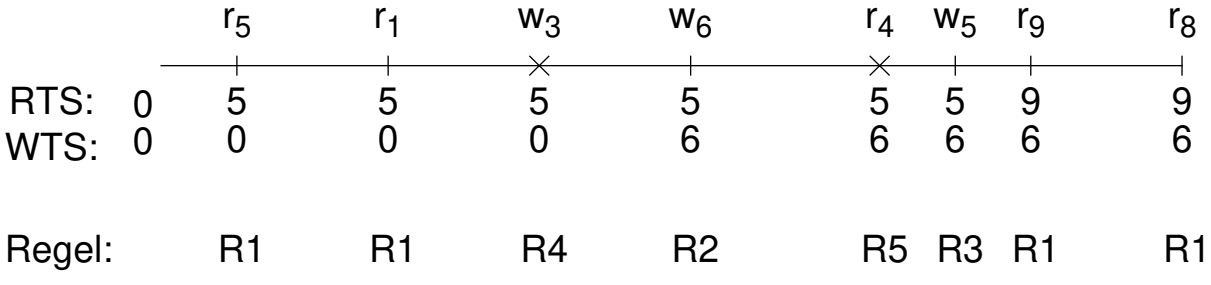

1. Diese Regel wird in der Literatur mit “Thomas’ Write Rule” bezeichnet

Zeitstempelverfahren (3)

- **Wo liegt das Problem?**
  $ts(T_i) = i$

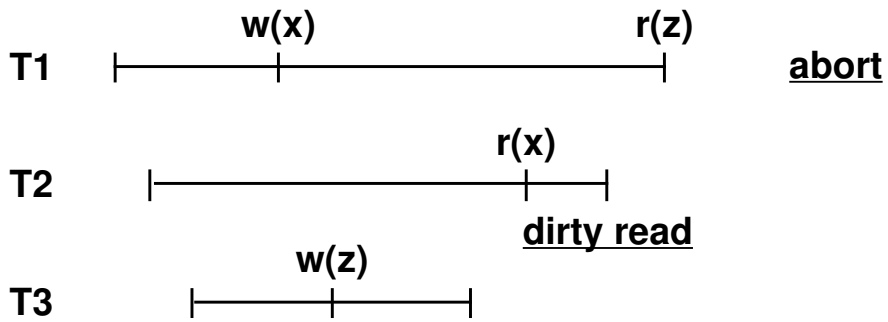

- **Vorkehrungen für den ABORT-Fall**
  - Sofortige Zulassung aller Schreiboperationen erzeugt inkonsistente DB
  - Einfrieren der Zeitstempel bis COMMIT der ändernden TA
  - Basic Timestamp Ordering (BTO)[1] schlägt Lösung mit Sperrverfahren und Verwaltung komplexer Abhängigkeiten vor

- **Eigenschaften von TO**
  - Serialisierungsreihenfolge einer Transaktion wird bei BOT festgelegt
  - Deadlocks sind ausgeschlossen
  - aber: (viel) höhere Rücksetzraten als pessimistische Verfahren
  - ungelöste Probleme, z. B. wiederholter ABORT einer Transaktion

- **Hauptsächlicher Einsatz**
  - Synchronisation in Verteilten DBS
  - lokale Prüfung der Serialisierbarkeit direkt am Objekt O_i (geringer Kommunikationsaufwand)

1. Bernstein, P.A., Goodman, N.: Timestamp-based Algorithms for Concurrency Control in Distributed Database Systems, in: Proc. 6th Int. Conf. on VLDB, 1980, 285-300

Zeitstempelverfahren (4)

- **Implementierung des Protokolls BTO[1]**
  - Alle Prüfungen/Entscheidungen müssen lokal erfolgen
  - Erwerb von Anwartschaften: Prewrites
  - **Prewrite i verzögert r_j, w_j mit j > i**
  - Einführung von Read-Queues (R-Q), Prewrite-Queues (P-Q) und Write-Queues (W-Q)

- **Zugriffsprotokoll auf Objekt O:**

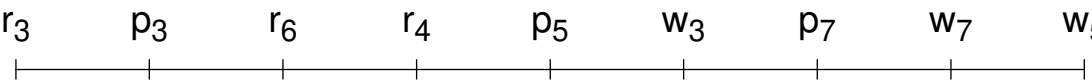

RTS:	2	3		3		3		3	3 4		4		4 6 6
WTS:	1	1		1		1		1	3 3		3		5 5 7
R-Q:					6		4 6		4 6	6		6	6	
P-Q:			3				3 5		5	5 7	5 7		7 7
W-Q:											7		7 7

➥ komplexe Verwaltung von Abhängigkeiten in R-Q, P-Q, W-Q

1. Peinl, P.: Synchronisation in zentralisierten Datenbanksystemen, Informatik-Fachberichte 161, Springer-Verlag, 1987

Prädikatssperren[1]

- Logische Sperren oder **Prädikatssperren**
  - Minimaler Sperrbereich durch geeignete Wahl des Prädikats
  - **Verhütung des Phantomproblems**
  - Eleganz

- **Form:**

  LOCK (R, P, a)

  R Relationenname
  P Prädikat
  a $\in$ {read, write}

  UNLOCK (R, P)

  - **Lock (R, P, write)**

  sperrt alle möglichen Tupeln von R exklusiv, die Prädikat P erfüllen

- **Beispiel:**

T1:	LOCK(R1, P1, read)	**T2:**	**. . .**
	LOCK(R2, P2, write)		LOCK(R2, P3, write)
	LOCK(R1, P5, write)		LOCK(R1, P4, read)
	. . .		**. . .**

- **Wie kann Konflikt zwischen zwei Prädikaten festgestellt werden?**
  - Im allgemeinen Fall rekursiv unentscheidbar,
    selbst mit eingeschränkten arithmetischen Operatoren
  - Entscheidbare Klasse von Prädikaten: einfache Prädikate
    ➥ (A Θ Wert) {$\wedge$, $\vee$} (. . .

---

1. Eswaran, K.P. et al.: The notions of consistency and predicate locks in a data base system. in: Commm. ACM 19:11, 1976, 624-633

Prädikatsperren (2)

- **Entscheidungsprozedur**

LOCK (R, P, a) **LOCK (R', P', a')**

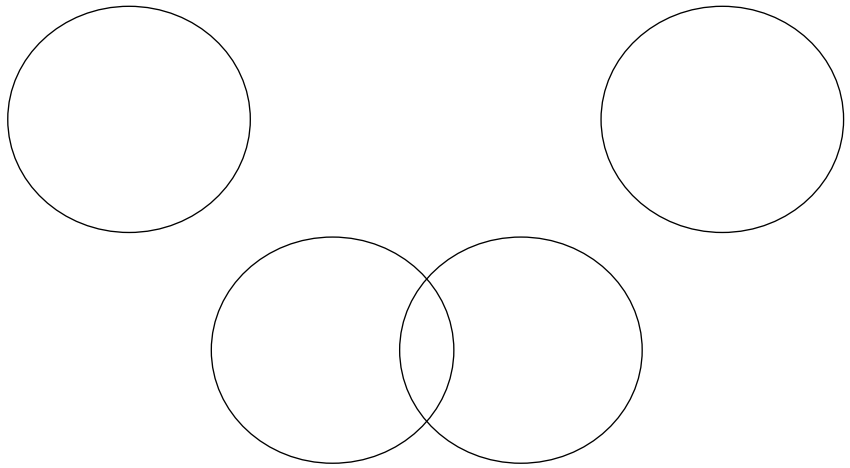

1. Wenn $R \neq R'$, kein Konflikt
2. Wenn a = read und a' = read, kein Konflikt
3. Wenn $P(t) \wedge P'(t)$ = TRUE für irgendein t, dann besteht ein Konflikt

T1:
LOCK (Pers, Alter > 50, read)

T2:
LOCK (Pers, Pnr = 4711, write)

➥ Entscheidung:

- **Nachteile**
  - Erfüllbarkeitstest:
    Aufwendige Entscheidungsprozedur mit vielen Prädikaten (N > 100)
    (wird in innerer Schleife des Lock-Mgr. häufig aufgerufen)
  - **Pessimistische** Entscheidungen ➥ Einschränkung der Parallelität
    (es wird auf Erfüllbarkeit getestet !)
  - Einsatz nur bei deskriptiven Sprachen!
  - Sonderfall: P=TRUE entspricht einer Relationensperre
    ➥ große Sperrgranulate, geringe Parallelität

Prädikatsperren (3)

- **Effizientere Implementierung: Präzisionssperren**[1]
  - **nur die gelesenen Daten** werden durch Prädikate gesperrt
  - für aktualisierte Tupel werden Schreibsperren gesetzt

    ➥ kein Disjunktheitstest für Prädikate mehr erforderlich, sondern lediglich zu überprüfen, ob Tupel ein Prädikat erfüllt

- **Datenstrukturen:**
  - **Prädikatsliste:**
    Lesesperren laufender TA werden durch **Prädikate** beschrieben

    (Pers: Alter > 50 and Beruf = ‘Prog.’)
    (Pers: Pname = ‘Meier’ and Gehalt > 50000)
    (Abt: Anr=K55)
    . . .
  - **Update-Liste:**
    enhält geänderte **Tupel** laufender TA

    (Pers: 4711, ‘Müller’, 30, ‘Prog.’, 70000)
    (Abt: K51, ‘DBS’, . . .)
    . . .

- **Leseanforderung (Prädikat P):**
  - für jedes Tupel der Update-Liste ist zu prüfen, ob es P erfüllt
  - wenn ja ➥ Sperrkonflikt

- **Schreibanforderung (Tupel T):**
  - für jedes Prädikat P der Prädikatliste ist zu prüfen, ob T es erfüllt
  - wenn T keines erfüllt ➥ Schreibsperre wird gewährt

---

1. J.R. Jordan, J. Banerjee, R.B. Batman: Precision Locks, in: Proc. ACM SIGMOD, 1981, 143-147

Synchronisation von High-Traffic-Objekten

- **High-Traffic-Objekte:**

  meist numerische Felder mit aggregierten Informationen
  z. B. - Anzahl freier Plätze
  - Summe aller Kontostände

- **Einfachste Lösung der Sperrprobleme:**

  Vermeidung solcher Attribute beim DB-Entwurf

- **Alternative:**

  Nutzung von semantischem Wissen zur Synchronisation wie Kommutativität von Änderungsoperationen auf solchen Feldern

- **Beispiel.:** Inkrement-/Dekrement-Operation

	R	**X**	**Inc/Dec**
R	**+**	**-**	**-**
X	**-**	**-**	**-**
Inc/Dec	**-**	**-**	**+**

Escrow-Ansatz[1]

- **High-Traffic-Objekte**
  - Deklaration als Escrow-Felder
  - Benutzung spezieller Operationen
    - Anforderung einer bestimmten Wertemenge

      IF **ESCROW (field=F1, quantity=C1, test=(condition))**
      THEN 'continue with normal processing'
      ELSE 'perform exception handling'

    - Benutzung der reservierten Wertmengen:

      USE (field=F1, quantity=C2)

  - Optionale Spezifizierung eines Bereichstest bei Escrow-Anforderung
  - Wenn Anforderung erfolgreich ist, kann Prädikat nicht mehr nachträglich invalidiert werden

  ➥ keine spätere Validierung/Zurücksetzung

- **Aktueller Wert eines Escrow-Feldes**
  - ist unbekannt, wenn laufende TA Reservierungen angemeldet haben

  ➥ Führen eines Werteintervalls, das alle möglichen Werte nach Abschluß der laufenden TA umfaßt

  - für Wert Q_k des Escrow-Feldes k gilt:

    $$LO_k \leq INF_k \leq Q_k \leq SUP_k \leq HI_k$$

  - Anpassung von INF, Q, SUP bei Anforderung, Commit und Abort einer TA

1. P. O'Neil: The Escrow Transactional Method, in: ACM Trans. on Database Systems 11: 4, 1986, 405-430

Escrow-Ansatz (2)

- **Beispiel:**

  Zugriffe auf Feld mit LO=0, HI=500 (Anzahl freier Plätze)

Anforderungen/Rückgaben				Werteintervall		
T1	T2	T3	T4	INF	Q	SUP
				15	15	15
-5						
	-8					
		+4				
			-3			
commit						
		commit				
	abort					

- **Eigenschaften**
  - Durchführung von Bereichstests bezüglich des Werteintervalls
  - Minimal-/Maximalwerte (LO, HI) dürfen nicht überschritten werden
  - hohe Parallelität ändernder Zugriffe möglich

- **Nachteile:**
  - spezielle Programmierschnittstelle
  - tatsächlicher Wert ggf. nicht abrufbar

Klassifikation von Synchronisationsverfahren

- **Gemeinsame Ziele**
  - Erhöhung der Parallelität
  - Reduktion von Behinderungen/Blockierungen
  - Einfache Verwaltung

- **Erhöhung der Parallelität durch Objektvervielfältigung**
  - Kopien: temporär, privat, nicht freigegeben
  - Versionen: permanent, mehrbenutzbar, freigegeben

*Kopien \ *Versionen	1	2	N	∞
0				
1				
P				

- **Beobachtung**
  - Einsatz in existierenden DBS: vor allem hierarchische Sperrverfahren und Varianten, aber auch Mehrversionen-Verfahren
  - Es existieren eine Fülle von allgemeingültigen und spezialisierten Synchronisationsverfahren (zumindest in der Literatur)
  - Es kommen (ständig) Verfahren durch Variation der Grundprinzipien dazu!

Leistungsanalyse und Bewertung von Synchronisationsverfahren

- **Wie bewertet man Parallelität?**
  - hoher Parallelitätsgrad - viele Rücksetzungen und Wiederholungen
  - moderate Parallelität, dafür geringerer Zusatzaufwand

- **Durchsatztest**
  - alle Transaktionen inkl. (mehrfache) Wiederholungen sind bearbeitet (Ermittlung der Durchlaufzeit)
  - einstellbarer Grad der maximalen Parallelität

- **Messung der effektiven Parallelität**
  - n = nominale Parallelität (MPL)
  - n' = durchschnittliche Anzahl aktiver Transaktionen (berücksichtigt Wartesituationen)
  - q = tatsächliche Arbeit (Referenzen) / minimale Arbeit (berücksichtigt Rücksetzungen und Wiederholungen)
  - effektive Parallelität

    $n^* = n'/q$

- **Zählung der Deadlocks**

Leistungsanalyse - Simulationsverfahren

- **Analyse von Synchronisationsverfahren**
  - pessimistisch: RX, RX2
  - optimistisch: BOCC, FOCC-K (Kill), FOCC-H (Hybrid)
  - Versionen: RAC, Mehrversionen-Verfahren (MVC)

- **Nachbildung der DB-Last**
  - Aufzeichnung der Seitenreferenzen realer Anwendungen im DBS
  - Nutzung verschiedenartiger TA-Mixe in Form von Referenzstrings
  - Simulation des DB-Puffers und der benötigten E/A-Zeiten
  - Ermittlung der Durchlaufzeiten unter den verschiedenen Synchronisationsverfahren und den eingestellten Sollparallelitäten

- **Simulationsverfahren**

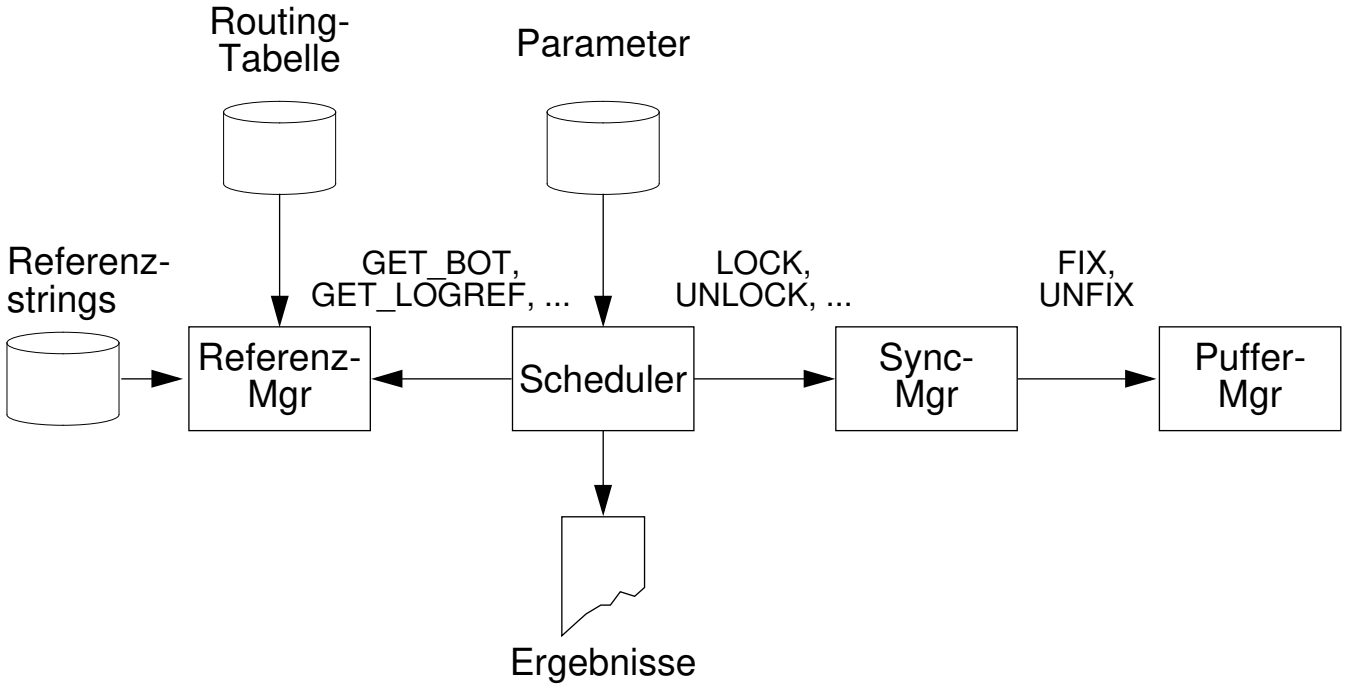

Implementierungsaspekte – Datenstrukturen

- **Probleme bei der Implementierung von Sperren**
  - Kleine Sperreinheiten (wünschenswert) erfordern hohen Aufwand
  - Sperranforderung und -freigabe sollten sehr schnell erfolgen, da sie sehr häufig benötigt werden ➥ Sperrtabelle ist High-Traffic-Objekt!
  - Explizite, satzweise Sperren führen u. U. zu umfangreichen Sperrtabellen und großem Zusatzaufwand

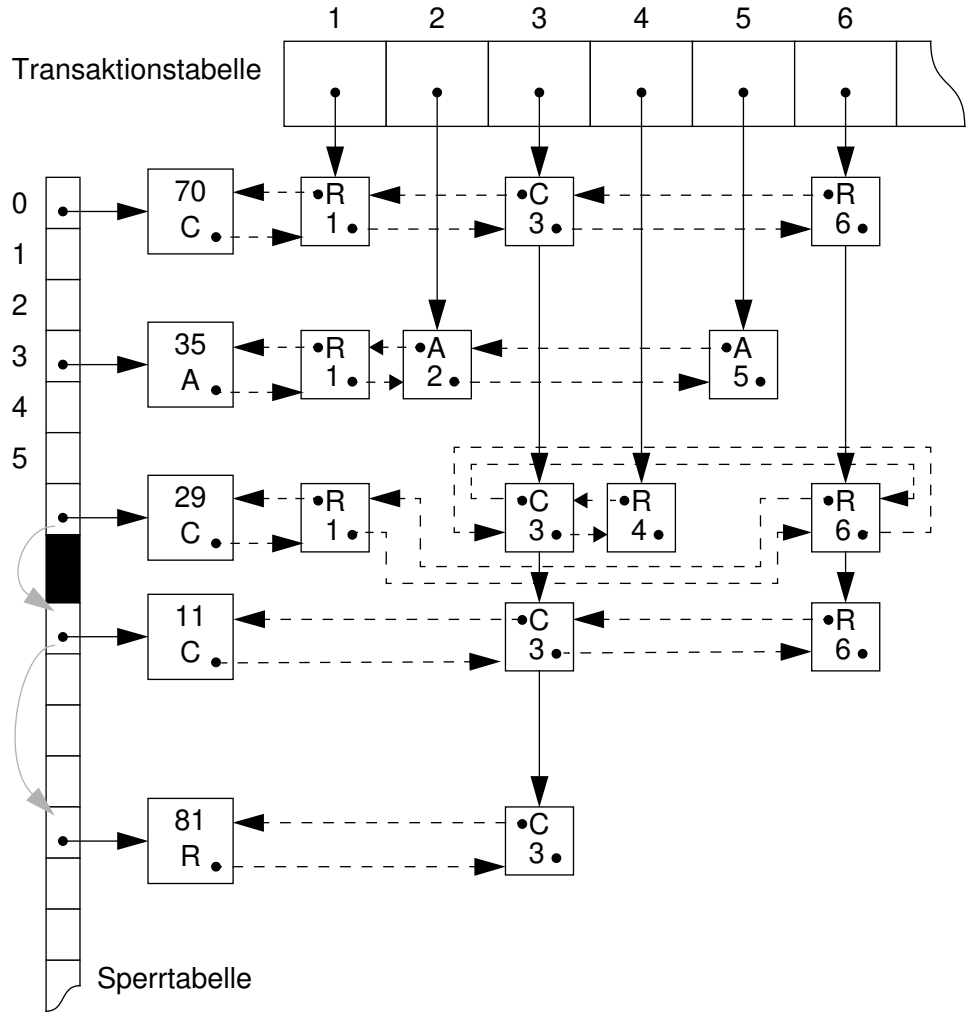

➥ **Beispiel:** Sperrtabelle / TA-Tabelle für RAC-Verfahren

- Hash-Tabelle erlaubt schnellen Zugriff auf Objektkontrollblöcke (OKB)
- Matrixorganisation Sperr-/TA-Tabelle
- Spezielles Sperrverfahren: **Kurzzeitsperren** für Zugriffe auf Sperrtabelle (Semaphor pro Hashklasse reduziert Konflikt-/Konvoi-Gefahr)

Synchronisationsverfahren – Vergleich

Effektive Parallelität

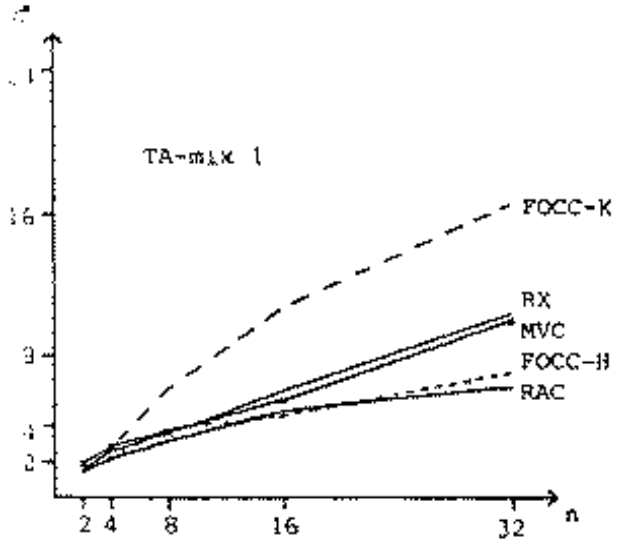

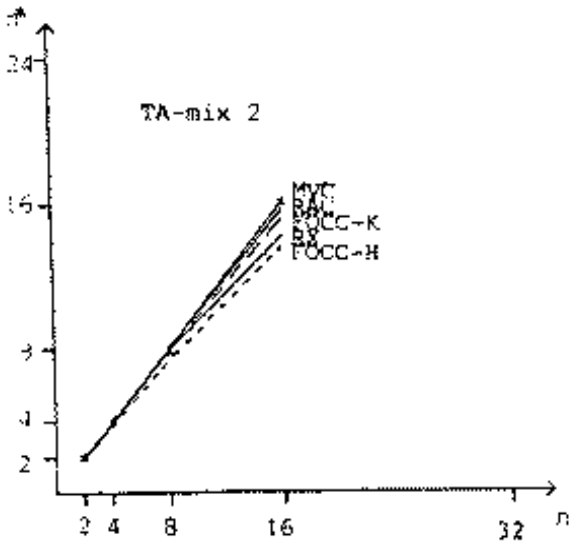

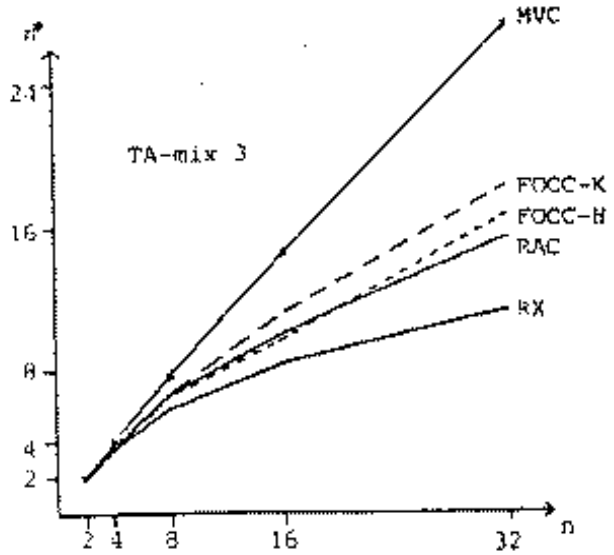

Summe der Deadlocks

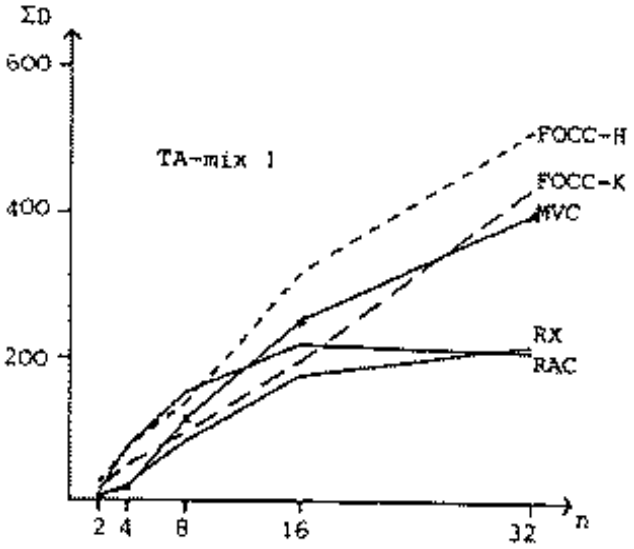

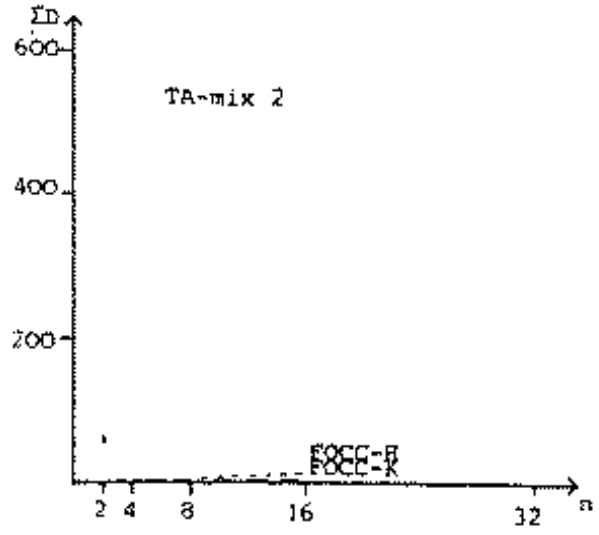

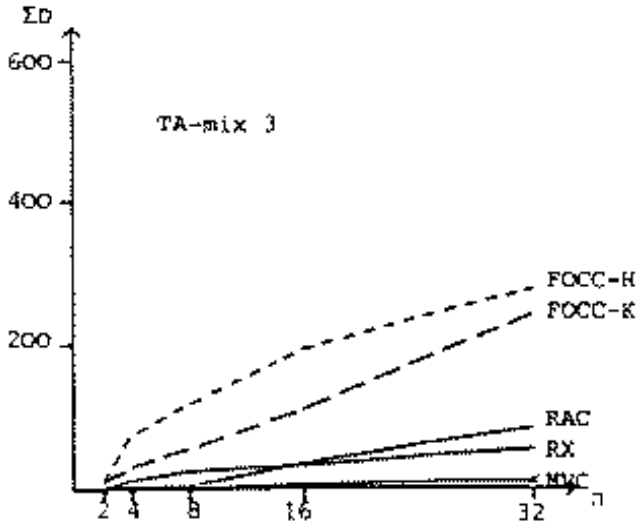

- **Schlußfolgerungen**
  - Sehr geringe Parallelität → keine effektive Nutzung der Ressourcen
  - Geringe Parallelität → bester Durchsatz,
    nicht notwendigerweise kürzeste Antwortzeiten
  - Pessimistische Methoden gewinnen:
    Blockierung vermeidet häufig Deadlocks
  - Optimistische Methoden geraten leicht in ein Thrashing-Verhalten
  - RX2 reduziert effektiv den Wettbewerb um gemeinsam genutzte Daten

Synchronisation und Lastkontrolle

- **Charakteristische Wannenform (idealisiert)**

  - Sie ergibt sich bei vielen Referenzstrings und Synchronisationsverfahren

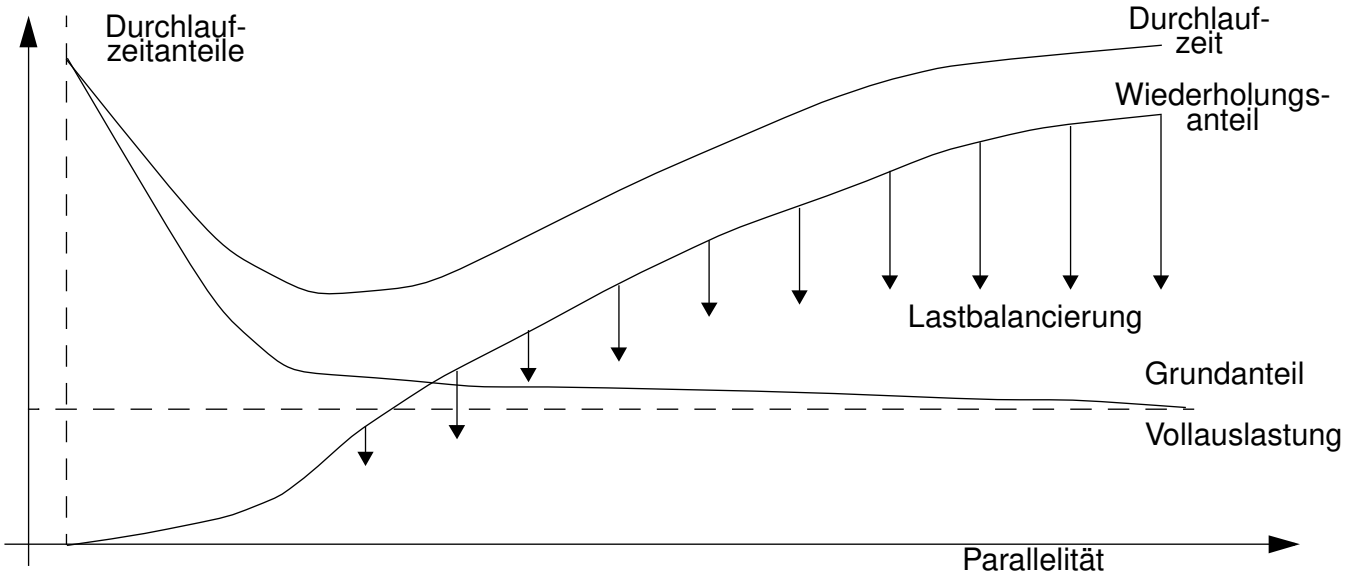

  - Sie wird von **zwei gegenläufigen Faktoren** bestimmt
    - Grundanteil der Durchlaufzeit beschreibt die Zeit, die zur Verarbeitung durch den Referenzstring vorgegebenen Last bei fehlender Synchronisation nötig wäre
    - Wiederholungsanteil umfaßt die Belegung des Prozessors zur nochmaligen Ausführung zurückgesetzter TA

  ➥ Rolle der Lastkontrolle und Lastbalancierung!

- **Empirische Bestätigung**

  - Theoretische Untergrenze des Grundanteils wird bei Vollauslastung des Prozessors erreicht
  - Häufigkeit von Leerphasen des Prozessors

DOD 1024							
PAR	BOCCT	FOCC	BOCC	RX2	RAX	RAC	RX
1	4864	4864	4864	4864	4864	4864	4864
2	1623	1734	1584	1719	1725	1717	1788
4	59	105	50	149	206	94	256
8	108	37	17	17	26	31	53
16	36	23	8	27	5	40	90
32	70	40	5	28	8	70	46

Dynamische Lastkontrolle

- **Was nützt „blinde" Durchsatzmaximierung?**

  mehr aktive TA → mehr gesperrte Objekte → höhere Konflikt-WS → längere Sperrwartezeiten, höhere Deadlock-Raten → **noch mehr** aktive TA

- **Parallelitätsgrad** (multiprogramming level, MPL)
  - Er hat wesentlichen Einfluß auf das Leistungsverhalten, bestimmt Umfang der Konflikte bzw. Rücksetzungen
  - Gefahr von „Thrashing" bei Überschreitung eines kritischen MPL-Wertes

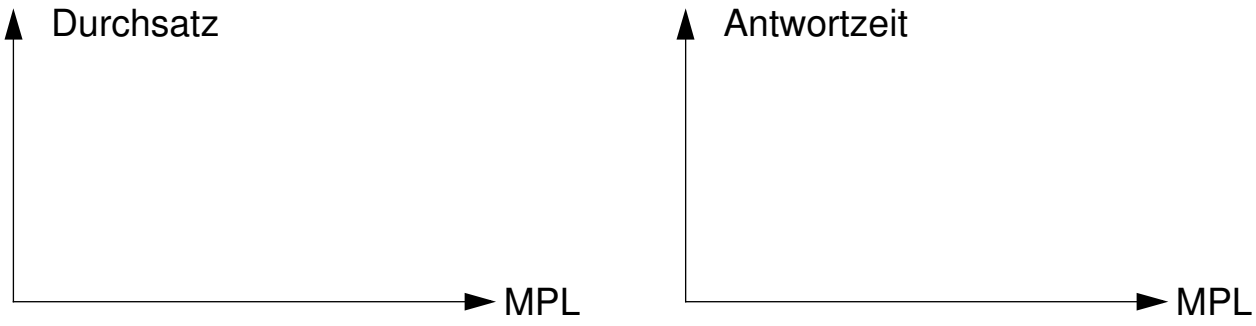

- **Statische MPL-Einstellung unzureichend:**
  wechselnde Lastsituationen, mehrere Transaktionstypen

- **Idee:**
  dynamische Einstellung des MPL zur Vermeidung von „Thrashing"

- **Ein möglicher Ansatz -**

  Nutzung einer Konfliktrate bei Sperrverfahren[1]:

  Konfliktrate = # gehaltener Sperren /
  #Sperren nicht-blockierter Transaktionen

  kritischer Wert: ca. 1,3 (experimentell bestimmt)
  - Zulassung neuer TA nur, wenn kritischer Wert noch nicht erreicht ist
  - Bei Überschreiten erfolgt Abbrechen von TA

1. Weikum, G. et al.:The Comfort Automatic Tuning Project, in: Information Systems 19:5, 1994, 381-432

Zusammenfassung

- Beim ungeschützten und konkurrierenden Zugriff von Lesern und Schreibern auf gemeinsame Daten können Anomalien auftreten

- **Korrektheitskriterium der Synchronisation: Serialisierbarkeit**

- **Theorie der Serialisierbarkeit**
  - einfaches Read/Write-Modell (Syntaktische Behandlung)
  - enorm gründlich erforscht
  - weitergehende Ansätze: Einbezug der Anwendungssemantik (Synchronisation von abstrakten Operationen auf Objekten)

- **Serialisierbare Abläufe**
  - gewährleisten „automatisch“ Korrektheit des Mehrbenutzerbetriebs
  - erzwingen u. U. lange Blockierungszeiten paralleler Transaktionen

- **Deadlock-Problem ist bei blockierenden Verfahren inhärent!**

- **Einführung von Konsistenzebenen**
  - zwei (geringfügig) unterschiedliche Ansätze
    - basierend auf Sperrdauer für R und X
    - basierend auf zu tolerierende “Fehler”
  - „Schwächere“ Synchronisation von Leseoperationen erlaubt höhere Parallelitätsgrade und Reduktion von Blockierungen, erfordert aber Programmierdisziplin!

    ➥ **Inkaufnahme von Anomalien reduziert die TA-Behinderungen**

Zusammenfassung (2)

- **Implementierung der Synchronisation: viele Verfahren**
  - Sperrverfahren sind universell einsetzbar
  - DBS-Standard: multiple Sperrgranulate durch hierarchische Sperrverfahren
  - RAX und RAC begrenzen Anzahl der Versionen und reduzieren Blockierungsdauern nur für bestimmte Situationen
  - Mehrversionen-Verfahren liefert hervorragende Werte bei der effektiven Parallelität und bei der Anzahl der Deadlocks, verlangt jedoch höheren Aufwand (Algorithmus, Speicherplatz)
  - Reine OCC- und Zeitstempelverfahren erzeugen zuviele Rücksetzungen
  - Prädikatssperren verkörpern eine elegante Idee, sind aber in praktischen Fällen nicht direkt einsetzbar,
    ggf. Nutzung in der Form von Präzisionssperren

- **Generelle Optimierungen:**
  - reduzierte Konsistenzebene
  - Mehrversionen-Ansatz

- **'Harte' Synchronisationsprobleme:**
    - 'Hot Spots' / 'High Traffic'-Objekte
    - lange (Änderung-) TA
  - Wenn Vermeidungsstrategie nicht möglich ist, sind zumindest für Hochleistungssysteme Spezialprotokolle anzuwenden
  - Nutzung semantischen Wissens über Operationen / Objekte zur Reduzierung von Synchronisationskonfliken
  - allerdings
    - ggf. Erweiterung der Programmierschnittstelle
    - begrenzte Einsetzbarkeit
    - Zusatzaufwand