7. Synchronisation[1]

- **Synchronisation -**
  Überblick über die Verfahren
- **Zweiphasen-Sperrprotokolle**
  - RX-Protokoll, RUX-Protokoll
  - Hierarchische Sperrverfahren
  - Deadlock-Behandlung
- **Einführung von Konsistenzebenen**
  - Reduzierung von TA-Blockierungen, aber Programmierdisziplin gefordert
  - Unterschiedliche Ansätze basierend auf
    - Sperrdauer für R und X
    - zu tolerierende “Fehler”
- **Optimistische Synchronisation**
  - Eigenschaften
  - BOCC, FOCC
- **Optimierungen**
  - RAX, RAC, Mehrversionen-Verfahren
  - Zeitstempel-Verfahren
  - Prädikatssperren
  - Spezielle Synchronisationsprotokolle
- **Leistungsanalyse und Bewertung**
  - Ergebnisse empirischer Untersuchungen
  - Dynamische Lastkontrolle

---

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

Dining Philosophers

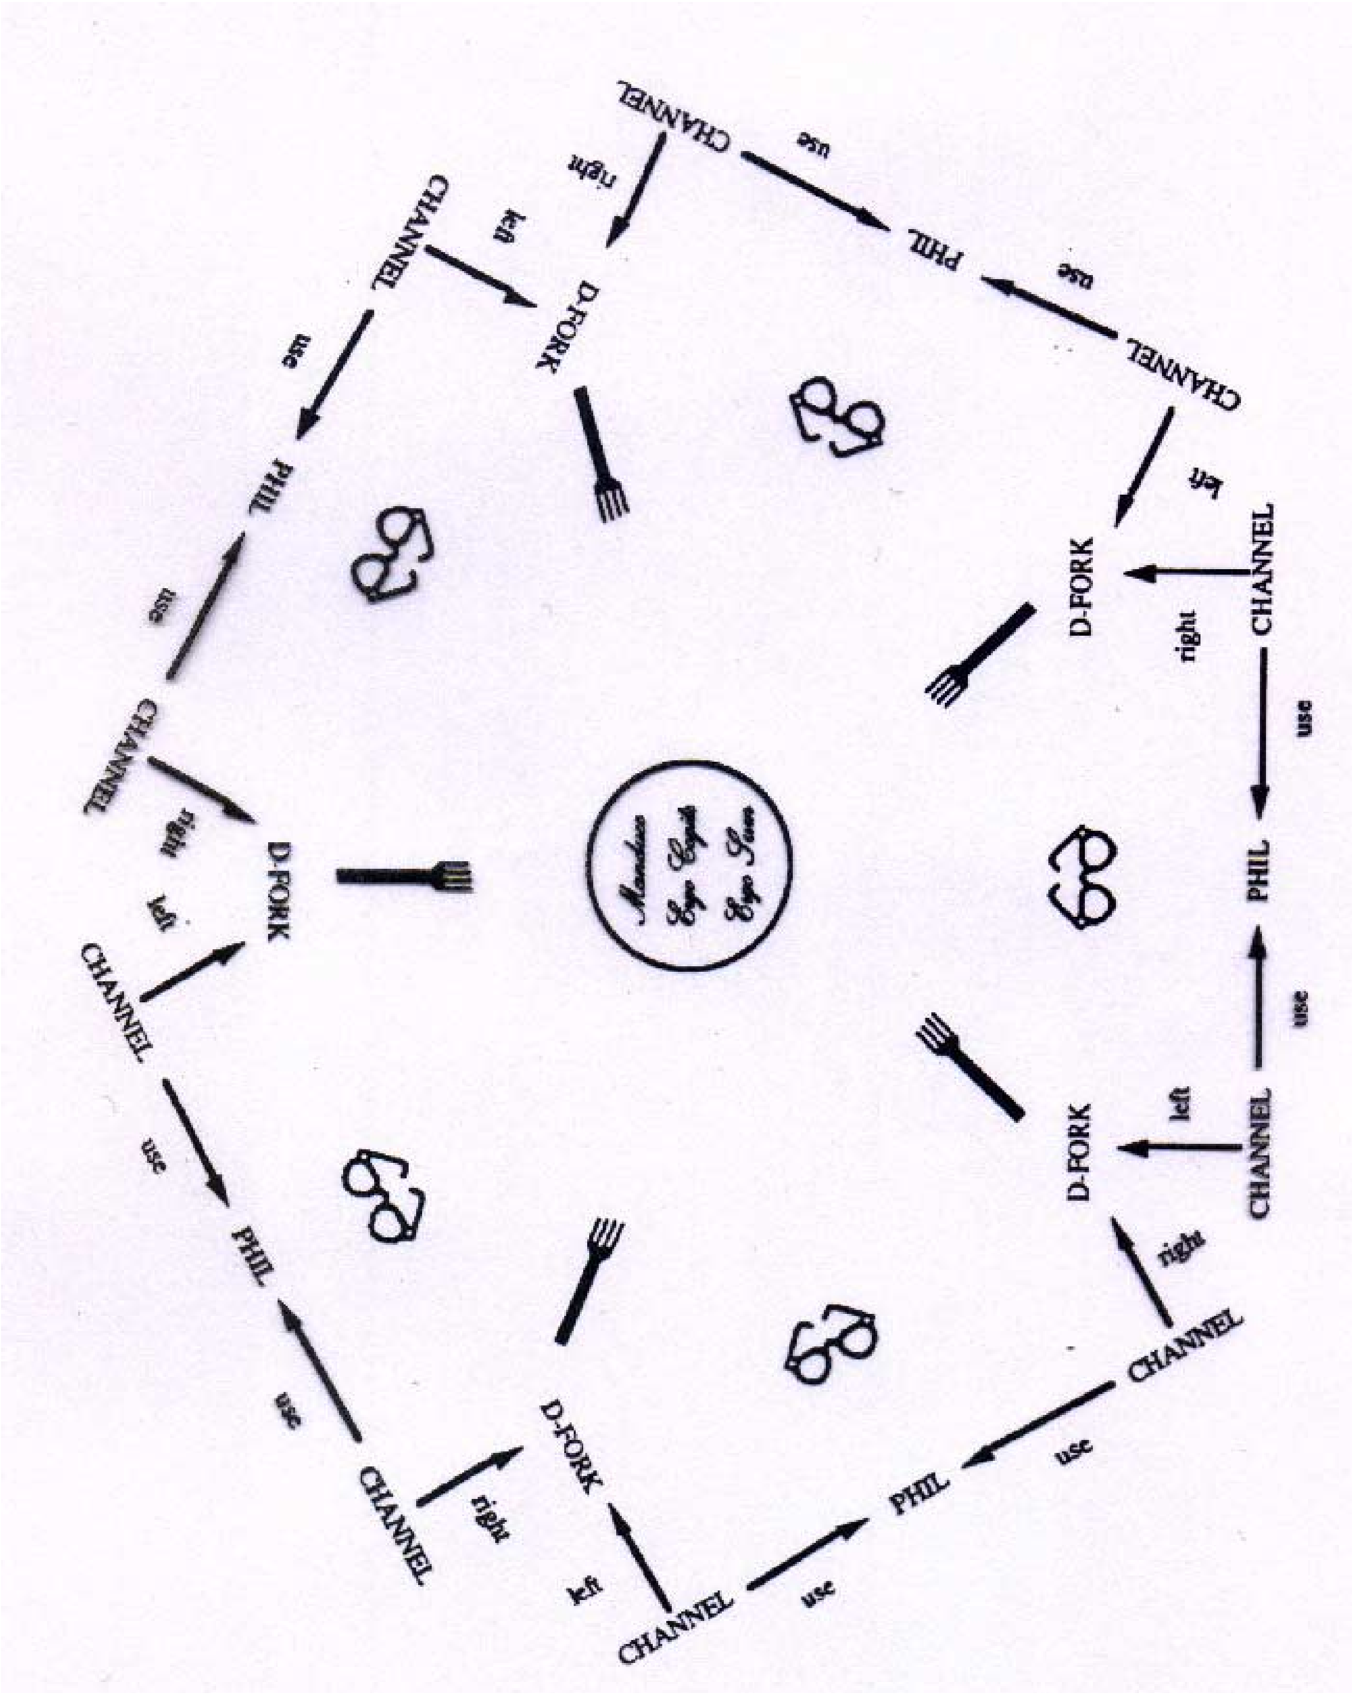

Wie unterscheidet sich die Synchronisation in DBS?

Einbettung des DB-Schedulers

- **Stark vereinfachtes Modell**

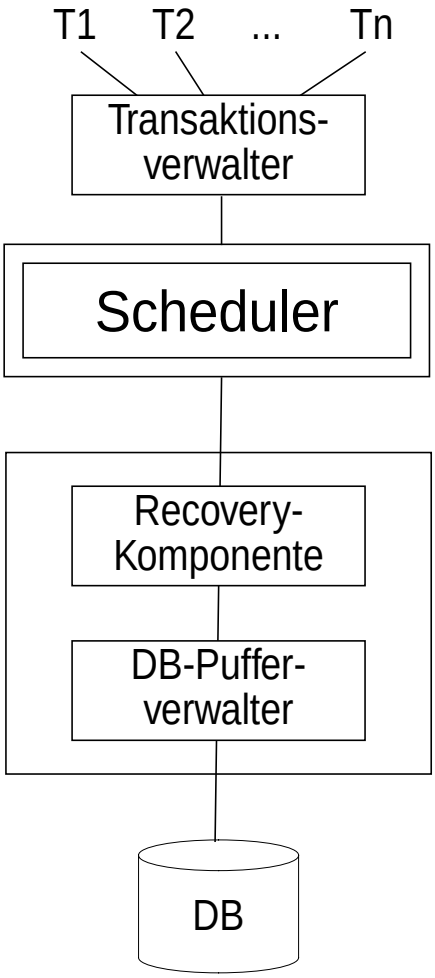

- **Welche Aufgaben hat der Scheduler?**
  - als Komponente der Transaktionsverwaltung zuständig für **I** von **ACID**
  - kontrolliert die beim TA-Ablauf auftretenden Konfliktoperationen (R/W, W/R, W/W) und garantiert insbesondere, daß nur „serialisierbare“ TA erfolgreich beendet werden
  - Nicht serialisierbare 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

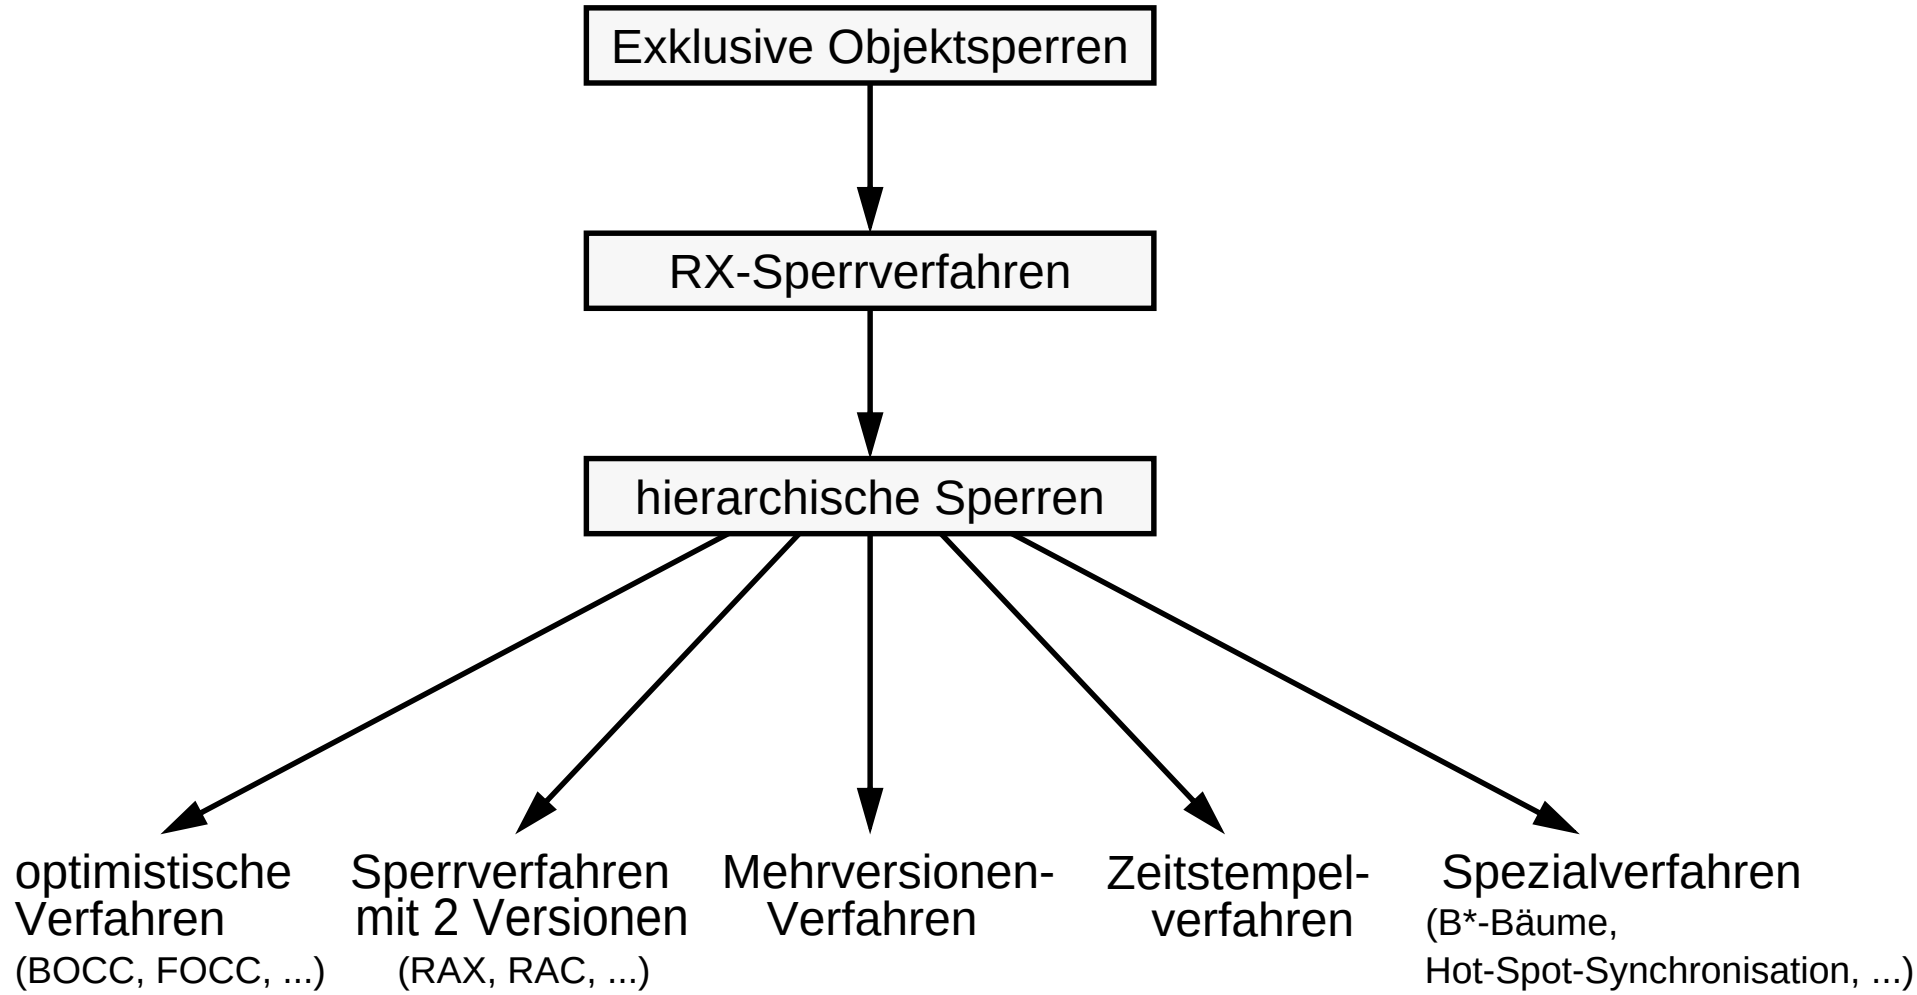

RX-Sperrverfahren

- **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

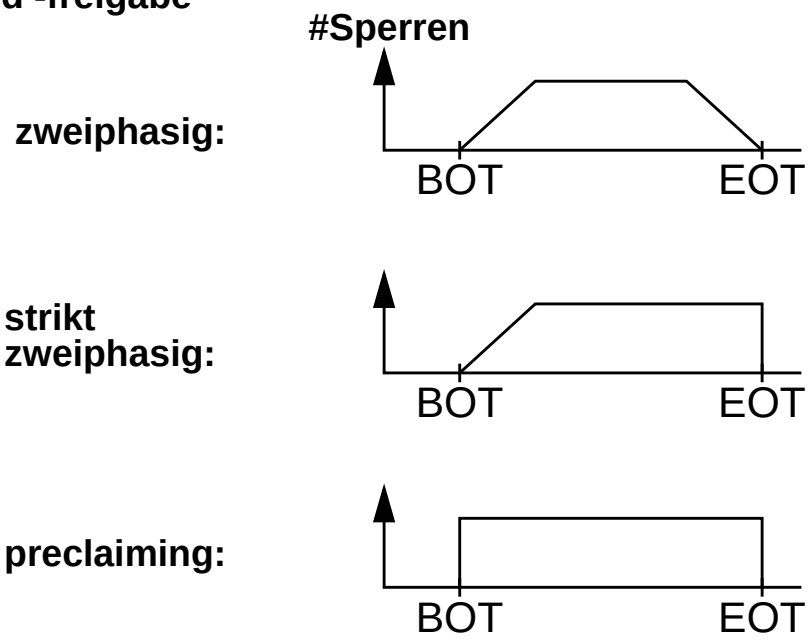

- **Anwendung des 2PL-Protokolls**

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**

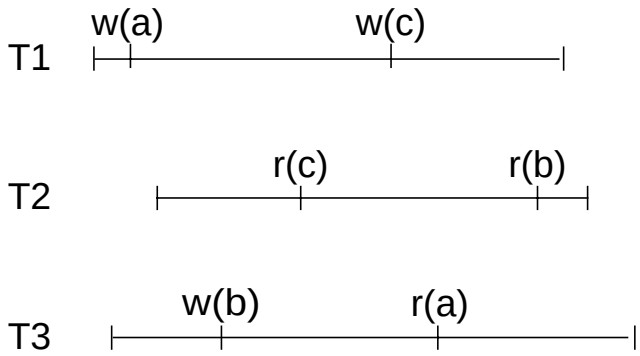

SG

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

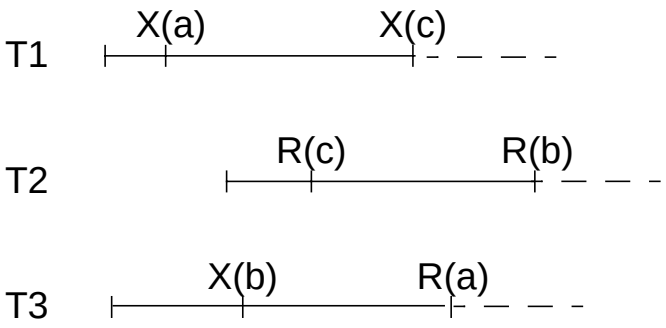

WfG

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**

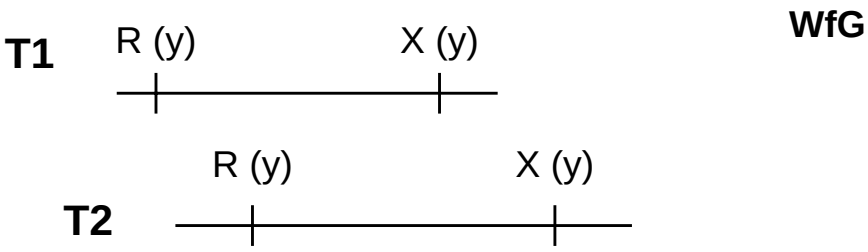

- **Erweitertes Sperrverfahren:**
  - Ziel: Verhinderung von Konversions-Deadlocks
  - U-Sperre für Lesen mit Änderungsabsicht (Prüfmodus)
  - bei Änderung Konversion U $\rightarrow$ X, andernfalls U $\rightarrow$ R (downgrading)

- **Wirkungsweise**

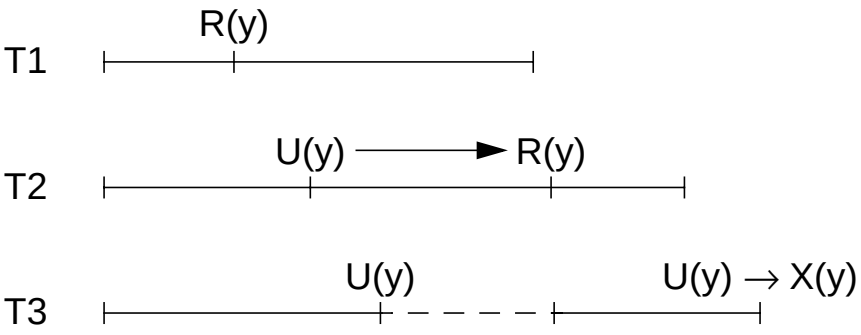

RUX-Sperrverfahren (2)

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

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

- **Beispiel**

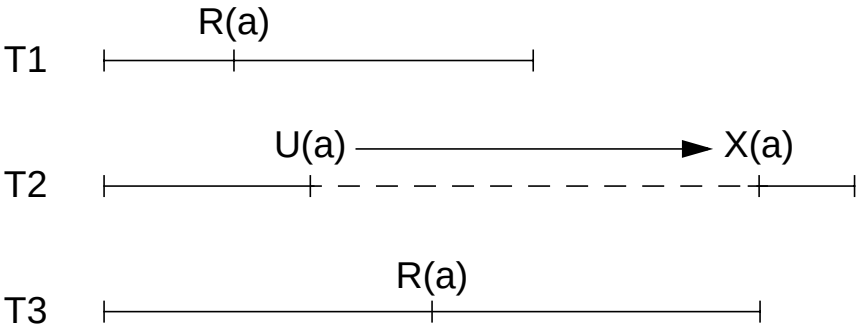

- **Unsymmetrie bei U**

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

  - u. a. in DB2 eingesetzt

- **Beispiel**

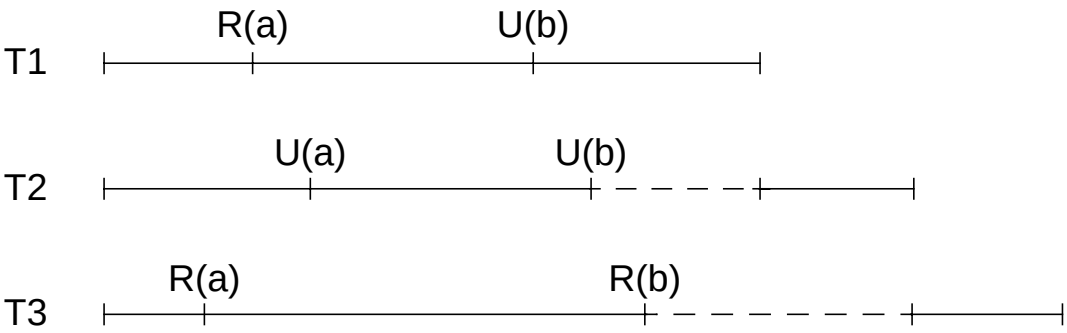

Hierarchische Sperrverfahren

- **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.

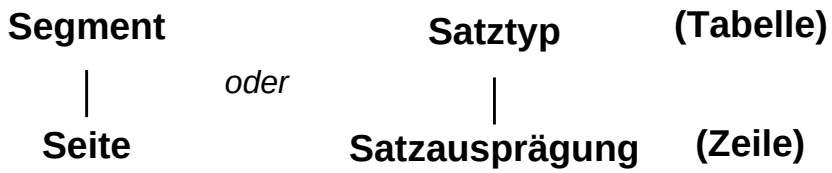

- Verfahren nicht auf reine Hierarchien beschränkt, sondern auch auf halbgeordnete Objektmengen erweiterbar (siehe auch objektorientierte DBS).

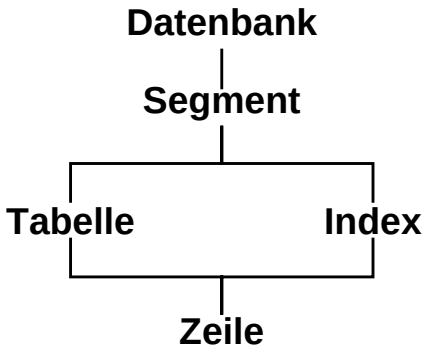

- Verfahren erheblich komplexer als einfache Sperrverfahren (mehr Sperrmodi, Konversionen, Deadlock-Behandlung, ...)

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	-	-	-

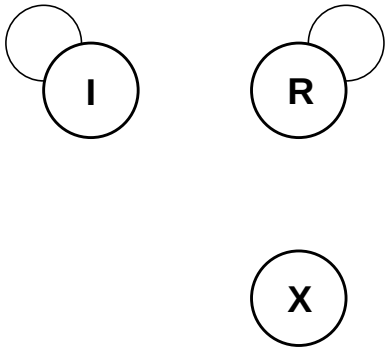

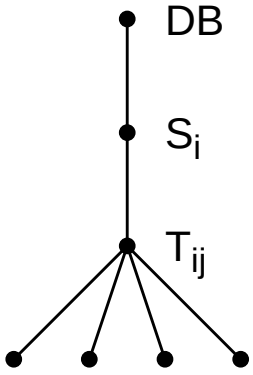

- Unverträglichkeit von I- und R-Sperren: zu restriktiv!

  ➥ zwei Arten von Anwartschaftssperren (IR und IX)

Anwartschaftssperren (2)

- **Anwartschaftssperren für Leser und Schreiber**

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

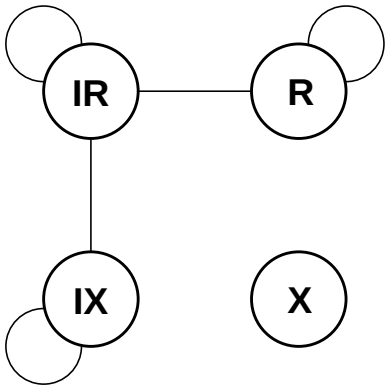

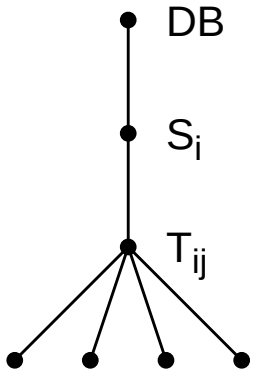

- IR-Sperre (intent read), falls auf untergeordneten Objekten nur lesend zugegriffen wird, sonst IX-Sperre

- 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	-	-	-	-	-	-

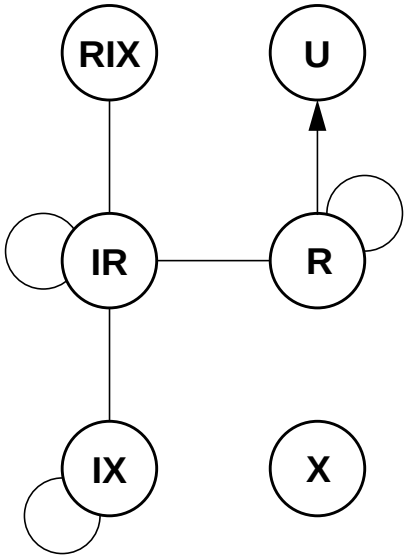

- **'Sperrdisziplin' erforderlich**
  - Sperranforderungen von der Wurzel zu den Blättern
  - Bevor T eine R- oder IR-Sperre für einen Knoten anfordert, muß sie für alle Vorgängerknoten IX- oder IR-Sperren besitzen
  - Bei einer X-, U-, RIX- oder IX-Anforderung müssen alle Vorgängerknoten in RIX oder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

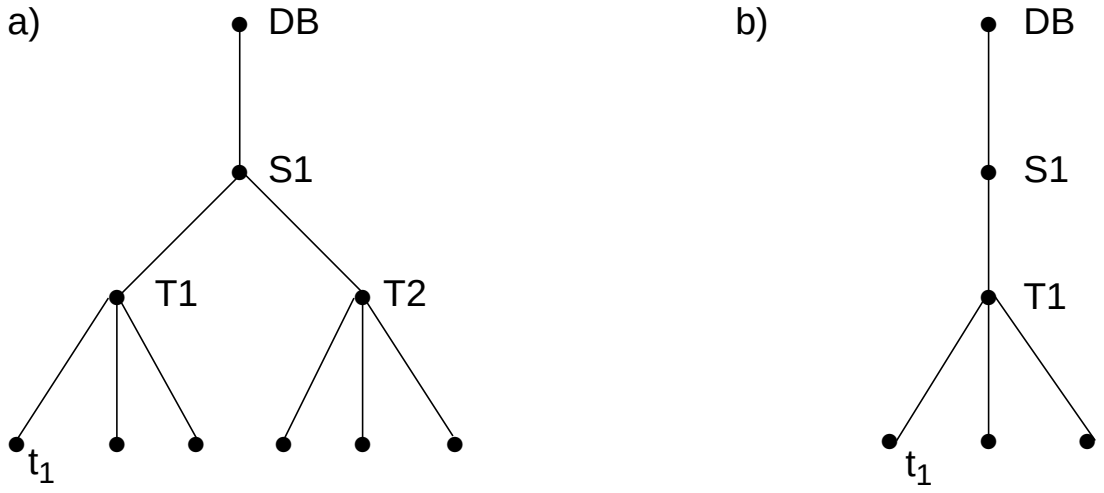

- **RIX-Modus**
  - TA1 liest alle Zeilen von T1 und ändert t_3
  - a) TA2 liest T1
  - b) TA3 liest t_2 in T1

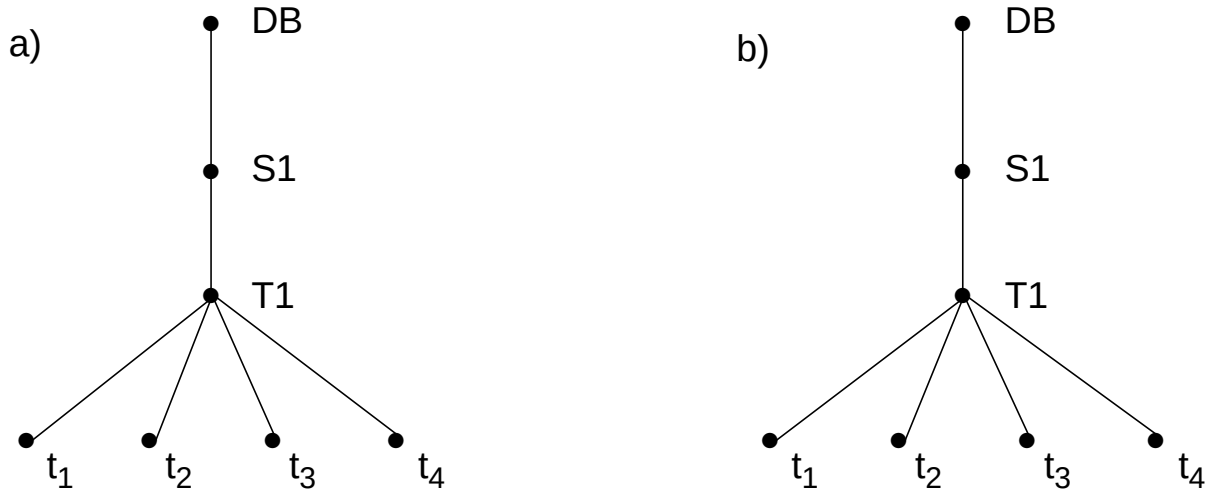

Hierarchische Sperren in OODBS

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

- **Generalisierungshierarchie**

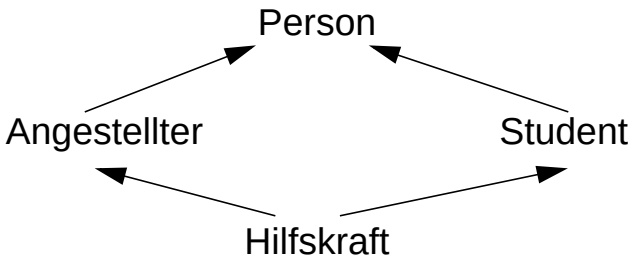

  ➥ **Probleme durch Mehrfachvererbung**

- **Aggregationshierarchie**

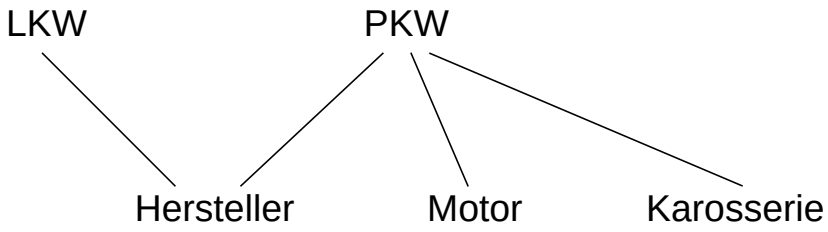

  ➥ **Probleme durch gemeinsam genutzte Komponentenobjekte**

  - 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

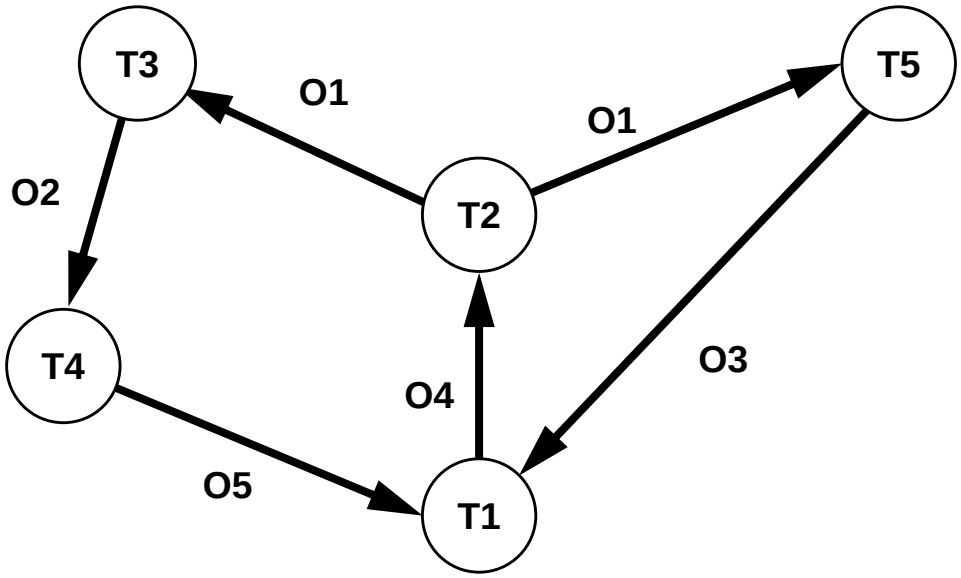

- **Deadlock-Auflösung** durch Zurücksetzen einer oder mehrerer am Zyklus beteiligter TA

  (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

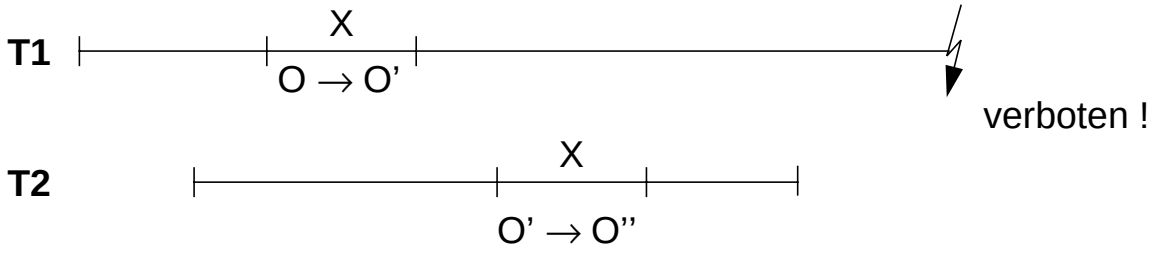

KE1: lange X, keine R

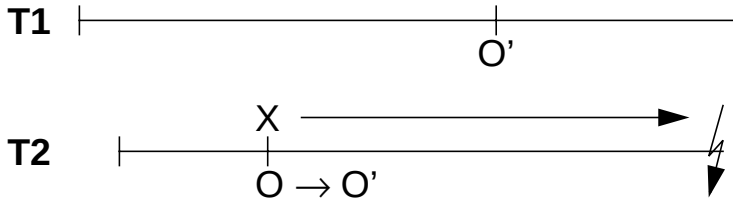

KE2: lange X, kurze R

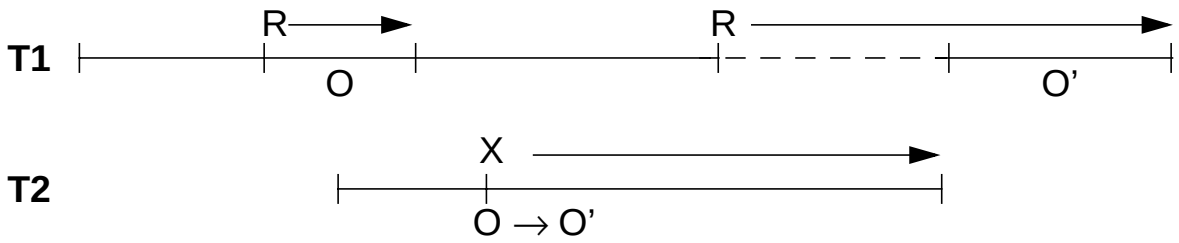

KE3: lange X, lange R

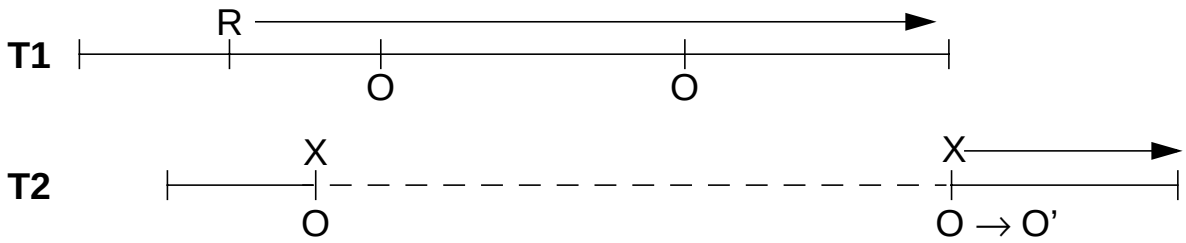

Konsistenzebenen (3)

- ***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**[1] (serializable)

1. Repeatable Read entspricht Read Stability und Serializable entspricht Repeatable Read in DB2

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

    Datenstruktur: O1 O2 . . Zugriff mit Get Next

  - **Serializable**
    garantiert Abwesenheit von Phantomen

Optimistische Synchronisation (OCC)

- **3-phasige Verarbeitung:**

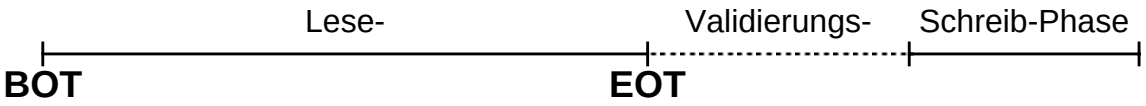

- **Lesephase**
  - eigentliche TA-Verarbeitung
  - Änderungen einer Transaktion werden in privatem Puffer durchgeführt

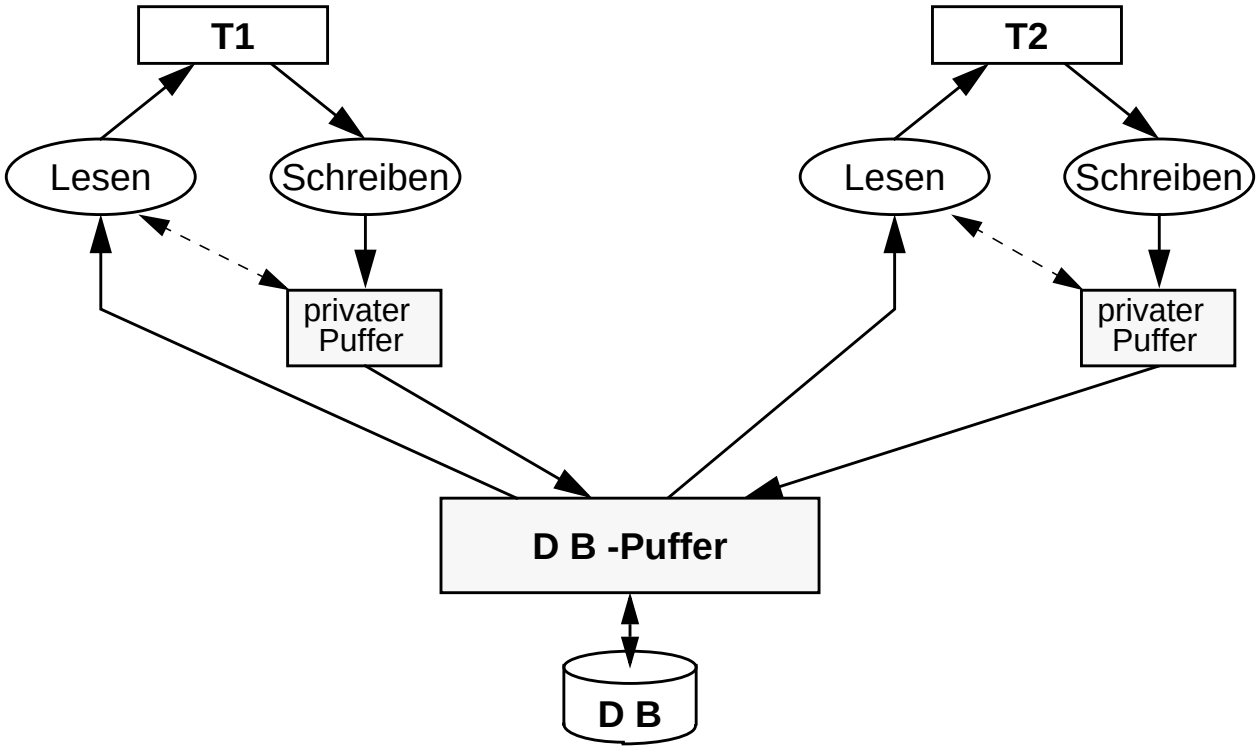

- **Validierungsphase**
  - Überprüfung, ob ein Lese-/Schreib- oder Schreib-/Schreib-Konflikt mit einer der parallel ablaufenden Transaktionen passiert ist
  - Konfliktauflösung durch Zurücksetzen von Transaktionen
- **Schreibphase**
  - nur bei positiver Validierung
  - Lese-Transaktion ist ohne Zusatzaufwand 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

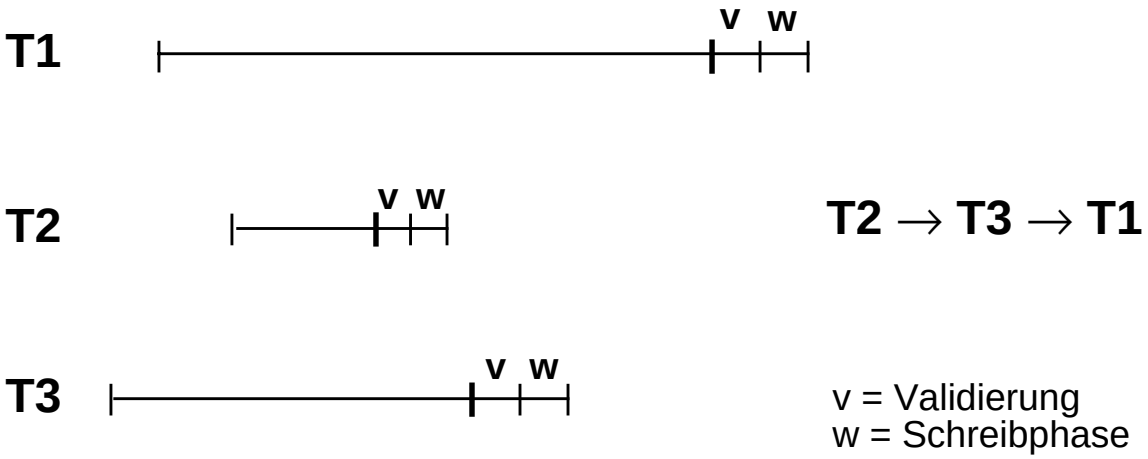

- **Nachteile/Probleme:**
  - unnötige Rücksetzungen wegen ungenauer Konfliktanalyse
  - Aufbewahren der Write-Sets beendeter TA erforderlich
  - hohe Anzahl von Vergleichen bei Validierung
  - Rücksetzung erst bei EOT ➥ viel unnötige Arbeit
  - Nur die validierende TA kann zurückgesetzt werden
    ➥ 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**

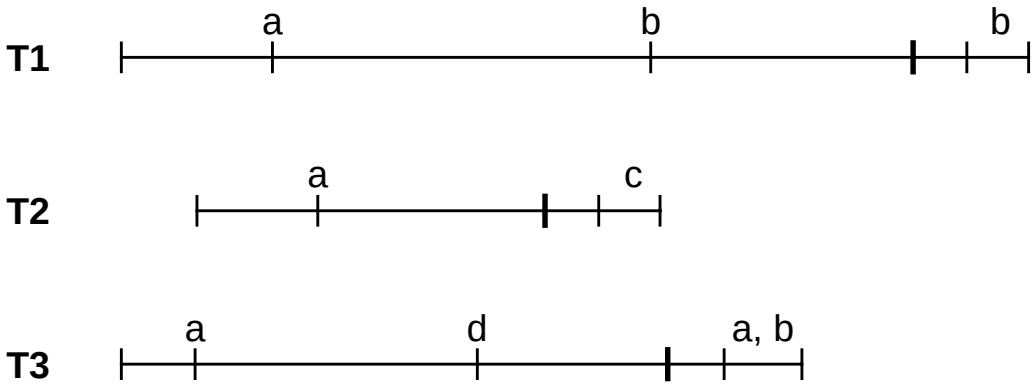

➥ Validierung von T1:

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

- **Optimierung von BOCC**

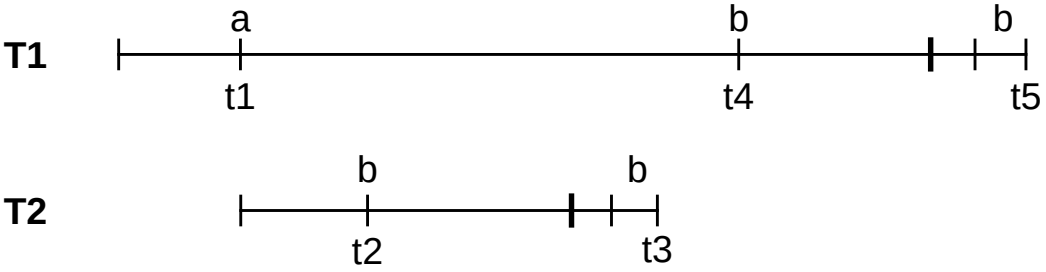

Zeitstempel in WS (Schreibzeitpunkt) und in RS (erste Referenz)

➥ Validierung von T1:

T1 : RS

T2 : WS

RS(T1) ∩ WS(T2) =

Zusätzliche Prüfung

Write(T2) = Ref(T1) =

BOCC+

- **Variation des Verfahrens**
  - Konflikterkennung über Zeitstempel (Änderungszähler) statt Mengenvergleich
  - erfolgreich validierte TA erhalten eindeutige, monoton wachsende TA-Nummer
  - geänderte Objekte erhalten TA-Nummer der ändernden TA als Zeitstempel TS zugeordnet
  - beim Lesen eines Objektes wird Zeitstempel ts der gesehenen Version im Read-Set vermerkt
  - **Validierung** überprüft, ob gesehene Objektversionen zum Validierungszeitpunkt noch aktuell sind:

```
    VALID := true
<<  forall  r  in  RS (T)  do;
        if  ts (r,T)  <  TS (r)  then  VALID := false;
    end;
    if    VALID  then do;
        TNC  :=  TNC + 1;  {ergibt  TA-Nummer für T}
        for  all  w  in  WS (T) do;
            TS (w)  := TNC;
            setze alle laufenden TA mit w in RS zurück;
        end;  >>
        Schreibphase für T;
    end;
    else  (setze  T  zurück);
```

  - Zeitstempel TS für geänderte Objekte können zur Durchführung der Validierungen in **Objekttabelle** geführt werden

BOCC+ (2)

- **Vorteile**
  - Zum Scheitern verurteilte TA können sofort zurückgesetzt werden
  - keine unnötigen Rücksetzungen
  - sehr schnelle Validierung

- **Probleme:**
  - wie bei BOCC ist ’starvation’ einzelner TA möglich
  - potentiell hohe Rücksetzrate

- **Lösungsmöglichkeiten:**
  - Reduzierung der Konfliktwahrscheinlichkeit, z.B. durch
    - geringere Konsistenzebene
      (Lese-TA werden bei Validierung nicht mehr berücksichtigt)
    - Mehrversionen-Verfahren
  - Kombination mit Sperrverfahren

F O C C[1]

- Nur Änderungs-TA validieren gegenüber laufenden TA T_i

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

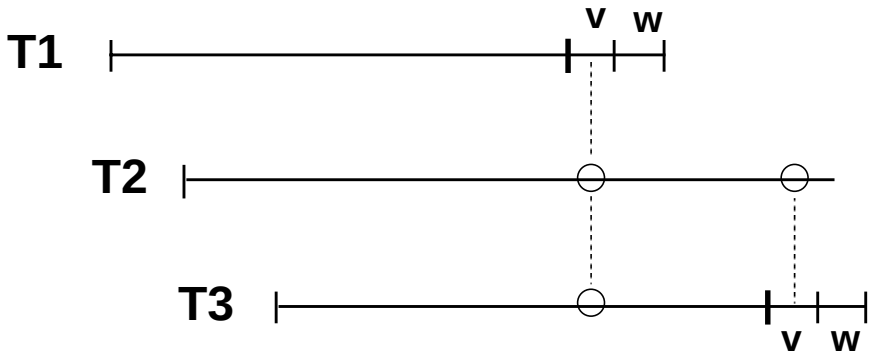

- **Vorteile:**
  - Wahlmöglichkeit des Opfers (Kill, Abort, Prioritäten, ...)
  - keine unnötigen Rücksetzungen
  - frühzeitige Rücksetzung möglich
    ➥ Einsparen unnötiger Arbeit
  - keine Aufbewahrung von Write-Sets,
    geringerer Validierungsaufwand als bei BOCC

- **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**

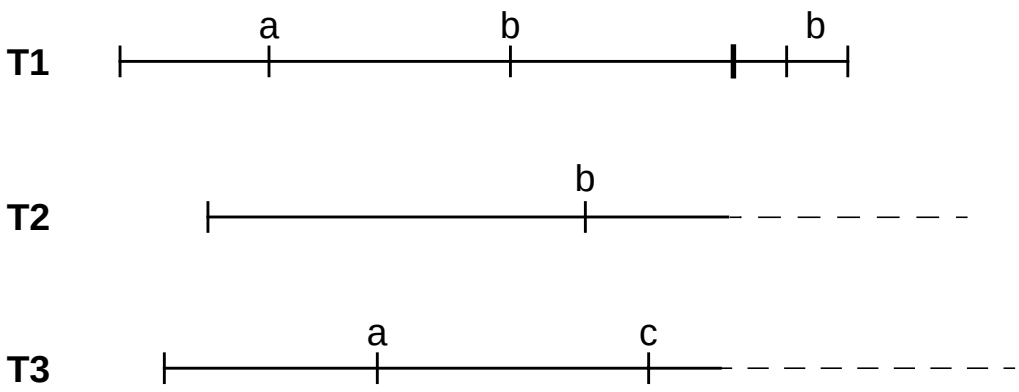

➥ Validierung von T1:

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

- **Mögliche Lösungen**

Kombination von OCC und Sperrverfahren

- **Ziel: Vorteile beider Verfahrensklassen kombinieren**
  - geringe Rücksetzhäufigkeit von Sperrverfahren
  - hohe Parallelität (weniger Sperrwartezeiten) von OCC

- Kombination kann auf verschiedenen Ebenen realisiert werden

  1. **TA-Ebene:**
     - optimistisch und pessimistisch synchronisierte TA
     - für lange TA, die bereits gescheitert waren, wird pessimistische Synchronisation eingesetzt
       ➥ keine Starvation

  2. **Objekt-Ebene:**
     - optimistisch und pessimistisch synchronisierte Datenobjekte
     - pessimistische Synchronisation für Hot-Spot-Objekte

  3. **Kombination**

- **Erhöhte Verfahrenskomplexität**
  - auch bei pessimistischer Synchronisation Änderungen in privatem TA-Puffer
  - erweiterte Validierung:
    TA scheitert, falls unverträgliche Sperre gesetzt ist
  - (teilweise) pessimistisch synchronisierte TA:
    - bei EOT optimistische TA zurücksetzen, die auf X-gesperrte Objekte zugegriffen haben
    - Schreibphase mit anschließender Sperrfreigabe

Sperrverfahren mit Versionen (RAX)

- **Kompatibilitätsmatrix:**

	R	A	X
R	+	⊕	-
A	⊕	-	-
X	-	-	-

- **Ablaufbeispiel**

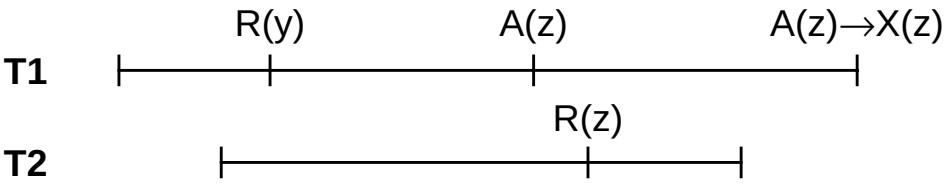

RAX: T2 → T1

- **Änderungen erfolgen in temporärer Objektkopie**

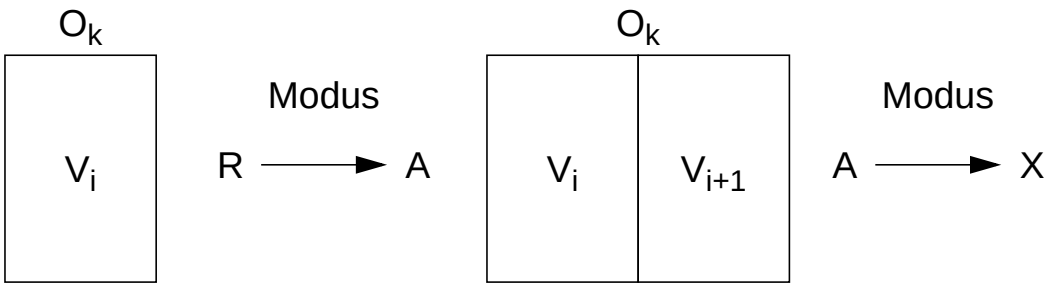

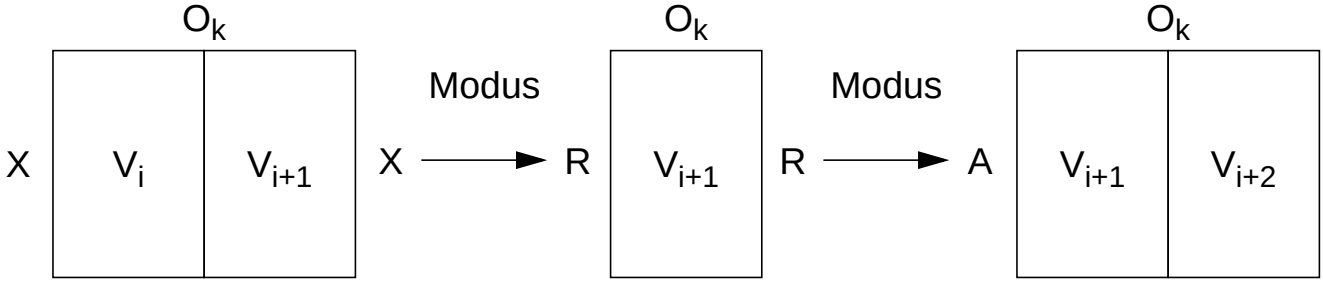

RAX (2)

- **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:

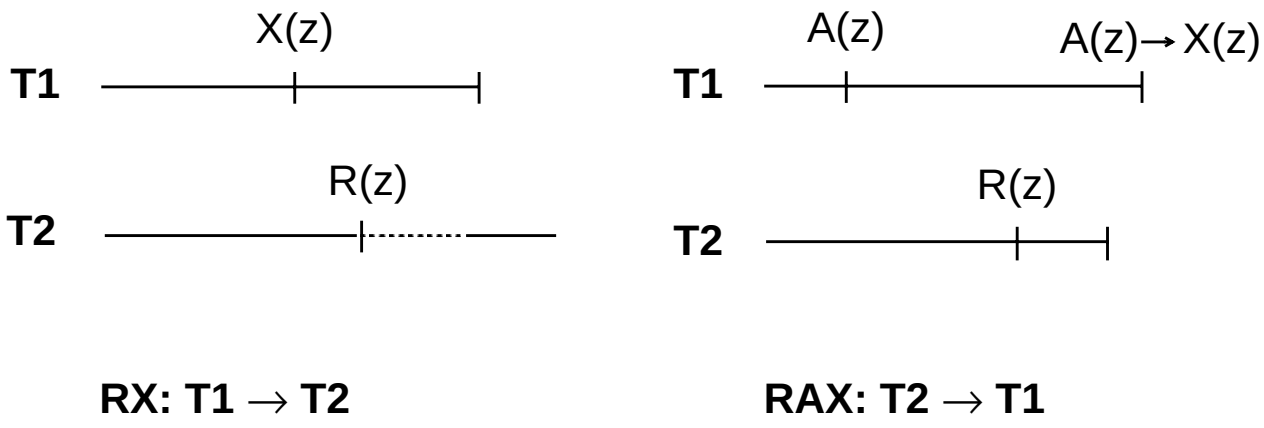

RX: T1 → T2 **RAX: T2 → T1**

- **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**

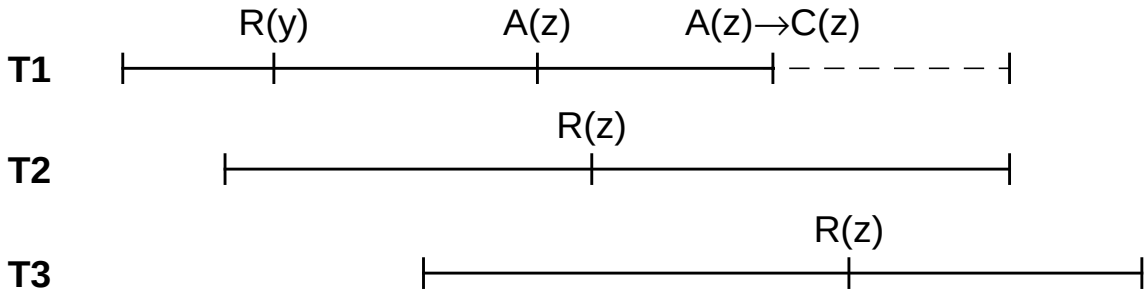

RAC: T2 → T1 → T3

- **Änderungen erfolgen ebenfalls in temporärer Objektkopie**

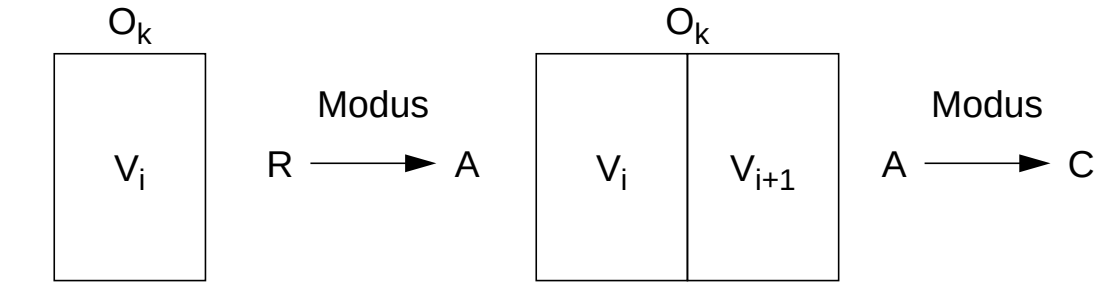

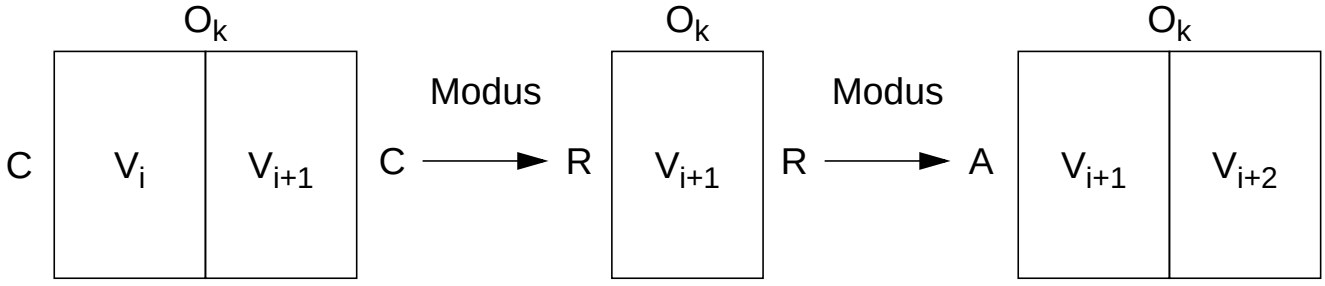

RAC (2)

- **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

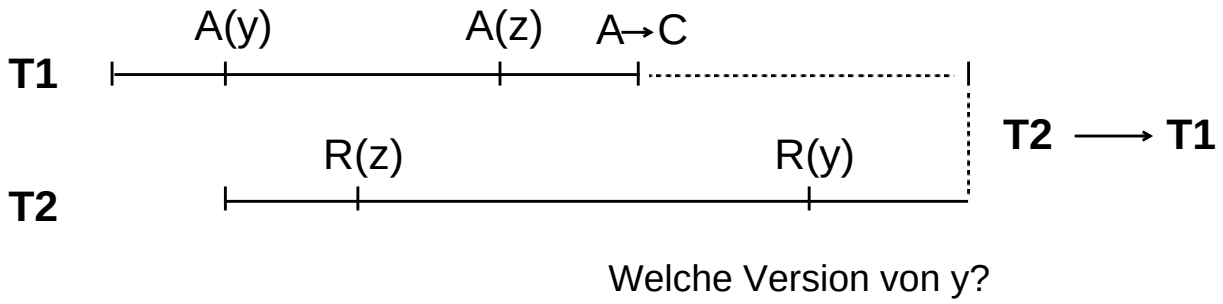

  ➥ Kein Warten auf Freigabe von Lesesperren auf alter Version (R- und C-Modus sind verträglich)

- **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 keine Blockierungen und Rücksetzungen für Lese-TA, dafür ggf. Zugriff auf veraltete Objektversionen
- **Beispiel für Objekt O_k**

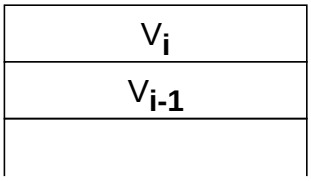

Zeitliche Reihenfolge der Zugriffe auf O_k

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)

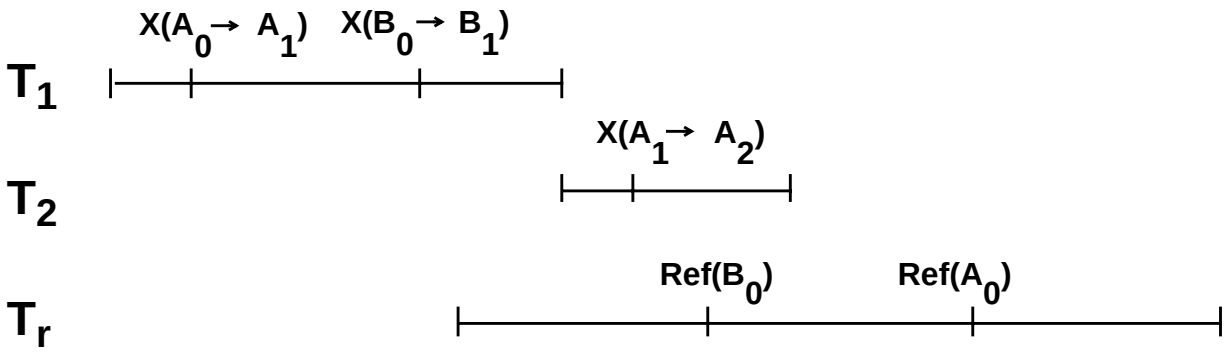

- **Konsequenz**
  - Lese-TA werden bei der Synchronisation nicht mehr berücksichtigt
  - Änderungs-TA werden untereinander über ein allgemeines Verfahren (Sperren, OCC, . . .) synchronisiert

➥ **deutlich weniger Synchronisationskonflikte**

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

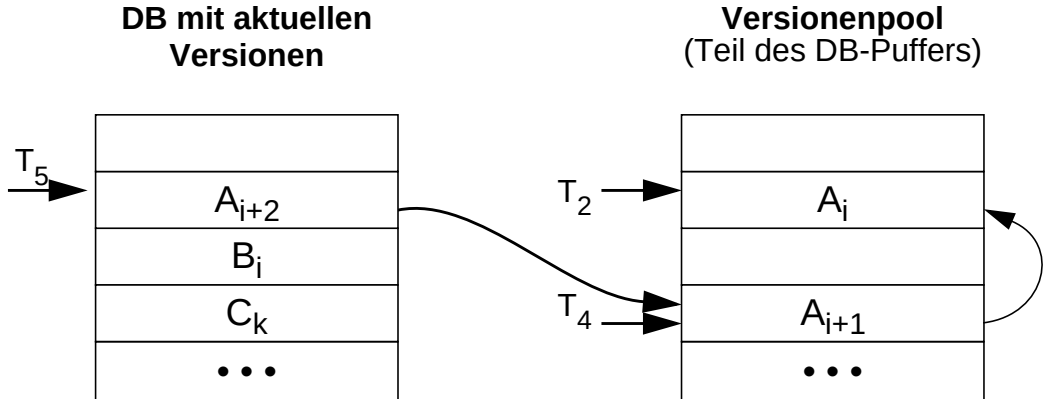

  - Speicherplatzoptimierung: Versionen auf Satzebene, Einsatz von Komprimierungstechniken
  - Was passiert, wenn Implementierung auf n Versionen begrenzt ist?

- 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):

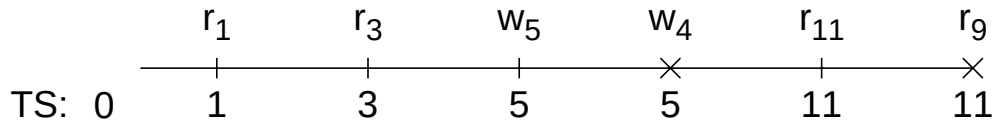

  ➥ kein Konflikt bei r_9!

- **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:**

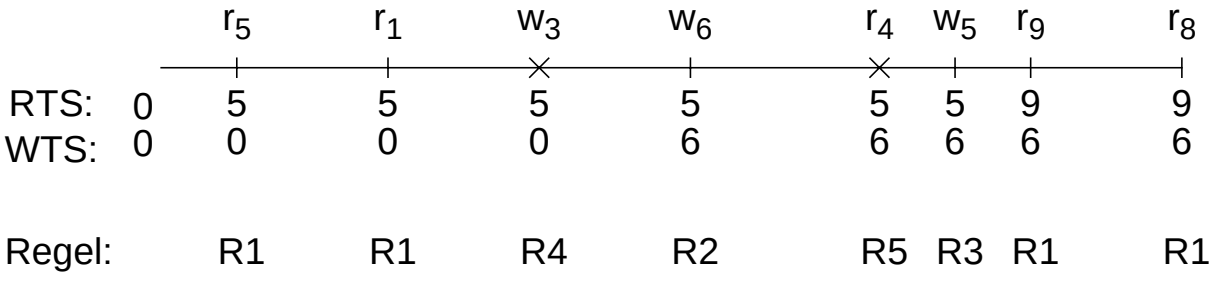

1. Diese Regel wird in der Literatur mit “Thomas’ Write Rule” bezeichnet

Zeitstempelverfahren (3)

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

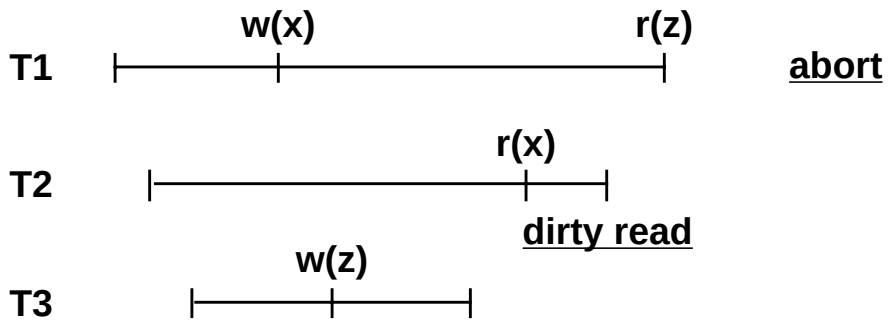

- **Vorkehrungen für den ABORT-Fall**
  - Sofortige Zulassung aller Schreiboperationen erzeugt inkonsistente DB
  - Einfrieren der Zeitstempel bis COMMIT der ändernden TA
  - Basic Timestamp Ordering (BTO)[1] schlägt Lösung mit Sperrverfahren und Verwaltung komplexer Abhängigkeiten vor

- **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:**

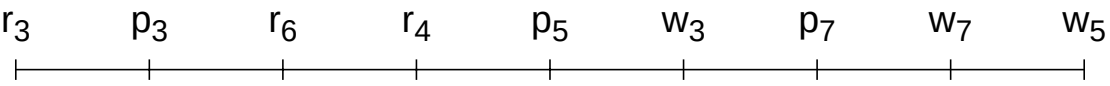

RTS:	2	3		3		3		3	4	4		4	4 6 6
WTS:	1	1		1		1		1	3 3	3		3	5 5 7
R-Q:					6		4 6	4 6	6	6		6	
P-Q:			3				3 5	5	5 7	5 7		7	7
W-Q:										7		7	7

➥ 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**

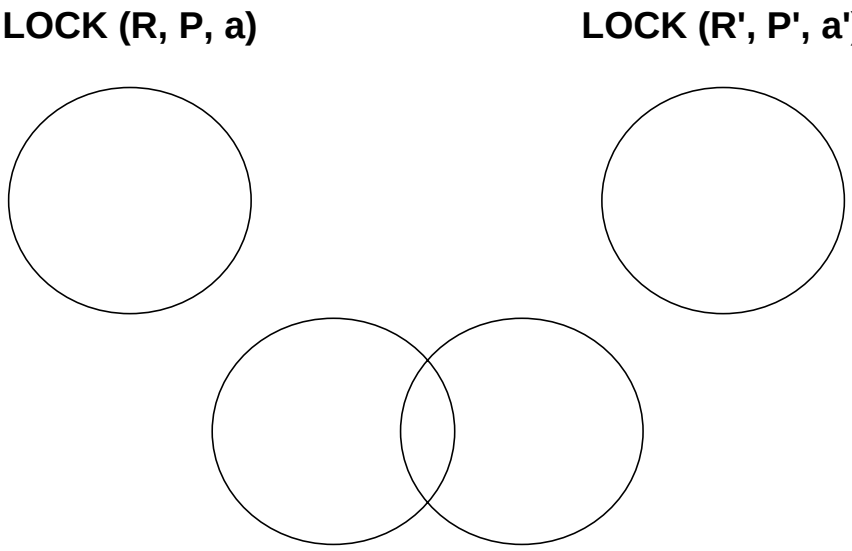

1. Wenn R ≠ R', kein Konflikt
2. Wenn a = read und a' = read, kein Konflikt
3. Wenn P(t) ∧ P'(t) = TRUE für irgendein t, dann besteht ein Konflikt

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

Semantische Synchronisationsverfahren

- **Erhöhung der Parallelität** durch Einführung kommutativer („semantischer“) DB-Operationen als Einheit für die Synchronisation
  - Synchronisation erfolgt auf abstrakterer Ebene (Objektebene)
  - Realisierung muß auf niedrigerer Ebene Korrektheit gewährleisten (z. B. durch Escrow-Verfahren)

- **Beispiel**

  Zwei Kontobuchungen auf Konten K1 und K2 durch die TA T1 und T2, die kommutative Operationen „erhöhe um x“ und „vermindere um x“ verwenden, könnten z.B. in folgenden Reihenfolgen ausgeführt werden:

Schedule S1	Schedule S2
1. erhöhe (T1,K1,x1)	1. erhöhe (T1,K1,x1)
2. vermindere (T1,K2,x1)	2. erhöhe (T2,K1,x2)
3. erhöhe (T2,K1,x2)	3. vermindere (T2,K2,x2)
4. vermindere (T2,K2,x2)	4. vermindere (T1,K2,x1)

  ➥ Schedule S1 wäre auch mit rein syntaktischen Verfahren (r/w) erzeugbar:

$$\underbrace{<r_1[K_1]\ w_1[K_1]}_{\text{erhöhe}(T_1,K_1,x_1)}\quad \underbrace{r_1[K_2]\ w_1[K_2]}_{\text{vermindere}(T_1,K_2,x_1)}\quad \underbrace{r_2K_1]\ w_2[K_1]}_{\text{erhöhe}(T_2,K_1,x_2)}\quad \underbrace{r_2[K_2]\ w_2[K_2]>}_{\text{vermindere}(T_2,K_2,x_2)}.$$

  Schedule S2 wäre hingegen mit rein syntaktisch arbeitenden Verfahren nicht erzeugbar.

Synchronisation von High-Traffic-Objekten

- **High-Traffic-Objekte**
  - auch Hot Spots genannt: Datenelemente, auf die viele TA ändernd zugreifen müssen
  - können leicht einen Systemengpaß bilden
  - meist numerische Felder mit aggregierten Informationen z. B.
    - Anzahl freier Plätze
    - Summe aller Kontostände
  - aber auch DBS-interne Strukturen und Systemressourcen
    - Wurzeln von Bäumen (erfordern spezielle Protokolle)
    - Log-Datei, Sperrtabelle, DB-Puffer usw.

  ➥ bei ungeschickter TA-Schedulingstrategie (FIFO) besteht Gefahr der Ausbildung langer TA-Warteschlangen (**Konvoiphänomen**)

- **Einfachste Lösung der Synchronisationsprobleme**
  - Vermeidung solcher Datenelemente beim DB-Entwurf
  - Einsatz von speziellen Sperren und angepaßten Schedulingstrategien bei Systemressourcen

Synchronisation von High-Traffic-Objekten (2)

- **Was läßt sich auf SQL-Ebene tun?**
  - Modifikation eines Feldes FreiePlätze

```
exec sql    select FreiePlätze
            into   :anzahl
            from Flüge
            where FlugNr = 'LH127';
anzahl := anzahl-2;
exec sql    update Flüge
            set FreiePlätze = :anzahl
            where FlugNr = 'LH127';
```

➥ Deadlock-Gefahr wegen Sperrkonversion.
Erhöhung dieser Gefahr wegen Hot Spot

  - **Verbesserung**

```
exec sql    update Flüge
            set FreiePlätze = FreiePlätze-2
            where FlugNr = 'LH127';
```

➥ keine Deadlock-Gefahr, nur noch möglicherweise
langes Warten auf Commit der Vorgänger-TAs.

Synchronisation von High-Traffic-Objekten (3)

- **Spezielle Behandlung von Hot Spots**
  - erfordert Systemmodifikation
  - Aktion auf Hot Spot wird in zwei Teile zerlegt
    - Testen eines Prädikats
    - Durchführung der Transformation
  - Beispiel:

```
exec sql    update hotspot Flüge
            set         FreiePlätze = FreiePlätze-2
            where       FlugNr = 'LH127'
            and         FreiePlätze   2;
```

- **Ablauf des Feldzugriffs**
  1. Beim Zugriff erfolgt der Test des Prädikats unter einer kurzen Lesesperre
  2. Falls der Test zu 'false' evaluiert wird, wird abgebrochen (Exception Handling der Anwendung)
  3. Sonst wird eine Redo-Log-Satz mit Prädikat und Modifikationsoperation angelegt
  4. Beim Erreichen von Commit werden die Transformationen von Hot-Spot-Feldern in zwei Phasen durchgeführt:
     - **Phase 1:** Alle Redo-Log-Sätze der TA, die Commit ausführt, werden abgearbeitet. Für Feldzugriffe, die keine Transformation erfordern, werden Lesesperren angefordert und für die alle anderen Feldzugriffe Schreibsperren. Danach werden alle Prädikate noch einmal evaluiert. Falls mindestens ein Prädikat zu 'false' evaluiert, wird die TA zurückgesetzt.
       Sonst Eintritt in Phase 2.
     - **Phase 2:** Alle Transformationen werden angewendet und die Sperren werden freigegeben.

Synchronisation von High-Traffic-Objekten (4)

- **Beispiel:**
  3 TA werden gleichzeitig aufgerufen, aber sequentiell abgewickelt

T1: FP > 5 ?
FP := FP-5
Commit

T2: FP > 2 ?
FP := FP-2
Commit

T3: FP > 8 ?
FP := FP-8
Commit

- **Beispiel:**
  Spezielle Behandlung von Hot Spots

T1	T2	T3	FP in DB
FP > 5 ?			12
	FP > 2 ? Commit FP > 2 FP := FP-2		
		FP > 8 ?	10
Commit FP > 5 ? FP := FP-5			
		Commit FP > 8 ?	5

Ansatz von IMS Fast Path

- **Spezielle Operationen für High-Traffic-Objekte:**

  V E R I F Y *FreiePlätze > Anforderung*

  M O D I F Y *FreiePlätze := FreiePlätze - Anforderung*

- **Quasi-optimistische Synchronisation:**
  - Zunächst werden keine (langen) Sperren gesetzt
  - Änderungen werden nicht direkt vorgenommen, sondern nur in 'intention list' vermerkt

    ➥ Eine TA sieht bei wiederholtem Zugriff auf ein solches Feld ihre eigenen Änderungen nicht!
  - Bei EOT Validierung- und Schreibphase:
    - Überprüfung, ob VERIFY-Prädikate noch erfüllt sind (geringe Rücksetzwahrscheinlichkeit)
    - MODIFY-Operation vornehmen
    - Sperren werden nur für Dauer der EOT-Behandlung gehalten

➥ **Verkürzung der Dauer exklusiver Sperren**, **weit geringere Konfliktgefahr als bei normalen Schreibsperren**

- **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	**-**	**-**	**+**

➥ Wie sieht das mit der Bereichskontrolle bei solchen Feldern aus?

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 - 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**

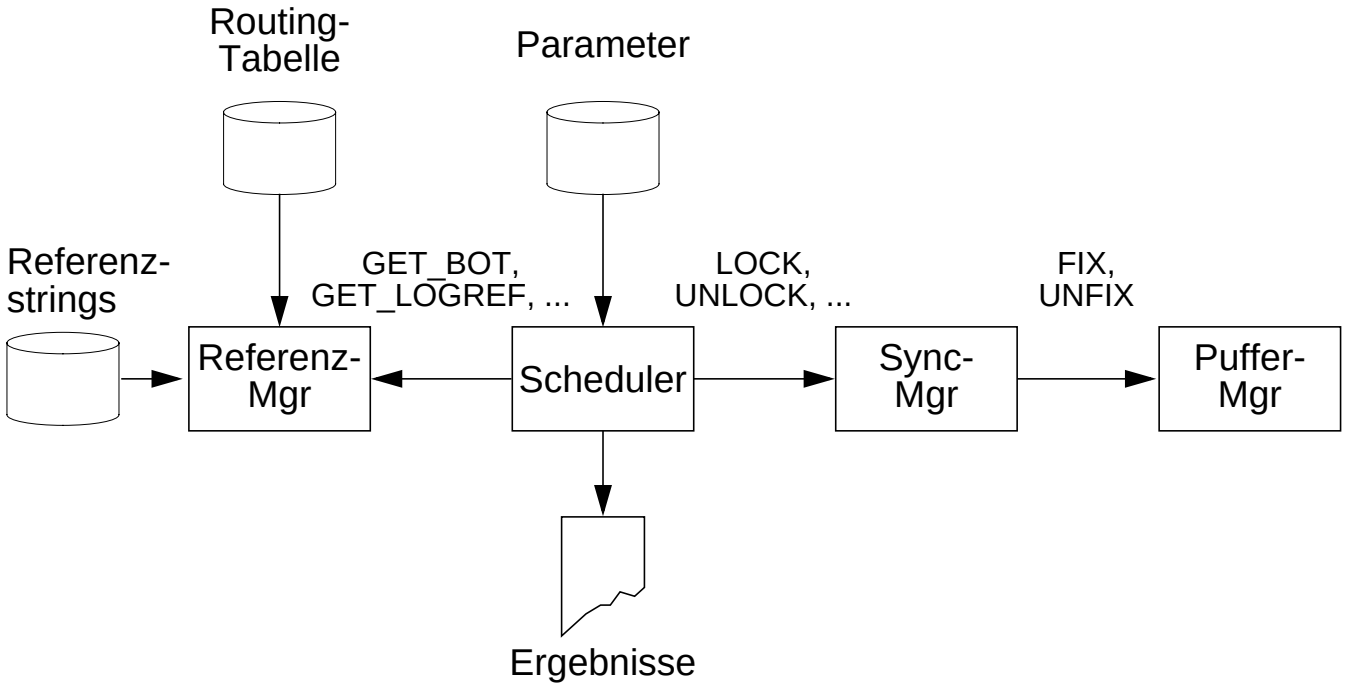

Implementierungsaspekte – Datenstrukturen

- **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

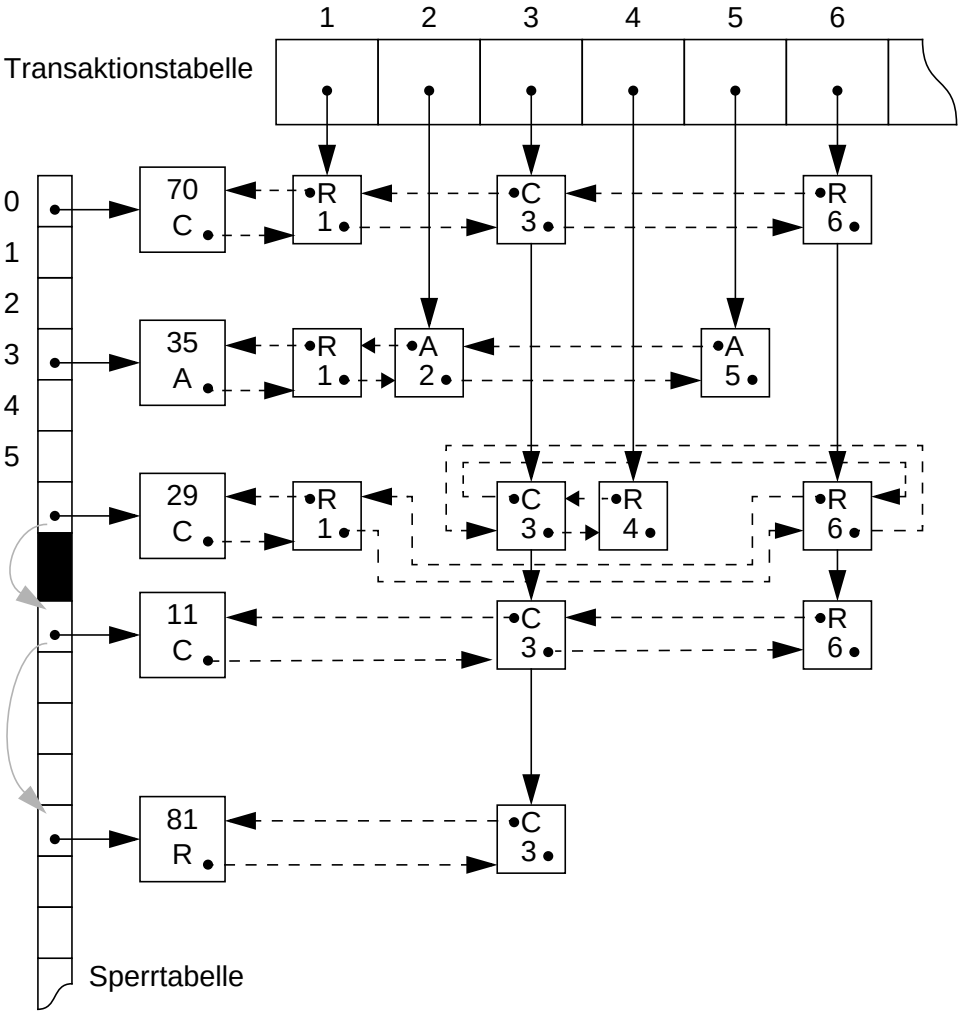

➥ **Beispiel:** Sperrtabelle / TA-Tabelle für RAC-Verfahren

- 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)

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**

Synchronisationsverfahren – Vergleich

Effektive Parallelität

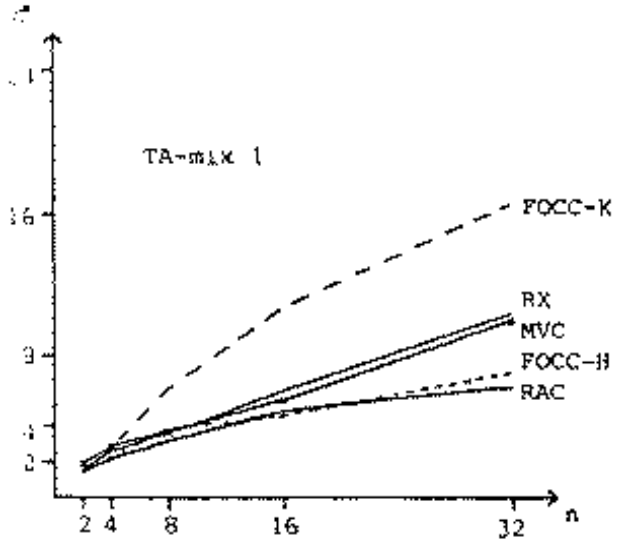

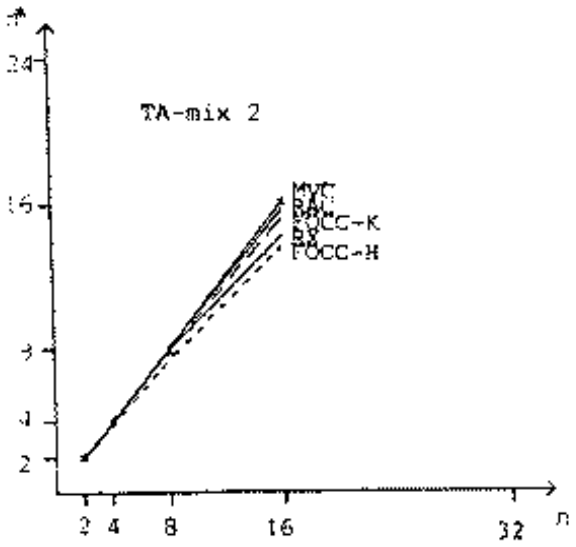

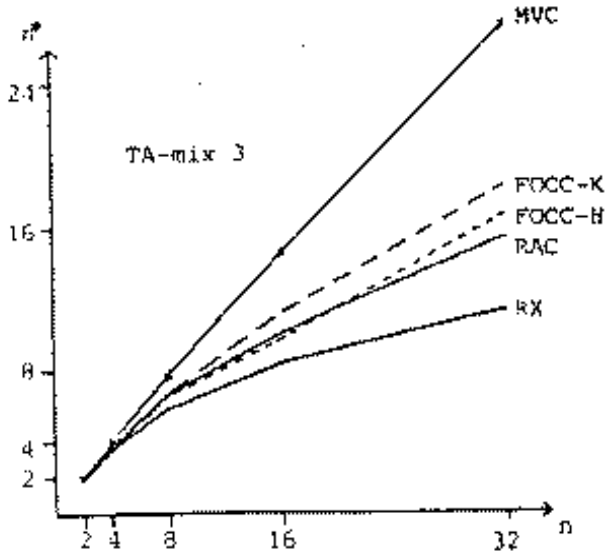

Summe der Deadlocks

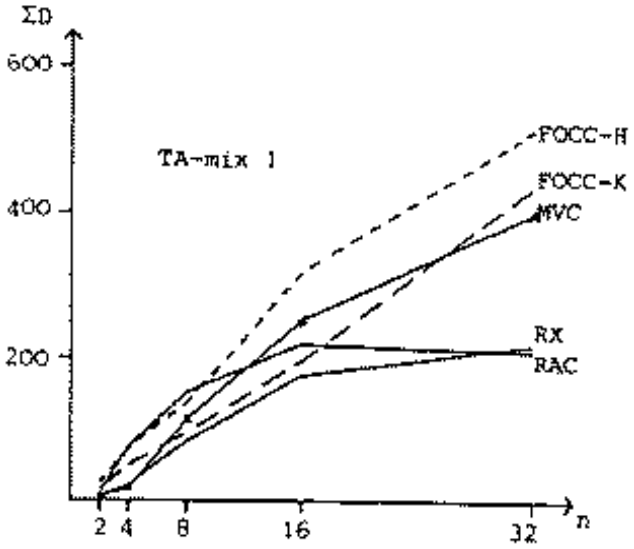

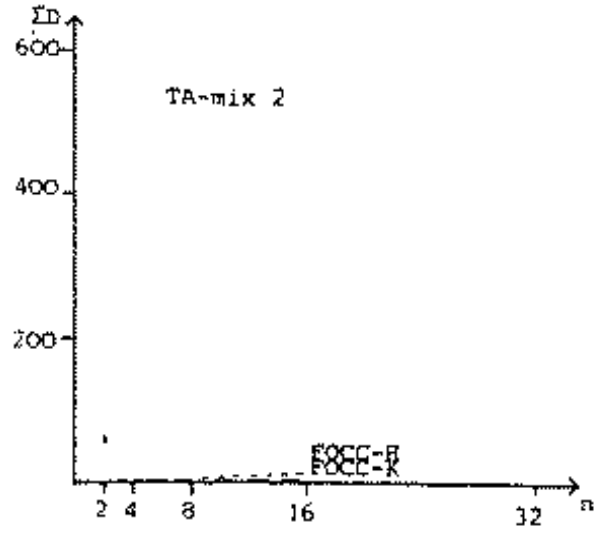

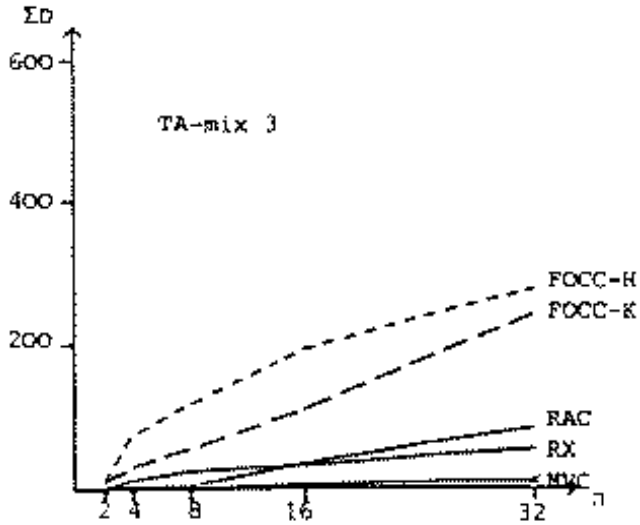

- **Schlußfolgerungen**
  - Sehr geringe Parallelität → keine effektive Nutzung der Ressourcen
  - Geringe Parallelität → bester Durchsatz,
    nicht notwendigerweise kürzeste Antwortzeiten
  - Pessimistische Methoden gewinnen:
    Blockierung vermeidet häufig Deadlocks
  - Optimistische Methoden geraten 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

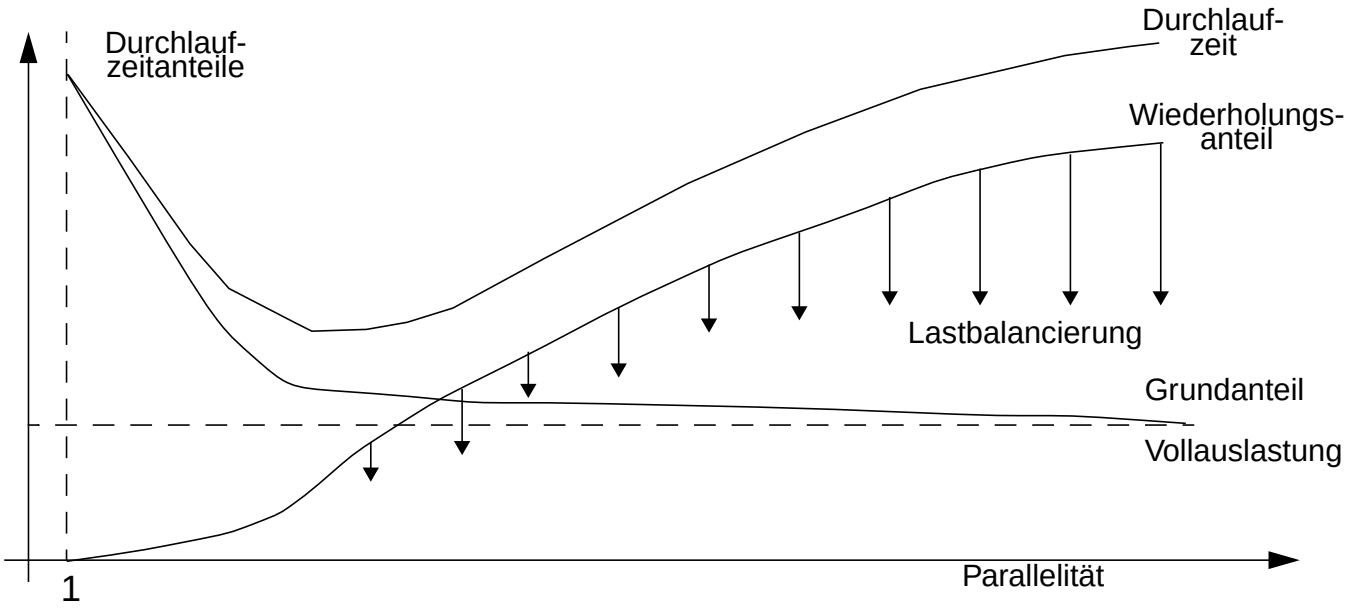

  - Sie wird von **zwei gegenläufigen Faktoren** bestimmt
    - Grundanteil der Durchlaufzeit beschreibt die Zeit, die zur Verarbeitung durch den Referenzstring vorgegebenen Last bei fehlender Synchronisation nötig wäre
    - Wiederholungsanteil umfaßt die Belegung des Prozessors zur nochmaligen Ausführung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

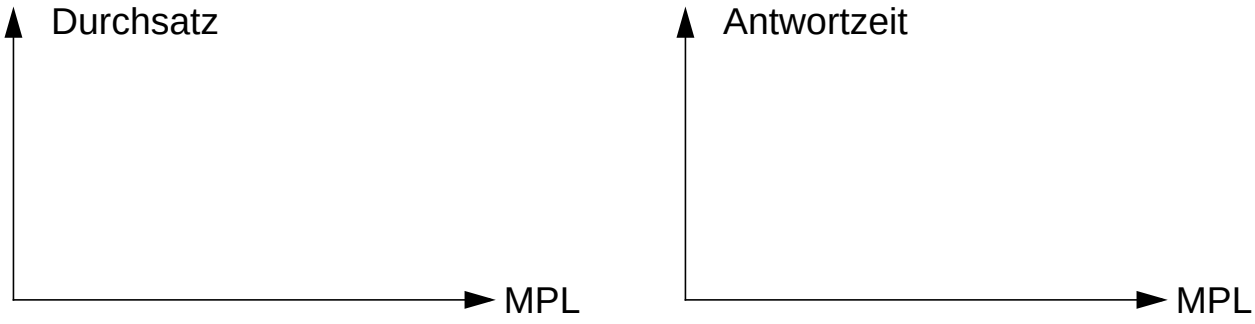

- **Statische MPL-Einstellung unzureichend:**
  wechselnde Lastsituationen, mehrere Transaktionstypen

- **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

- **Serialisierbare Abläufe**
  - gewährleisten „automatisch“ Korrektheit des Mehrbenutzerbetriebs
  - erzwingen u. U. lange Blockierungszeiten paralleler Transaktionen
- **Realisierung der Synchronisation durch Sperrverfahren**
  - Sperren stellen während des laufenden Betriebs sicher, daß die resultierende Historie serialisierbar bleibt
  - Bei einer Konfliktoperation blockieren sie den Zugriff auf das Objekt.
  - Es gibt mehrere Varianten (RX, RUX, ...)
  - Prädikatssperren verkörpern eine elegante Idee, sind aber in praktischen Fällen nicht direkt einsetzbar,
    ggf. Nutzung in der Form von Präzisionssperren
  - DBS-Standard: multiple Sperrgranulate durch hierarchische Sperrverfahren

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

- **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: weitere Verfahren**
  - 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
- **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
- **Dynamische Lastkontrolle erforderlich**
  - Vermeidung von „Thrashing“ bei wechselnden Lastsituationen, mehreren Transaktionstypen usw.
  - Nutzung einer Konfliktrate (1.3) zur dynamischen Einstellung der MPL