8. Sperrverfahren – Implementierung und Leistungsanalyse[1]

- **Synchronisation – Überblick über die Verfahren**
- **Zweiphasen-Sperrprotokolle**
  - RUX-Protokoll
  - Hierarchische Sperrverfahren
- **Einführung von Konsistenzebenen**
  - Reduzierung von TA-Blockierungen, aber Programmierdisziplin gefordert
  - Unterschiedliche Ansätze basierend auf
    - Sperrdauer für R und X
    - zu tolerierende “Fehler”
- **Optimierungen**
  - RAX und RAC
  - Mehrversionen-Verfahren
  - Prädikatssperren
  - Synchronisation auf Objekten
  - 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.

Einbettung des DB-Schedulers

- **Stark vereinfachtes Modell**

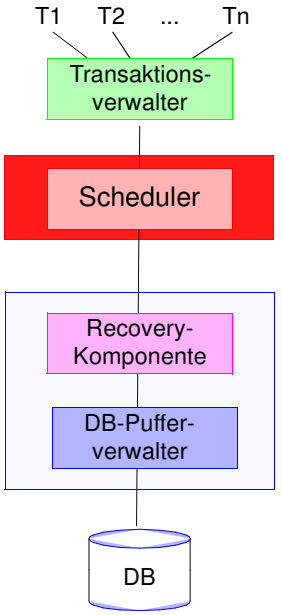

- **Welche Aufgaben hat der Scheduler (Lock Mgr)?**
  - als Komponente der Transaktionsverwaltung zuständig für **I** von **ACID**
  - kontrolliert die beim TA-Ablauf auftretenden Konfliktoperationen (R/W, W/R, W/W) und garantiert insbesondere, dass nur „serialisierbare“ TAs erfolgreich beendet werden
  - verhindert nicht-serialisierbare TAs
  - kann jedoch keine Deadlocks verhindern. Zur Deadlock-Auflösung ist eine Kooperation mit der Recovery-Komponente erforderlich (Rücksetzen von TAs)

➥ **garantiert „vernünftige” Schedules:**

Historische Entwicklung von Synchronisationsverfahren

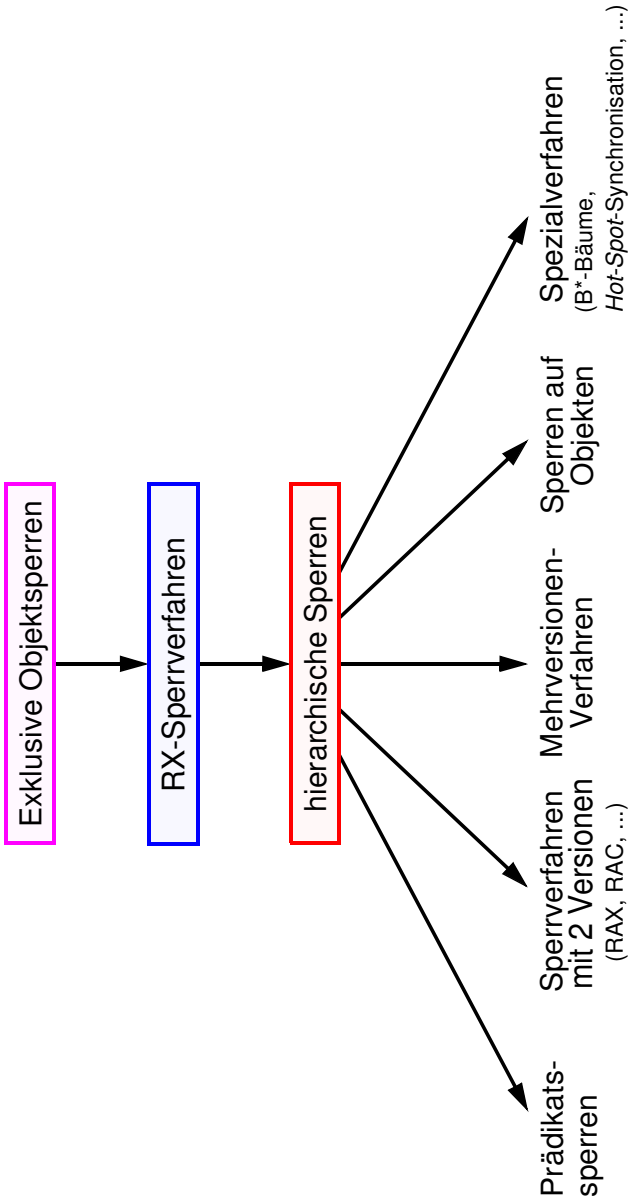

Sperrverfahren

- **Zur Realisierung der Synchronisation gibt es viele weitere Verfahren**
  - **Pessimistische Verfahren:**
    Bei einer Konfliktoperation blockieren sie den Zugriff auf das Objekt.
    Verfeinerungen: Konversion des Sperrmodus, multiple Sperrgranulate
  - **Versionsverfahren:**
    es werden zwei oder mehr Versionen eines Objektes gehalten.
    Keine Behinderung der Leser durch Schreiber
  - **Prädikatssperren:**
    Es wird die Menge der möglichen Objekte, die das Prädikat erfüllen, gesperrt. Elegante Lösung für das Phantom-Problem
  - **Sperren auf Objekten:**
    Nutzung der Kommutativität von Änderungen
  - **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

Phantom-Problem

Einfügungen oder Löschungen können Leser zu falschen Schlussfolgerungen verleiten:

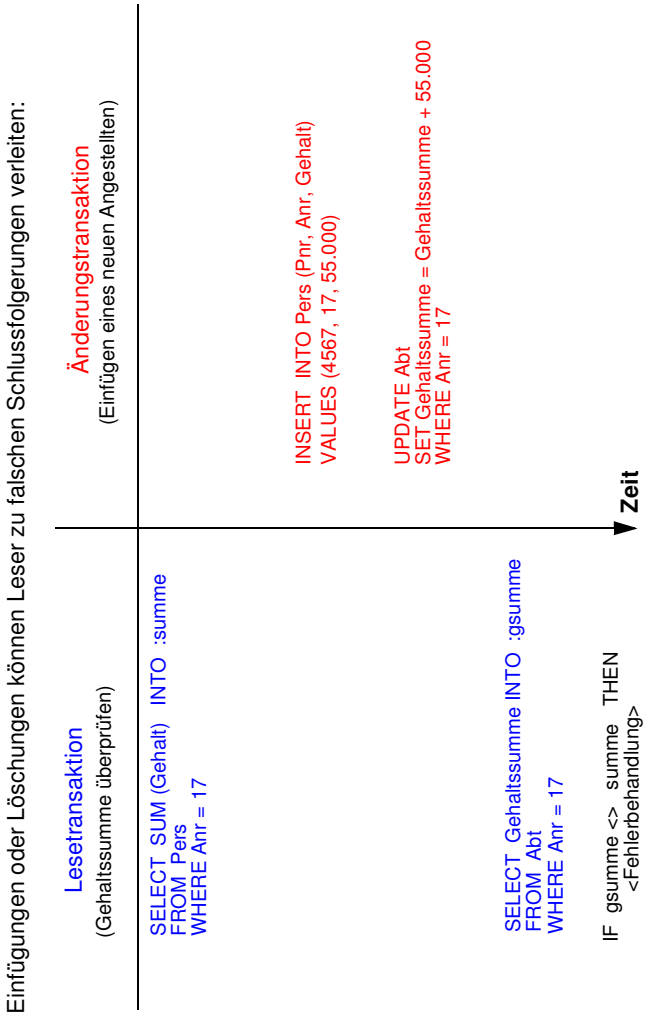

RX-Sperrverfahren

- **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	+	-	-

angeforderter Modus der TA	Modus-Übergang: NL	R	X
R	R	R	-
X	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
- **Erinnerung**
  - Zweiphasigkeit: 2PL
  - Unter striktem 2PL (S2PL) werden alle exklusiven Sperren einer TA bis zu ihrer Terminierung gehalten
  - Unter starkem 2PL (SS2PL) werden alle Sperren einer TA bis zu ihrer Terminierung gehalten

2PL

- **SQL-API**
  - An der SQL-Schnittstelle ist die Sperranforderung und -freigabe **nicht sichtbar!**
  - Objektanforderung durch Zugriffsmodul (nach Optimierung) über OID (direkt), Scan (Fetch Next), Index usw.
  - Optimierung der Sperranforderungen im DBMS
    - **Mehrere Sperrgranulate** anwendbar
    - Nach welchen Kriterien entscheidet das DBMS?
    - Zusätzliche Option: **Sperreskalation**
  - Wie wird das Phantom-Problem gelöst?

- **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 mindestens **striktes 2PL-Protokoll**!

RUX-Sperrverfahren

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

- **Problem: Sperrkonversionen**

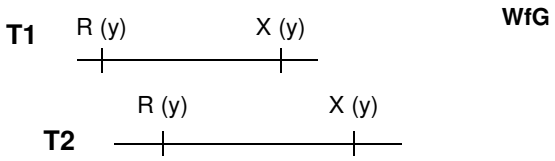

- **Erweitertes Sperrverfahren:**
  - Ziel: **Verhinderung von Konversions-Deadlocks**
  - U-Sperre für Lesen mit Änderungsabsicht (Prüfmodus)
  - bei Änderung Konversion U → X, andernfalls U → R (*downgrade*)

- **Wirkungsweise**

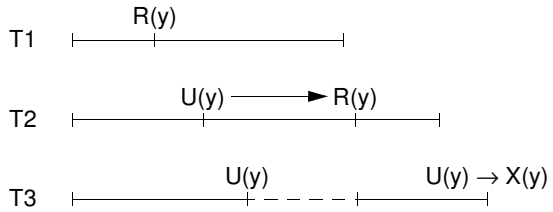

RUX-Sperrverfahren (2)

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

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

- **Beispiel**

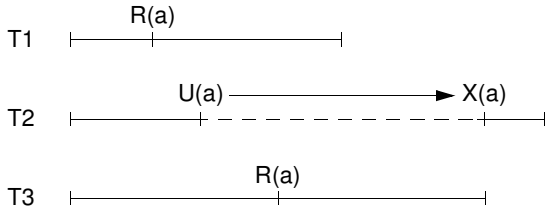

- **Unsymmetrie bei U**

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

  - u. a. in DB2 eingesetzt

- **Beispiel**

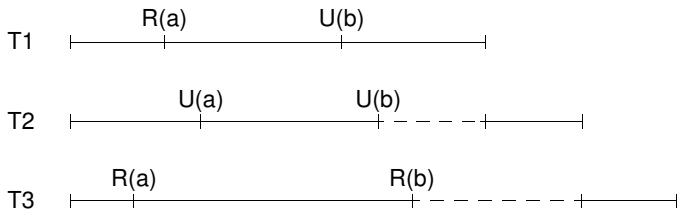

Hierarchische Sperrverfahren

- **Sperrgranulat bestimmt Parallelität/Aufwand:**

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

- **Hierarchische Verfahren erlauben Flexibilität bei Wahl des Granulates (*multi-granularity locking*), z. B. Synchronisation**
  - langer TAs auf Tabellenebene
  - kurzer TAs auf Zeilenebene

- Kommerzielle DBS unterstützen zumeist mindestens zweistufige Objekthierarchie, z. B.

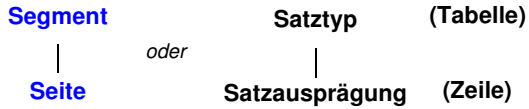

- Verfahren nicht auf reine Hierarchien beschränkt, sondern auch auf halbgeordnete Objektmengen erweiterbar (siehe auch objektorientierte DBS).

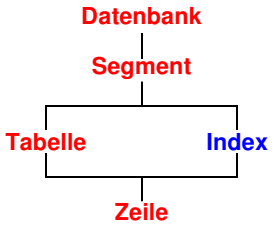

- Verfahren erheblich komplexer als einfache Sperrverfahren (mehr Sperrmodi, Konversionen, Deadlock-Behandlung, ...)

Beispiel einer Sperrhierarchie

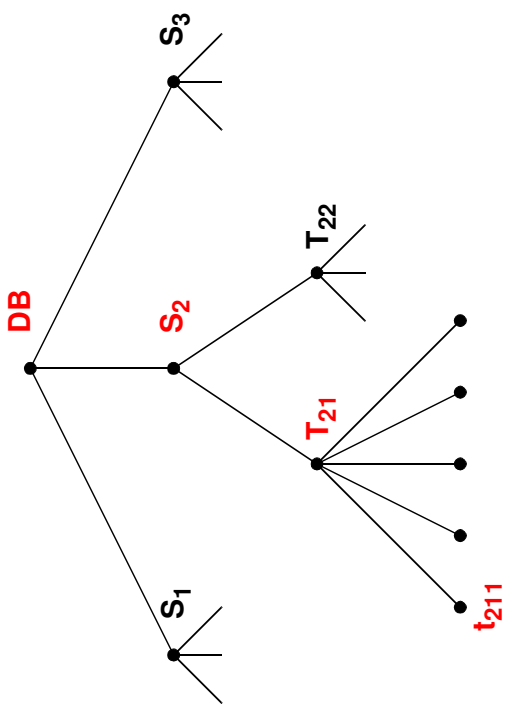

Datenbank

Dateien (Segmente)

Satztypen (Tabellen)

Sätze (Zeilen)

Wieviel Aufwand zum Sperren von

- 1 Satz
- k Sätzen
- 1 Satztyp

Was ist Sperr-Eskalation?

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	-	-	-

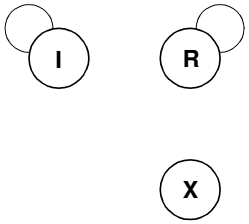

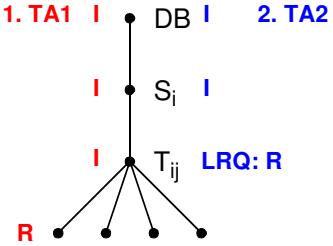

- Unverträglichkeit von I- und R-Sperren:
  - I-Sperre bei parallelem Lesen zu restriktiv!
  - TA2 wartet (LRQ: Lock Request Queue)

  ➥ zwei Arten von Anwartschaftssperren (IR und IX)

Anwartschaftssperren (2)

- **Anwartschaftssperren für Leser und Schreiber**

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

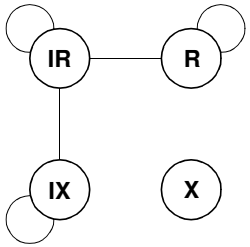

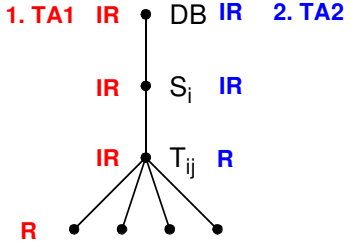

- IR-Sperre (*intent read*), falls auf untergeordneten Objekten nur lesend zugegriffen wird, sonst IX-Sperre

- 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 → X, sonst U → R.

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

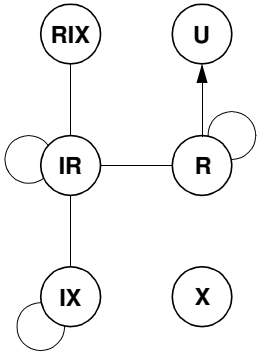

- **'Sperrdisziplin' erforderlich**
  - Sperranforderungen von der **Wurzel zu den Blättern**
  - Bevor T eine R- oder IR-Sperre für einen Knoten anfordert, muss sie für alle Vorgängerknoten IX- oder IR-Sperren besitzen
  - Bei einer X-, U-, RIX- oder IX-Anforderung müssen alle Vorgängerknoten in RIX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

a)

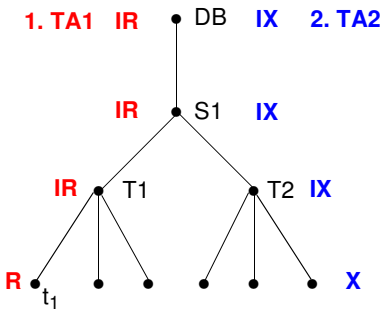

b)

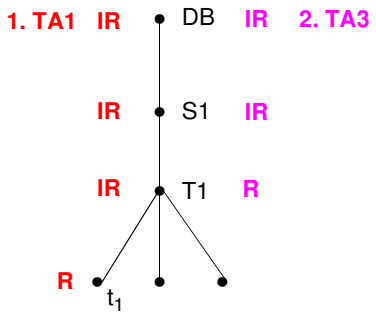

- **RIX-Modus**
  - TA1 liest alle Zeilen von T1 und ändert t_3
  - a) TA2 liest T1
  - b) TA3 liest t_2 in T1

a)

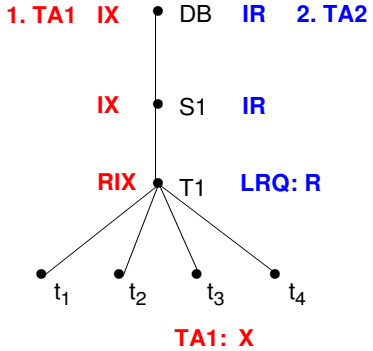

b)

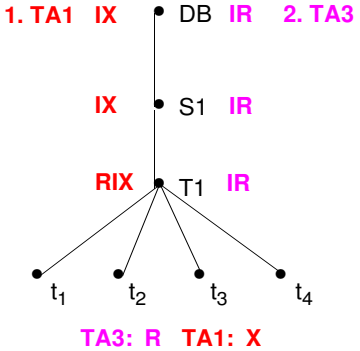

Sperrverfahren in Datenbanksystemen

- **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)
  - blinde Durchsatzmaximierung?

    Um Durchsatzziel zu erreichen :
    mehr aktive TAs → **mehr** gesperrte Objekte → **höhere** Konflikt-WS →
    längere Sperrwartezeiten, **höhere** Deadlock-Raten → **noch mehr** aktive TAs

  - Häufig berührte Objekte können zu Engpässen (*Hot Spots*) werden
  - Eigenschaften des Schemas können *High-Traffic-Objekte* erzeugen
- **Einführung von Konsistenzebenen**
  zur Reduktion des Blockierungspotentials:

  ➥ **Programmierdisziplin gefordert!**
- **Optimierungen!?**
  - Änderungen auf privaten Objektkopien (verkürzte Dauer exklusiver Sperren)
  - Nutzung mehrerer Objektversionen
  - 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)

KE 0: kurze X, keine R

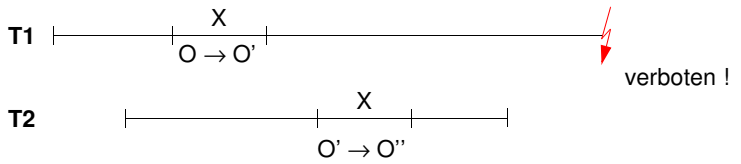

KE 1: lange X, keine R

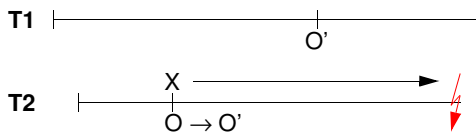

KE 2: lange X, kurze R

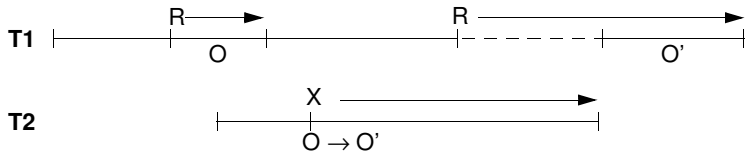

KE 3: lange X, lange R

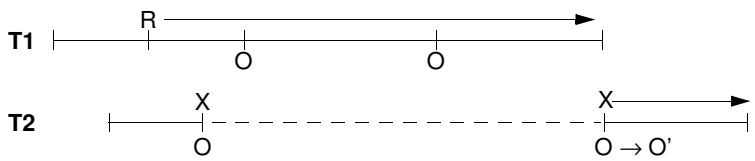

Konsistenzebenen (3)

- ***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	Deadlocks
Read Uncommitted	+	+	+	
Read Committed	-	+	+	
Repeatable Read	-	-	+	
Serializable	-	-	-	

- Default ist **Serialisierbarkeit**[2] (serializable)

2. 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 KE 3 und "Serializable"?**

  - **Repeatable Read**
    Sperren von vorhandenen Objekten

    Datenstruktur: O1 O2 . . Zugriff mit Get Next

    1. Lesefolge von T1:

       Einfügen von T2:

    2. Lesefolge von T1:

  - **Serializable**
    garantiert Abwesenheit von Phantomen

    1. Lesefolge von T1:

       Einfügen von T2:

    2: Lesefolge von T1:

Sperrverfahren mit Versionen (RAX)

- **Kompatibilitätsmatrix:**

	R	A	X
R	+	⊕	-
A	⊕	-	-
X	-	-	-

A = Analyse

- **Ablaufbeispiel**

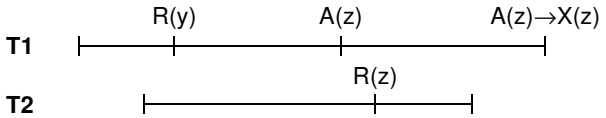

RAX: T2 → T1

- **Änderungen erfolgen in temporärer Objektkopie**

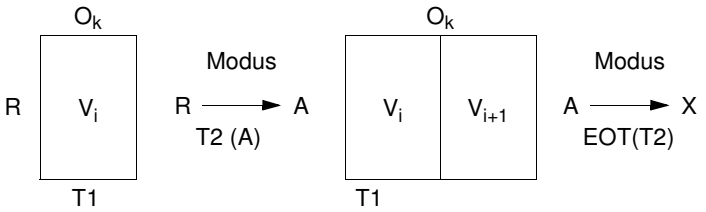

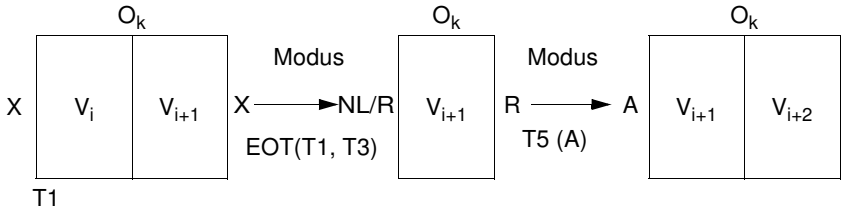

LRQ (R):
LRQ (A):

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 Serialisierbarkeitsreihenfolge**:

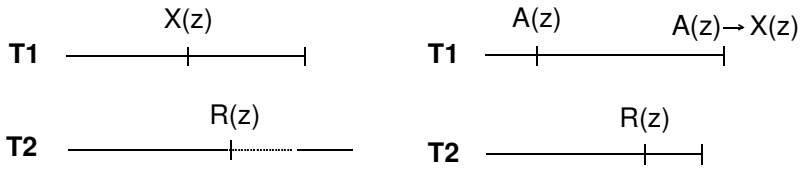

RX: T1 → T2 **RAX: T2 → T1**

- **Nachteile**
  - Neue Version wird für neu ankommende Leser erst verfügbar, wenn alte Version aufgegeben werden kann
  - Starke Behinderungen von Update-TAs 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	⊕	-	-

C = Commit

- **Ablaufbeispiel**

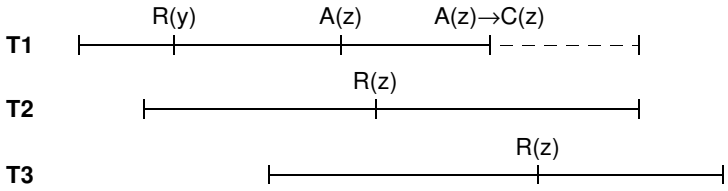

RAC: T2 → T1 → T3

- **Änderungen erfolgen ebenfalls in temporärer Objektkopie**

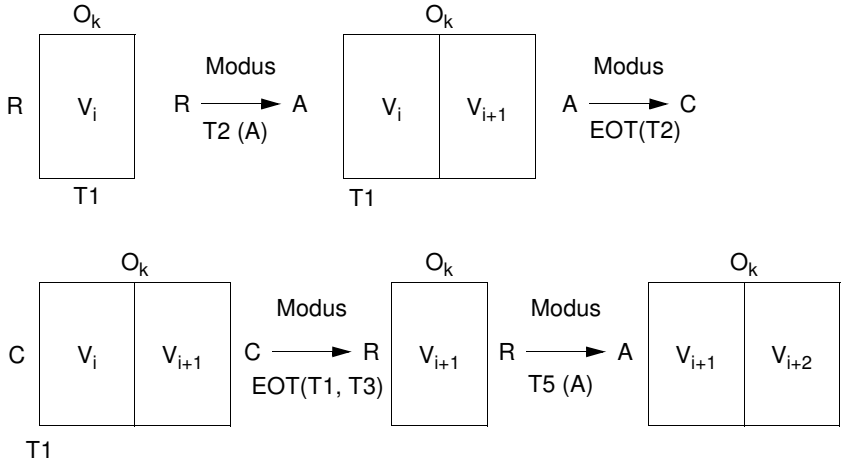

LRQ (A):

RAC (2)

- **Eigenschaften von RAC**
  - Änderungen werden nach wie vor serialisiert (A-Sperre erforderlich)
  - Bei EOT Konversion von A → 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

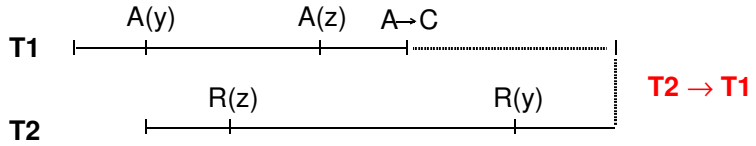

Welche Version von y?

➥ 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)
    ➥ komplexere Sperrverwaltung
  - Leseanforderungen bewirken nie Blockierung/Rücksetzung, jedoch: **Auswahl der „richtigen" Version erforderlich**
  - Änderungs-TAs, 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-TAs erzeugen neue Objektversionen**
  - Es kann immer nur eine neue Version pro Objekt erzeugt werden
  - Sie wird bei EOT der TA freigegeben

- **Lese-TAs sehen den bei ihrem BOT gültigen DB-Zustand**
  - Wie erkennt das DBS Leser?

  Sie greifen immer auf die jüngsten Objektversionen zu, die bei ihrem BOT freigegeben waren

  ➥ ***Eine Objektversion, auf die ein Leser noch zugreifen könnte, darf nicht gelöscht werden***
  - Sie setzen und beachten keine Sperren
  - Es gibt keine Blockierungen und Rücksetzungen für Lese-TAs, dafür ggf. Zugriff auf veraltete Objektversionen

- **Beispiel für Objekt O_k**

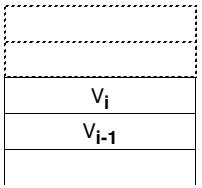

Zeitliche Reihenfolge der Zugriffe auf O_k

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)

- **Kompatibilitätsmatrix für Objekt O**

	NL	R	X
L	+	+	-
R	+	+	-
X	+	-	-

- **Auswahl der Objektversion**

Der Zugriff im Modus L bezieht sich auf die bei BOT(T_r) freigegebene Version:

- T_r: Lese-TA (Read-only-Operationen)
- T_x: Schreib-TA (Read/Write-Operationen)
- Commit-Zeitpunkte der Versionen: ... $O_i = t_i$, $O_{i+1} = t_{i+1}$ ...
- BOT(T_r) = t_r
  Wenn $t_{i+1} > t_r \geq t_i$, dann bezieht sich der L-Zugriff auf = O_i

- **Sperrsituationen**

$t_{i+1} > t_r \geq t_i$ T_r : L

	$O_{i+1} : t_{i+1}$
NL	$O_i : t_i$
	$O_{i-1} : t_{i-1}$

$t_{i+1} > t_r \geq t_i$ T_r : L

X	T_{x1} : X
NL	

$t_{r2} \geq t_i$ T_{r2} : L
$t_i > t_{r1} \geq t_{i-1}$ T_{r1} : L

	WS: T_{x2} : X
R	T_{x1} : R (Konversion der R-Sperre durch T_{x1}
NL	würde neue Version erzeugen)

Zugriff auf O in der Reihenfolge T_{x1}, T_{x2}, T_r ($t_r \geq t_{i-1}$)

T_{x1} : X
T_r : L

X	O_i WS: T_{x2} : R
NL	O_{i-1}

➥ Mit R wird immer die jüngste freigegebene Version gelesen;
solange Lock(O, R) gilt, kann keine neue Version erzeugt werden

Mehrversionen-Verfahren (3)

- **Ablaufszenario**

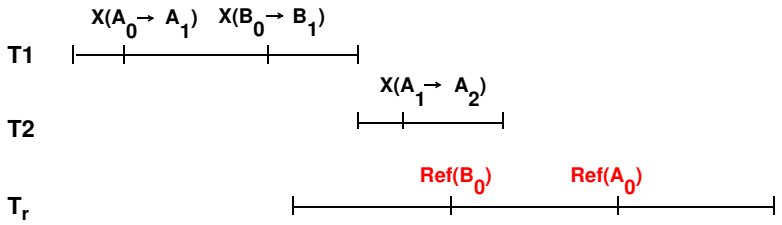

- **Konsequenz**

- Lese-TAs werden bei der Synchronisation nicht mehr berücksichtigt
- Schreib-TAs werden mit ihren Lese- und Schreib-Operationen untereinander über ein allgemeines Verfahren (Sperren, OCC, . . .) synchronisiert

➥ **deutlich weniger Synchronisationskonflikte**

- **Hypothetische Annahme**: Ein Schreiber greift bei seinen Lese-Operationen wie ein Leser zu (ohne Synchronisation). Ist der Schreiber serialisierbar?

L:

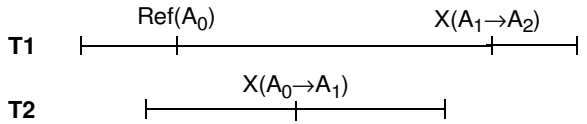

R:

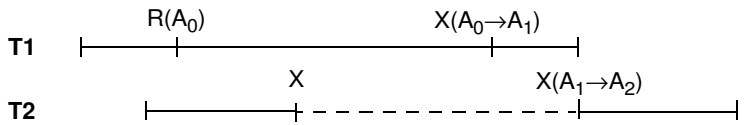

Mehrversionen-Verfahren (4)

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

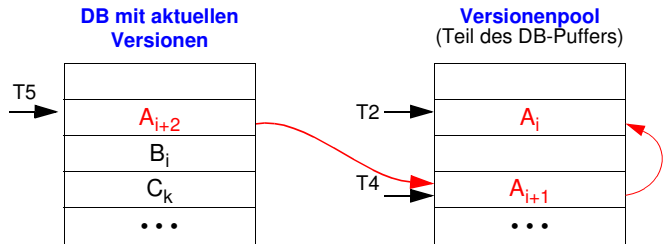

  - Speicherplatzoptimierung: Versionen auf Satzebene, Einsatz von Komprimierungstechniken
  - Was passiert, wenn Implementierung auf n Versionen begrenzt ist?

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

Prädikatssperren[3]

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

- **Form:**

  LOCK (R, P, a)

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

  UNLOCK (R, P)

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

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

- **Beispiel:**

T1:		**T2:**	
	LOCK(R1, P1, read)		. . .
	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) {$\wedge$, $\vee$} (. . .

3. Eswaran, K.P. et al.: The Notions of Consistency and Predicate Locks in a Database System. in: Communications of the ACM 19:11, 1976, 624-633

Prädikatsperren (2)

- **Entscheidungsprozedur**

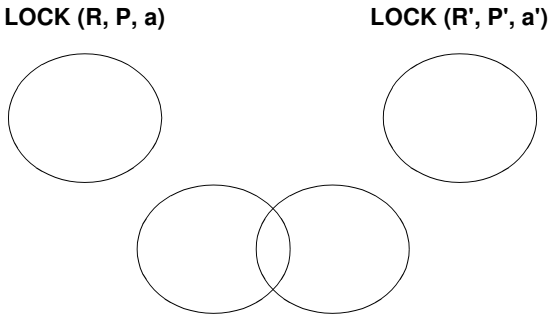

1. Wenn R ≠ R', kein Konflikt
2. Wenn a = read und a' = read, kein Konflikt
3. Wenn P(t) ∧ P'(t) = TRUE für irgendein t, dann besteht ein Konflikt

T1:	T2:
LOCK (Pers, Alter > 50, read)	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 Tabellensperre
    ➥ große Sperrgranulate, geringe Parallelität

Prädikatsperren (3)

- **Effizientere Implementierung: Präzisionssperren**[4]
  - **sperren nur die gelesenen Daten** durch Prädikate
  - setzen für aktualisierte Sätze Schreibsperren
    ➥ Es ist kein Disjunktheitstest für Prädikate mehr erforderlich,
    sondern es ist lediglich zu überprüfen, ob der Satz ein Prädikat erfüllt

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

    (Pers: Alter > 50 and Beruf = 'Prog.')
    (Pers: Pname = 'Meier' and Gehalt > 50000)
    (Abt: Anr=K55)
    . . .
  - **Update-Liste:**
    enhält geänderte **Sätze** laufender TAs

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

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

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

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

Synchronisation auf Objekten

- **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 TAs 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 ist auch mit rein syntaktischen Verfahren (r/w) erzeugbar:

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

➥ Schedule S2 ist hingegen mit rein syntaktischen Verfahren nicht erzeugbar.

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

Synchronisation von *High-Traffic*-Objekten

- ***High-Traffic*-Objekte**
  - auch *Hot Spots* genannt: Datenelemente, auf die viele TAs 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 ungeschicktem TA-Scheduling (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 Scheduling-Verfahren 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';

if anzahl ≥ 2 then anzahl := anzahl-2;

exec sql    update Flüge
            set FreiePlätze = :anzahl
            where FlugNr = 'LH127';
```

➥ Deadlock-Gefahr wegen Sperrkonversion.
Erhöhung dieser Gefahr bei *Hot-Spot*-Verhalten

- **Verbesserung**

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

aber: Prüfung der Integritätsbedingung (FreiePlätze ≥ 0) durch das DBMS

➥ keine Deadlock-Gefahr, jedoch 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 (Fehlerbehandlung der Anwendung)
3. Sonst wird ein 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 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 TAs 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

Escrow-Ansatz[5]

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

      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 Spezifikation 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 TAs Reservierungen angemeldet haben

➥ Führen eines Wertintervalls, 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

5. 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=100 (Anzahl freier Plätze)

Anforderungen/Rückgaben				Wertintervall		
T1	T2	T3	T4	INF	Q	SUP
				15	15	15
-5				10	10	15
	-8			2	2	15
		+4		2	6	19
			-3			
commit				2	6	14
		commit		6	6	14
	abort			14	14	14

- **Eigenschaften**
  - Durchführung von Bereichstests bezüglich des Wertintervalls
  - 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 Objektreplikation**
  - Kopien: temporär, privat, nicht freigegeben
  - Versionen: permanent, mehrbenutzbar, freigegeben

#Versionen / #Kopien	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**

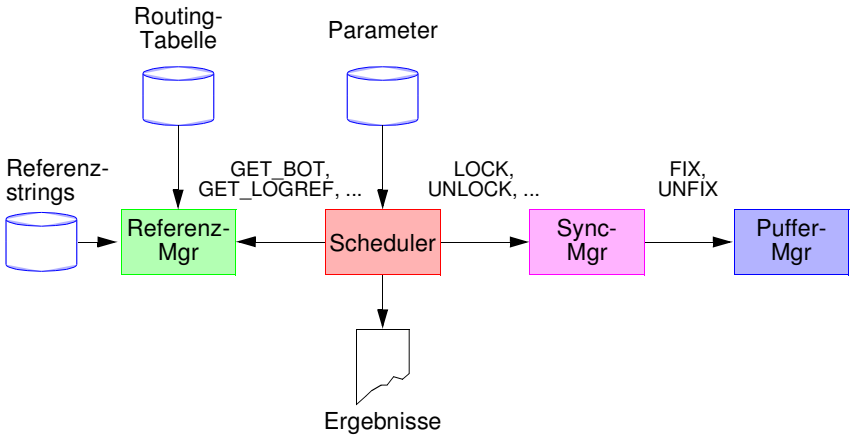

Implementierungsaspekte – Datenstrukturen

- **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

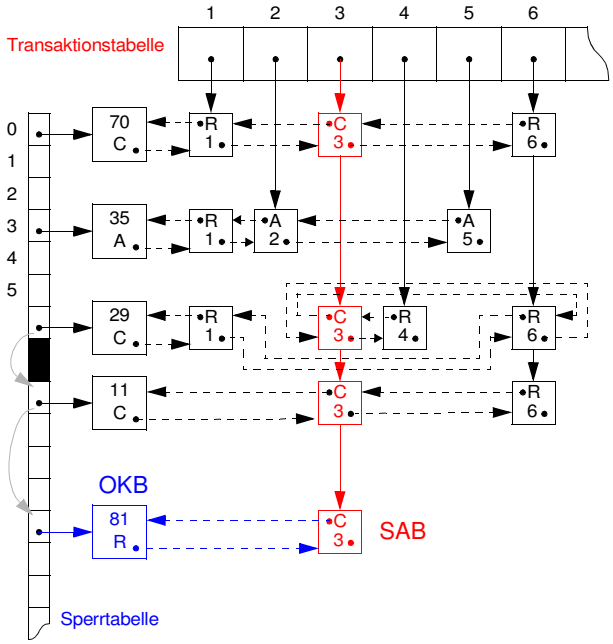

➥ **Beispiel:** Sperrtabelle / TA-Tabelle für RAC-Verfahren
  - Hash-Tabelle erlaubt schnellen Zugriff auf Objektkontrollblöcke (OKB)
  - Matrixorganisation der Sperrtabelle mit Sperranforderungsblöcken (SAB)
  - Spezielles Sperrverfahren: **Kurzzeitsperren** für Zugriffe auf Sperrtabelle (Semaphor pro Hash-Klasse 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**

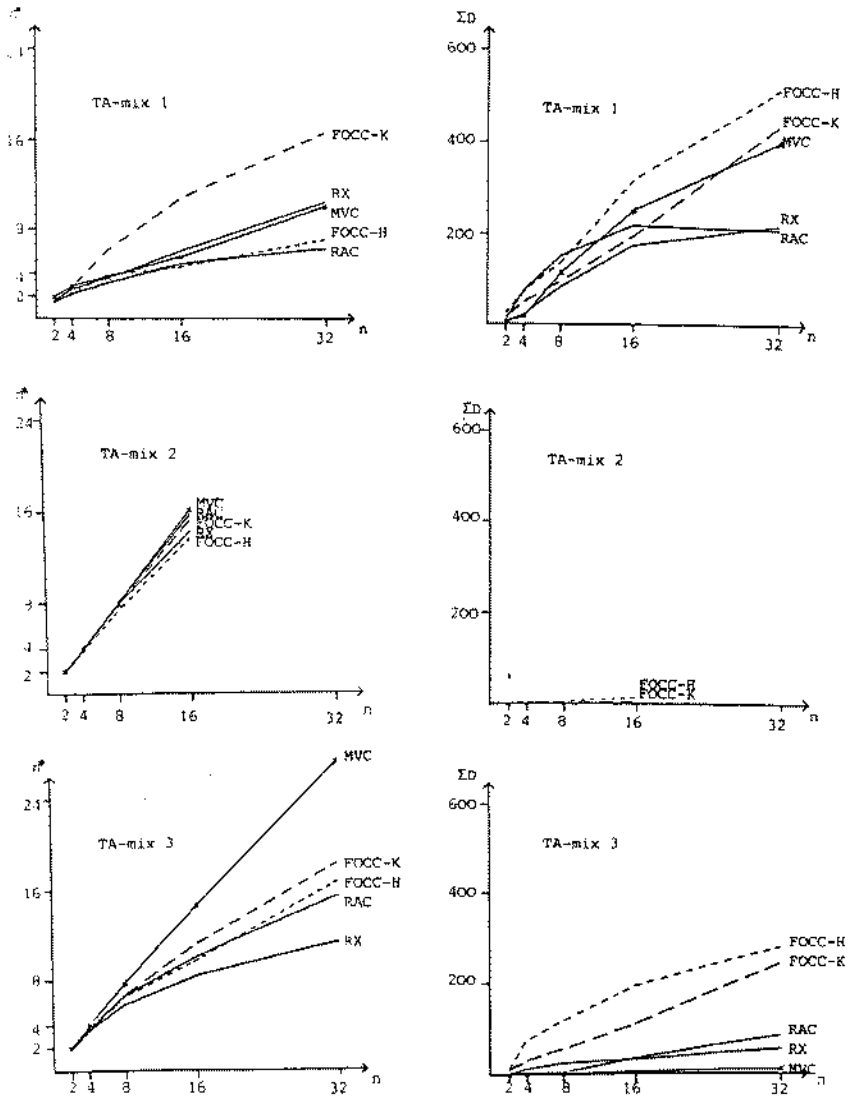

Vergleich verschiedener Synchronisationsverfahren

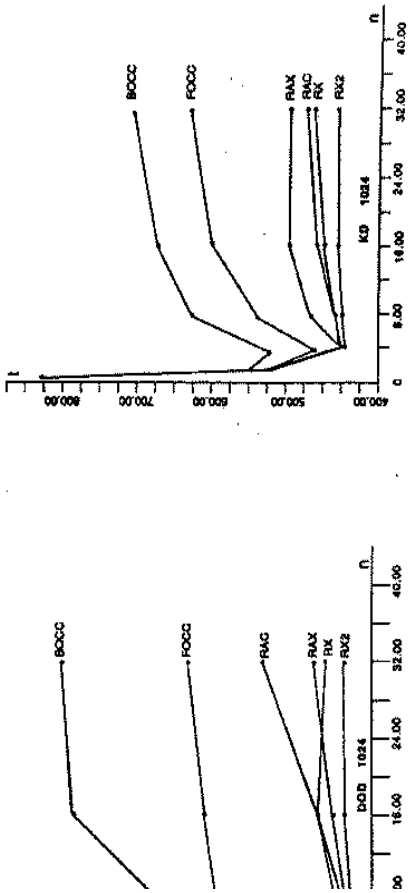

- **Schlussfolgerungen**
  - Sehr geringe Parallelität ➡ keine effektive Nutzung der Ressourcen
  - Geringe Parallelität ➡ bester Durchsatz, nicht notwendigerweise kürzeste Antwortzeiten
  - Pessimistische Methoden gewinnen: Blockierung vermeidet häufig Deadlocks
  - Optimistische Methoden geraten leicht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

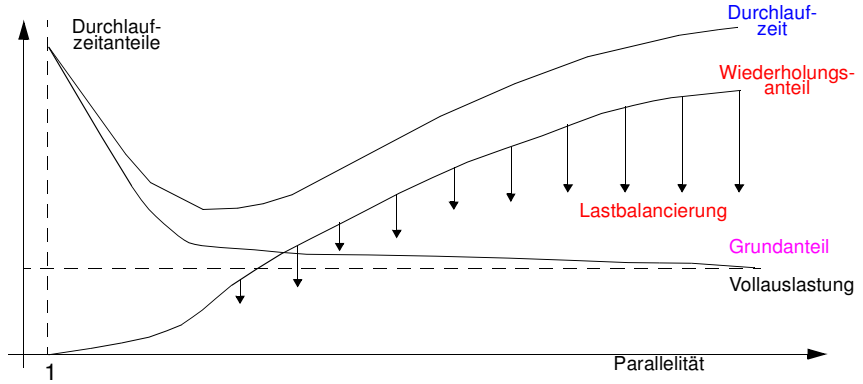

  - Sie wird von **zwei gegenläufigen Faktoren** bestimmt
    - Grundanteil der Durchlaufzeit beschreibt die Zeit, die zur Verarbeitung durch den Referenzstring vorgegebenen Last bei fehlender Synchronisation nötig wäre
    - Wiederholungsanteil umfasst die Belegung des Prozessors zur nochmaligen Ausführung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

➡ 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?**
- **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

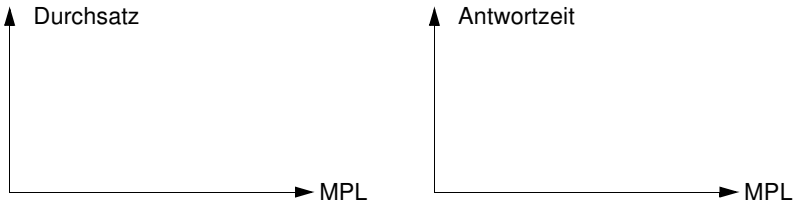

- **Statische MPL-Einstellung unzureichend:**
  wechselnde Lastsituationen, mehrere Transaktionstypen
- **Idee:**
  dynamische Einstellung des MPL zur Vermeidung von *Thrashing*
- **Ein möglicher Ansatz -**

  Nutzung einer Konfliktrate bei Sperrverfahren[6]:

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

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

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

Zusammenfassung

- **Realisierung der Synchronisation durch Sperrverfahren**
  - Prädikatssperren verkörpern eine elegante Idee, sind aber in praktischen Fällen nicht direkt einsetzbar, ggf. Nutzung in der Form von Präzisionssperren
  - 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)

    ➥ Standard: multiple Sperrgranulate durch hierarchische Sperrverfahren
- **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**
- **Generelle Optimierungen**
  - reduzierte Konsistenzebene
  - Mehrversionen-Ansatz
- **'Harte' Synchronisationsprobleme:**
  - *Hot Spots* / *High-Traffic*-Objekte
  - lange (Änderung-) TAs
  - Wenn Vermeidungsstrategie nicht möglich ist, sind zumindest für Hochleistungssysteme Spezialprotokolle anzuwenden
- **Dynamische Lastkontrolle erforderlich**