

Synchronisation im Kern

Reinhard Bündgen
buendgen@de.ibm.com

Warum Synchronisieren?

Thread 1

`i++;`

get i (7)

increment i (7->8)

write back i (8)

Thread 2 [Option 1]

`i++;`

get i (8)
increment i (8->9)
write back i (9)

Thread 2 [Option 2]

`i++;`

get i (7)

increment i (7->8)

write back i (8)

Ursachen von Nebenläufigkeit im Kern

- auf UP & SMP (Pseudo-Nebenläufigkeit)
 - Unterbrechungen
 - Verdrängung von Kerncode (kernel preemption)
 - Schlafen/Warten
- auf SMP (echte Nebenläufigkeit, Parallelität)
 - paralleles Arbeiten von CPUs

Was muss synchronisiert werden?

- ✓ Der Zugriff auf Ressourcen (Daten)
- ✗ Nicht der Ablauf von bestimmten Codeabschnitten
- Kritischer Abschnitt:
 - Codeabschnitt in dem auf kritische Ressource zugegriffen wird.
 - Merke, unterschiedliche Codeabschnitte können auf die gleiche kritische Ressource zugreifen

Synchronisationsmechanismen

- auf UP
 - Verhindern von Unterbrechungen
 - Kein Aufruf von `schedule()` in kritischen Abschnitten
- auf SMP
 - Verhindern von Unterbrechungen
 - Kooperative Nutzung von Schlössern (Locks)
 - Ein Schloss kann nur einmal (oder n mal) abgeschlossen werden
 - Jeder Versuch es öfter abzuschließen scheitert
 - Nur wer ein Schloss abgeschlossen hat, kann/darf es aufschließen
 - (ein Schloss muss so oft aufgeschlossen werden wie es abgeschlossen wurde)

Probleme mit der Synchronisation

- Verklemmungen (dead locks)
 - Thread 1
 - Lock A
 - Lock B

	Thread 2
Lock A	
Lock B	
- Skalierbarkeit
 - Wenn mehrere Threads gleichzeitig das gleiche Lock anfordern, kann nur einer weiterarbeiten (Sequenzialisierung)
 - Je länger ein Lock gehalten wird, desto höher die Wahrscheinlichkeit, dass Threads sequenzialisiert werden.
- Prioritätsinversion
 - Ein Thread mit niedriger Priorität hält ein Lock, dass ein Thread mit hoher Priorität benötigt: Gefahr von

Überblick über Synchronisationsmechanismen im Linuxkern

- Atomare Operationen
 - auf ints
 - auf longs (ab 2.6.16)
 - auf bits in einem Wort
- Spin Locks
 - einfach
 - Lese-/Schreiblocks
 - Sequence Locks
- Semaphore
 - Standard
 - Mutexe
 - Lese-/SchreibSemaphore
- Completion Variablen
- RCU
- The Big Kernel Lock (BLK)
- Per-CPU Daten & Preemption disabling
- Barrieren

Atomare Operationen

- Auf Integers (24 bit)
 - Datentyp `atomic_t`
 - z.B. `atomic_add(2 , &v) ; /* v=v+2 atomically */`
 - `<asm/atomic.h>`
- Auf Longs (64 bit)
 - Datentyp `atomic_long_t`
 - z.B. `atomic_long_read(atomic_long_t *l)`
- Bit Operationen
 - z.B. `set_bit(3 , &word) ; /* bit 3 of word is set atomically */`
 - `<asm/bitops.h>`

Spin Locks

- Basiert auf einer Synchronisations-Instruktion
 - z.B. test&set oder compare&swap
 - <asm/spinlock.h> <linux/spinlock.h>
- Busy-waiting an einem Schloss
- Nicht rekursiv
 - `spinlock_t datax_lock = SPIN_LOCK_UNLOCKED;`
 - `...`
 - `spin_lock(&datax_lock);`
 - `/* critical region for work on datax */`
 - `spin_unlock(&datax_lock);`
- Spin Lock Nutzung
 - Kurz!
 - kein Kontextwechsel, insbesondere *nicht* schlafen!

Spin Lock mit Compare & Swap

- Compare and Swap (System z) Pseudocode

```
int CS (*A, *B, C)
{
    if (*A == *B)
        then *B = C;
    else *A = *B;
}
```

- Lock Pseudocode (1 bedeutet „locked“)

```
bool lock(L) { int B=1; CS(&L, &B, 0); return B; }
```

Spin Locks und Interrupts

- Wenn ein Spin Lock von einem Interrupt Handler angefordert werden kann, muss es immer gegen Interrupts geschützt werden!
 - `spinlock_t datax_lock = SPIN_LOCK_UNLOCKED;`
 - `unsigned long myflags;`
 - `...`
 - `spin_lock_irqsave(&datax_lock,myflags);`
 - `/* critical region for work on datax */`
 - `spin_unlock_irqrestore(&datax_lock,myflags);`
- Wenn keine IRQs maskiert:
 - `spin_lock_irq()`
 - `spin_unlock_irq()`

Lese/Schreib Spin Locks

- Initialisierung
- ```
rwlock_t myrwlock = RW_LOCK_UNLOCKED;
```
- Lese Lock (gemeinsamer Zugriff)
  - `read_lock()` / `read_unlock()`
- Schreib Lock (exklusiver Zugriff)
  - `write_lock()` / `write_unlock()`
- Kein „upgrade“ von Lese auf Schreiblock möglich
- Lese/Schreib Locks favorisieren Leser
- Jeweils interruptmaskierende Varianten vorhanden
  - `{read|write}_lock_{irq|irqsave}`
  - `{read|write}_unlock_{irq|irqrestore}`

# Sequence Locks

- Lese/Schreib Lock
- favorisiert Schreiber
- Implementierung mit Hilfe von Zähler
- Schreibreservierung

- inkrementiert Zähler auf ungerade Zahl
  - Freigabe einer Schreibreservierung: inkrementiert Zähler auf gerade Zahl

```
seqlock_t myslock = SEQLOCK_UNLOCKED;
```

```
write_seqlock(&myslock);
```

```
...
```

```
write_sequnlock(&myslock);
```

- Lese Reservierung

- Klammere Zugriff und stelle sicher, dass Zähler unverändert bleibt

```
unsigned long seq;
```

```
do {
```

```
 seq = read_seqbegin(&myslock);
```

```
 /* lese Daten -- keine Seiteneffekte!!! */
```

```
} while (read_seqretry(&myslock, seq));
```

# Semaphore

- Edsger Wybe Dijkstra (1930-2002)
  - „Cooperating Sequential Processes“, 1965
- Anfordernde Task schläft, wenn sie auf Lockfreigabe warten muss
  - Kann nur in Task-Kontext benutzt werden
- Semaphorwert:
  - Zahl der Semaphor-Halter (Maximum deklarierbar)
  - 0: Semaphor ist frei
- Operationen
  - Reservieren: P() [prolaag/pobeer/passeer], down()
    - falls frei, inkrementiere Zahl der Halter, sonst warte bis frei
  - Freigeben: V() [verhoog/vrijgeven], up()
    - dekrementiere Zahl der Halter
- Binäre Semaphore / Mutex
  - Maximale Zahl der Halter ist 1

# Semaphorfunktionen in Linux

- <linux/semaphore.h>
- sema\_init(struct semaphore \*, int)
- down(struct semaphore \*)
- down\_interruptible(struct semaphore \*)
- down\_trylock(struct semaphore \*)
- up(struct semaphore \*)

# Die neue Mutex Implementierung

- Neue Implementierung seit Version 2.6.16
- die meisten Semaphore werden als Mutex benutzt:
  - benutze optimierte Mutex Implementierung
  - Elimination von Semaphoren wo immer möglich
- Schnittstelle:
  - Initialisierung statisch: `DEFINE_MUTEX(name)`
  - Initialisierung dynamisch: `mutex_init(name)`
  - `int mutex_lock(struct mutex *lock);`
  - `int mutex_lock_interruptible(struct mutex *lock);`
  - `int mutex_trylock(struct mutex *lock);`
  - `void mutex_unlock(struct mutex *lock);`
  - Test: `int mutex_is_locked(struct mutex *lock);`

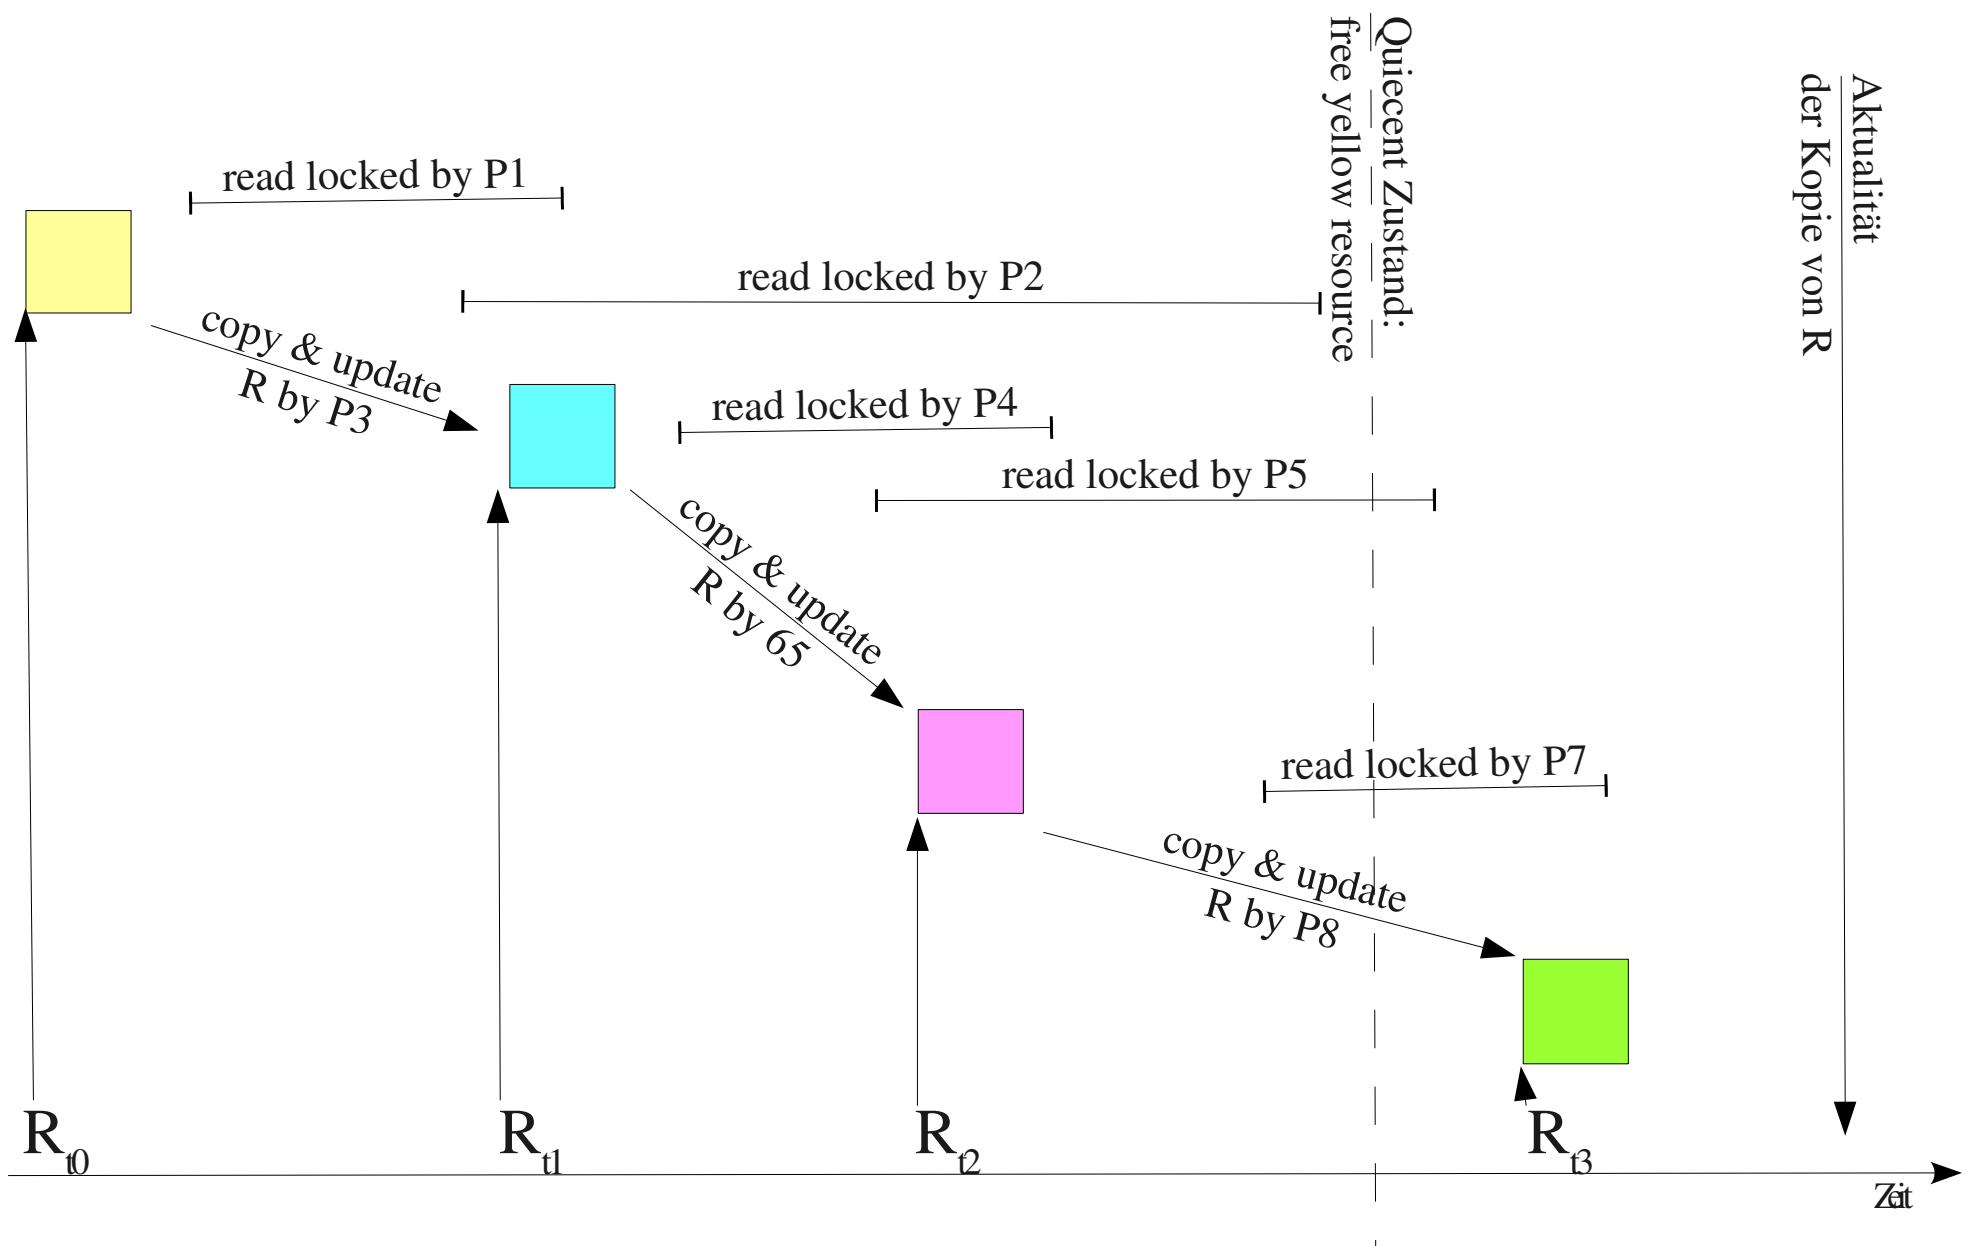
# Lese/Schreib-Semaphore

- <linux/rwsem.h>
- init\_rwsem(struct rw\_semaphore \*)
- down\_read(struct rw\_semaphore \*)
- up\_read(struct rw\_semaphore \*)
- down\_read\_trylock(struct rw\_semaphore \*)
- down\_write(struct rw\_semaphore \*)
- up\_write(struct rw\_semaphore \*)
- down\_write\_trylock(struct rw\_semaphore \*)
- downgrade\_write(struct rw\_semaphore \*)

# Read Copy Update (RCU)

- Ziel: verhindere Blockaden bei Synchronisation
- Idee:
  - Leser lesen aktuelles Objekt ohne zu blockieren
  - Schreiber modifizieren Kopie des aktuellen Objekts und ersetzen ursprüngliches Objekt *atomar* durch aktuelle Kopie
- Anforderung
  - Leser und Schreiber hängen nicht von einander ab
  - Objekt, dynamisch, nur durch einen Zeiger erreichbar
- Herausforderung
  - Wann kann man ursprüngliches Objekt frei geben?

# Read Copy Update



# Standard RCU – Linux Implementierung

- <linux/rcupdate.h>, kernel/rcupdate.c
- Leser: schläft nicht, kritischer Bereich nicht verdrängbar (non-preemptive)
  - rcu\_read\_lock( ) / rcu\_read\_unlock( )
- Schreiber:
  - alloziert Kopie der Struktur und füllt sie aus
  - ersetzt atomar ursprüngliche Struktur durch neue Kopie,
  - schedule-t Freigabe mit
    - void call\_rcu(struct rcu\_head \*head,  
                  void (\*func) (struct rcu\_head \*head))
    - func beschreibt Freigabeoperation
  - optional: synchronize\_rcu( )
- Freigabe der ursprünglichen Struktur:
  - nach dem alle CPUs durch „quiescent“ Zustand gegangen sind:
    - nach Task Kontextswitch
    - in User Space
    - in Idle Task

# Sonstige Locks

- **Obsolete:** the Big Kernel Lock: BLK
  - Schlafen erlaubt, wird automatisch freigegeben und wieder reserviert
  - nur im Task-Kontext nutzbar
  - Rekursives Lock (so oft freigeben, wie reservieren)
  - `lock_kernel()`, `unlock_kernel()`, `kernel_locked()`
- Completion variables
  - `DECLARE_COMPLETION(name)`
  - `init_completion(struct completion *)`
  - `wait_for_completion(struct completion *)`
  - `complete(struct completion *)`
- Verhindern von Preemption
  - implizit mit Spin Locks
  - Synchronisation für CPU-lokale Variablen
    - `preempt_disable()` / `preempt_enable()`
    - `preempt_enable_no_resched()`, `preempt_count()`
    - `int get_cpu()` / `put_cpu()`

# Barrieren

- out of order processing
  - z.B. `a=1; b=2;` sind logisch unabhängige Instruktionen
  - manchmal ist es aber wichtig das Reihenfolge nach außen hin erhalten bleibt (SMP)
- Prozessor Scheduling Barrieren
  - `rmb()`, `wmb()`, `mb()`,  
`read_barrier_depends()`
  - `smp_rmb()`, `smp_wmb()`, `smp_mb()`,  
`smp_read_barrier_depends()`
- Compile Scheduling Barrieren
  - `barrier()`