

Wechselseitiger Ausschluss

Klaus Kusche
Juni 2016

Inhalt

- **Ziele & Voraussetzungen**
- **Der “einfachste Fall”
und seine Lösung**
- **Der “Normalfall”
und seine Lösung**
- **Probleme des Konzeptes**
- **2. Teil: Neue Ansätze**

Ziele

Verständnis

- ... der zu lösenden Problematik,
- ... des Lösungskonzeptes,
- ... sowie dessen Implementierung
(incl. notwendiger HW-Voraussetzungen)
- ... und dessen potentieller Probleme

Kenntnis

- ... der wichtigsten Fachbegriffe

Voraussetzungen

Grundkenntnisse von

- Hardware:

Arbeitsweise Prozessor und Speicher
Multicore- / Multiprozessor-Systeme
Interrupts

- Betriebssystem:

Prozesse / Threads & Scheduling, ...

- Programmierung, Datenstrukturen:

Verkettete Liste (wegen des Beispiels)

Computerei heute ...

... ist fast immer

parallel!

Auf Hardware-Ebene:

Multicore-Prozessoren, Multiprozessor-Server

Auf Betriebssystem-Ebene:

Viele Anwendungen & Dienste laufen “gleichzeitig”
(= “Quasi-Parallel”, z.B. Round-Robin-Scheduling)

Auf Anwendungs-Ebene:

Viele Anwendungen (und vor allem Server-Dienste)
starten intern mehrere / viele parallele Threads

Die zentrale Frage

Kann man parallele Systeme

“ganz normal”

(= wie rein sequentielle Systeme)

programmieren?

Oder müssen neue Effekte berücksichtigt werden,
die bei sequentieller Programmierung
nicht auftreten?

Zwei simple Additionen ...

Prozessor A will zu **x** 10 dazuzählen,
Prozessor B will zu **x** 15 dazuzählen,
der bisherige Wert von **x** sei 100

Prozessor A	Prozessor B	Speicher x
		100
liest x aus Speicher: 100		100
	liest x aus Speicher: 100	100
zählt intern 10 dazu: 110		100
	zählt intern 15 dazu: 115	100
speichert Ergebnis in x : 110		110
	speichert Ergebnis in x : 115	115
		115

==> Ergebnis 115 statt 125, Addition von A ging verloren!

Die Lösung

Erfordert zwingend Hardware-Unterstützung:

- Auf Single-Core-Systemen:

Interrupt-Sperre

rund um den Befehl / die Befehle

==> Unterbindet Prozesswechsel & Interrupt Handler

==> Alleiniger, ungestörter Ablauf garantiert

==> Dann reichen “normale” Prozessorbefehle

- Auf Multi-Core-Systemen:

**“Atomare” Maschinenbefehle
bzw. Speicherzugriffe**

Ein “Atomarer” Befehl ...

... ist ein Maschinenbefehl, der eine Speicherzelle (= **int**)

exklusiv liest und anschließend schreibt,

ohne dass ein anderer Core

zwischen dem Lesen und dem Schreiben
denselben Speicherinhalt modifizieren kann

- *Atomic Increment, “Test-and-Set”, Atomic Exchange, ...*
- x86: “*Bus Lock Prefix*” vor einem Befehl
- RISC-Architekturen: *Load Linked / Store Conditional*

Technisch sehr aufwändig und relativ langsam:

Früher Pin am Prozessorbus, heute durch Cache Coherence Hardware!


Reicht das für Anwendungen? (1)

Anhängen von `myelem` an eine einfach verkettete Liste:


```
tail->next = myelem;
```

```
tail = myelem;
```


Ausgangslage:



Nach Zeile 1:



Nach Zeile 2:




Reicht das für Anwendungen? (2)


... und das wieder zwei Mal gleichzeitig:

Zwei neue Elemente **myA** und **myB**


Ausgangslage:




Reicht das für Anwendungen? (3)




1: Task A hat Listenende geändert.



2: Task B hat Listenende geändert.



3: Task B hat Tailpointer geändert.



4: Task A hat Tailpointer geändert.

==> Die Liste ist in zwei getrennte Teile zerbrochen!

Erkenntnis

*Atomare Befehle helfen hier nicht:
Inkonsistente Daten entstehen
durch mehrere Zugriffe pro Thread
auf verschiedene Variablen*

==> Bestimmte Reihenfolge der Zugriffe erzwingen

==> Parallelität einschränken

==> Threads koordinieren bzw. synchronisieren

Konzept “Kritische Region” (1)

= *ein Stück Code,*

*das “allein und ungestört”
durchlaufen muss,*

um vom alten konsistenten Zustand der Daten
in einen neuen konsistenten Zustand der Daten
zu kommen.

Bei genauerer Betrachtung:

Während der kritischen Region sind die Daten inkonsistent

==> Dürfen von anderen nicht einmal gelesen werden!

==> Auch reine Lese-Zugriffe gehören in eine kritische Region

Konzept “Kritische Region” (2)

Eine kritische Region besteht aus

***mehreren logisch zusammengehörenden
Lese- und Schreibzugriffen auf die Daten***

Beispiel Liste: Genau die beiden Zeilen!

**Aber: Wichtiger Grundsatz für den Code
innerhalb einer kritischen Region:**

*So viel wie nötig,
so wenig wie möglich!*

==> Kritische Regionen möglichst kurz halten!

Weil: *Parallelität so wenig wie möglich einschränken!*

Wechselseitiger Ausschluss ...

... garantiert *exklusiven Zugriff*
für kritische Regionen:

*Für jede Datenstruktur
darf sich zu jedem Zeitpunkt
nur ein einziges Thread
innerhalb einer kritischen Region befinden,
die auf diese Datenstruktur zugreift!*

Konzepte und Konstrukte

Konstrukte zur Erreichung dieses Ziels:

- ***Mutex = “Mutual Exclusion”***

(bezeichnet im Englischen sowohl das allgemeine Konzept als auch das konkrete Konstrukt zur Lösung!)

- ***Lock***
- ***Semaphore***
- ***Monitor***

... beschreiben alle in etwa dasselbe!

Code-Struktur

Kritische Regionen werden im Code irgendwie

“eingerahmt”

(durch eigenes Sprachkonstrukt oder Library-Aufrufe)

... (“unkritischer” Code)
Lock(...) (oder **Wait(...)** oder **Acquire(...)**)

***Code der kritischen Region
bzw. Zugriffe auf gemeinsame Daten***

Unlock(...) (oder **Signal(...)** oder **Release(...)**)
... (“unkritischer” Code)

Naive Vorstellung (1)

- Die kritische Datenstruktur befindet sich in einer versperrten Kiste
- Es gibt nur einen *einzigsten Schlüssel*
- Nur einer kann den Schlüssel haben
- Nur wer den Schlüssel hat, darf auf die Daten zugreifen (und muss nachher wieder zusperren)
- Der Hausmeister (= z.B. das Betriebssystem) verwaltet den Schlüssel

Typischerweise ein separater “Schlüssel”
für jeden zu schützenden Datenbereich ==> mehr Parallelität!

Naive Vorstellung (2)

Lock bzw. **Wait** bzw. **Acquire**:

- Hol dir den Schlüssel vom Hausmeister
- Wenn gerade jemand anderer den Schlüssel hat:
Warte!

Unlock bzw. **Signal** bzw. **Release**:

- Gib den Schlüssel zurück an den Hausmeister
- Wenn jemand auf den Schlüssel wartet:
Der Hausmeister weckt einen auf
und gibt ihm den Schlüssel

Implementierung eines Mutex (1)

Grundsätzlich:

Eine *binäre Variable* (0 / 1)
(+ ev. eine *Queue* für die Wartenden)

Lock:

- *Atomares Test-and-Set* der Variable
- *Warten* wenn Test-and-Set meldet
“war schon gesetzt”

Unlock:

- *Clear* der Variable

Implementierung eines Mutex (2)

Auf Anwendungs- bzw. Library-Ebene:

In vielen Fällen nicht direkt!

Stattdessen:

Nutzung von
Betriebssystem-Funktionalität!

==> Jedesmal ein System Call, dauert!!!

Häufiger Mittelweg:

- Lock-Variable setzen / löschen: Direkt
- Nur wenn Warten / Aufwecken nötig: Syscall

Implementierung des Wartens (1)

Im Normalfall:

Aufruf des Schedulers

- ==> Thread *gibt die CPU ab*
und wird bei Freiwerden der kritischen Region
wieder in die Bereit-Queue des Schedulers gereiht
- ==> Scheduler- bzw. Prozesswechsel-Overhead
- ==> Längere Warte- bzw. Reaktionszeit
- ==> *Kein CPU-Verbrauch* während des Wartens

Implementierung des Wartens (2)

- Nur bei
 - ganz kurzer zu erwartender Sperrzeit
 - und echten Multicore-Systemen

Spin Lock bzw. ***Busy Waiting***

Warten durch ***ständiges Prüfen*** des Mutex-Status in einer ***Schleife***

==> Verheizt während des Wartens sinnlos eine CPU

==> Dafür kein Betriebssystem-Aufruf,
kein Prozesswechsel

==> Reagiert in Nanosekunden auf das Freiwerden!

Wo braucht man das?

Innerhalb des Betriebssystems

... für die internen Datenstrukturen
des Betriebssystems:

Scheduler Queres,

Filesystem-Caches und -Metadaten, ...

In Multithread-Anwendungen

... für von mehreren Threads
gemeinsam benutzte Datenstrukturen

Problem: Race Conditions

“Race Condition” =

*Korrektheit / Ergebnis / Verhalten
des Programms*

hängen von ***zeitlichen Zufällen*** ab.

Ursache:

Kritische Regionen vergessen oder zu klein!

==> Zugriffe auf *gemeinsame Daten*
je nach zufälliger zeitlicher Verzahnung
in *verschiedener Reihenfolge*.

Problem: Deadlocks

“Deadlock” = Verklemmung = Zyklisches Warten
mehrerer Threads aufeinander:

A wartet auf B, B wartet auf A
(„Dining Philosophers“)

==> Keiner kann mehr weiterrechnen, System steht!

==> Gewaltsamer Eingriff von außen nötig!

Ursache (ganz unwissenschaftlich gesprochen):

Zu viele / schlecht entworfene kritische Regionen!

Aber: Theoretisch gut untersucht & gelöst!

Problem: “Übergebliebene” Locks

Wenn ein Thread
innerhalb einer kritischen Region

- eine **Exception** wirft
(die Exception “fliegt” am **Unlock** vorbei!),
- **abstürzt**, getötet wird oder hängenbleibt,
- oder z.B. versehentlich ein **return** enthält,

dann **bleibt die kritische Region gesperrt**

=> Alle anderen hängen “ewig” beim **Lock** !

Problem: Priority Inversion

“Priority Inversion”: (Problem in Echtzeit-Systemen!)

- Unwichtiger Thread C
ist gerade innerhalb einer kritischen Region.
- Halbwichtiger Thread B nimmt C die CPU weg
==> C wird nicht fertig, sperrt die Region “ewig”!
- Hochwichtiger Thread A
wartet auf die von C gesperrte kritische Region.
==> Halbwichtiger B kann hochwichtigen A
beliebig lange blockieren!

Problem: Interrupt Handler

Interrupt Handler

(= jene Codeteile des Betriebssystems,
die hardwaremäßig durch Interrupts aktiviert werden)

dürfen nie blockiert

(wartend gestellt) werden!

==> Daher kann man in Interrupt Handlern
keine kritische Region bzw. Mutex verwenden.

==> Sie erfordern spezielle Techniken
zum Datenaustausch mit dem Rest des Systems!

Problem: Amdahl's Law

„Amdahl's Law“:

Der nicht parallelisierbare Code-Anteil beschränkt die durch Parallelisierung erreichbare Beschleunigung des Gesamtsystems.

Anschaulich: *„50 % Regel“*

„Wenn (zeitlich) die Hälfte des Codes rein sequentiell berechnet werden muss (d.h. innerhalb von kritischen Regionen steht), wird es selbst mit unendlich vielen Prozessoren höchstens doppelt so schnell“

Themenwechsel

-

Fragen?

Alternativen zum wechselseitigen Ausschluss

Klaus Kusche
Juni 2016

Inhalt

- **Motivation**
- **CAS = “Compare and Swap”**
- **RCU = “Read-Copy-Update”**
- **Multiword CAS**
- **STM = “(Software) Transactional Memory”**

Mein Bezug zum Thema

Ich habe Lock-freie, CAS-basierte Algorithmen & Datenstrukturen als zentrale Komponente eines Betriebssystems für industrielle Echtzeit-Steuerungs-Systeme entworfen, implementiert, getestet und optimiert.

Mein Code (entwickelt: 2006 / 2007) läuft derzeit in einigen tausend produktiven Systemen.

(Ich habe das Lock-freie Grundkonzept nicht erfunden und nicht wissenschaftlich weiterentwickelt.)

Motivation

Probleme (siehe zuvor) von wechselseitigem Ausschluss

=> Forderung “*Lock-freier*” Code

Kein Thread wird je blockiert (zeitlich)
bzw. von einem Stück Code ausgesperrt (örtlich).

Weitere sinnvolle Anforderung:

Mindestens einer der laufenden Threads
macht immer echten Fortschritt
(= sinnvolle Arbeit).

(das vermeidet “Livelocks”,
d.h. dass sich mehrere Threads
ewig sinnlos gegenseitig beschäftigen)

Eine „Lock-freie“ Lösungsidee

Der „optimistische“ Ansatz:

“wird schon keiner gleichzeitig zugreifen”

- Jeder macht seine Berechnungen „ganz normal“, als ob er der einzige Thread wäre...
- ... und erst **am Ende beim Speichern** der Ergebnisse in die gemeinsamen Daten:

Jeder prüft, ob ein anderer inzwischen die Daten “hinter seinem Rücken“ verändert hat.

Wenn ja (sehr selten!): “Nochmal probieren!”
(Berechnung mit den neuen Daten wiederholen, wieder prüfen und speichern)

Die Grund-Operation dafür: CAS

Jede Art der Synchronisation paralleler Threads
braucht Hardware-Unterstützung!

In unserem Fall für den

“prüfen-und-wenn-ok-speichern”-Schritt:

Maschinenbefehl

“Compare and Swap” (CAS)

Was macht CAS(xPtr, old, new) ?

- **xPtr** ... Zeiger auf zu ändernde Variable **x**
- **old** ... erwarteter alter Wert von **x**
- **new** ... zu schreibender neuer Wert von **x**

```
int CAS(int *xPtr, int old, int new) {  
    if (*xPtr == old) { // Diese beiden *xPtr ...  
        *xPtr = new; // ... müssen atomar sein!  
        return new; // new heißt „Erfolg“  
    } else { // Verändere x nicht!!!  
        return *xPtr; // Nicht new = „Misserfolg“  
    }  
}
```

Einfachste Verwendung von CAS

```
// hol den alten Wert der gemeinsamen Variable x  
old = x;  
do {  
    // berechne den neuen Wert von x in new  
    // nur auf old basierend (nicht mehr auf x,  
    // denn x könnte inzwischen geändert werden!)  
    new = ... old ... ;  
    // versuche das Ergebnis zu speichern  
    old = CAS(&x, old, new);  
    // wiederhole Berechnung bis erfolgreich gespeichert  
} while (old != new);
```


Die Implementierung von CAS

... muss atomar sein:

*Kein anderer Thread darf **x**
zwischen Vergleich und Zuweisung ändern!*

- IBM 370 Großrechner: Seit 1970 eigener Befehl
- x86: Befehl “**CMPXCHG**” (und weitere)
(“COMpare and eXCHanGe”, seit i486)
- ARM, PowerPC, ...: Zwei Befehle ohne Lock in HW!
“**LL**” = “Load Linked” + “**SC**” = “Store Conditional”
- Auf Single-Core-Systemen:
Normaler Code innerhalb Interrupt-Sperre.

Read-Copy-Update (1)

Einfachste “Lock-freie” Datenstruktur, Voraussetzung:

Zugriff auf die Datenstruktur (bzw. ihre Elemente)
über einen einfachen Pointer

=> Es genügt, einen einzelnen Pointer auszutauschen,
um die Struktur bzw. ein Element atomar zu ändern!

=> Bestehende Daten werden nie “in Place” geändert,
nur als Ganzes durch woanders gespeicherte ersetzt!

Sehr häufig verwendet in vielen Betriebssystemen
(in IBM-Betriebssystemen seit ~1970 zentrales Konzept,
auch Linux enthält über 5000 RCU-Datenstrukturen!)

Read-Copy-Update (2)

- Leser:
 - Müssen **read_begin()** und **read_end()** aufrufen, um über aktive Leser Buch zu führen (in Linux: unnötig!)
 - Lesen ganz normal (ohne Locks, ohne CAS, ...).
- Schreiber:
 - Machen eine private Kopie des Original-Elementes.
 - Ändern ihre private Kopie ganz normal (ohne CAS).
 - Ersetzen das Original durch ihre Kopie, indem sie den Pointer darauf auf ihre Kopie umbiegen.
 - Schützen das Ändern des Pointers mit CAS (oder Locks).
- Aufräumen:
 - Wenn der letzte Leser die alten, ausgehängten Daten verlassen hat: Speicher freigeben.

Komplexe Datenstrukturen & CAS

Komplexe Datenstrukturen (verkettete Listen, Bäume, ...)

benötigen mehrere Schreibzugriffe
um von einem konsistenten Zustand
zum nächsten zu kommen

„Einfach mehrere CAS nacheinander“ ist keine Lösung:

- Das erste CAS endet erfolgreich
- Das zweite CAS schlägt fehl

=> Die Datenstruktur ist inkonsistent!

=> Es gibt keine einfache Möglichkeit zum Wiederholen
oder zum rückgängig Machen der kaputten Änderung!

Ad-hoc Lösung: Nachdenken!

Für manche Datenstrukturen schafft man es,

clevere Algorithmen mit CAS zu “erfinden”!

Beispiel:

Einfach & doppelt verkettete Listen haben wir gelöst!

- Es gibt kein mechanisches “Kochrezept” zur Umformung bestehender Algorithmen!

- Sehr schwierig:

Meist fällt einem keine / eine falsche Lösung ein...

- Die Algorithmen sind schwer zu lesen & zu verstehen, ihre Korrektheit kaum mit Kopf & Papier überprüfbar!

Systematische Lösung: Multiword CAS

- Nimm an, es gibt eine CAS-Grundoperation, die atomar mehrere Variablen prüft und setzt:

```
MultiCAS(xPtr1, old1, new1,  
         xPtr2, old2, new2,  
         xPtr3, old3, new3, ...)
```

- Zuerst alle Werte prüfen
(alle Prüfungen müssen erfolgreich sein!)
- Dann alle Werte auf einmal speichern, oder gar keinen
... und das alles atomar
=> Hinterlässt nie teilweise geänderte Daten!!!

Multiword CAS Implementierung

- Multiword CAS ist nicht in Hardware verfügbar ...
- ... aber kann basierend auf Single-Word CAS in Software implementiert werden
- Erstes praktisch umsetzbares Paper (Vorlage für mich)
“Timothy L. Harris, Keir Fraser, Ian A. Pratt:
A Practical Multi-Word Compare-and-Swap Operation” (2002)
- Das “Innenleben” von Multiword CAS ist kompliziert und relativ langsam (mindestens 3 CAS pro Variable)
- *Gegen “halbe” Änderungen: Auch Lesezugriffe müssen über die Multiword-CAS-Library erfolgen!!!*

Multiword CAS Algorithmen

- Gleiche Struktur wie Single-Word-CAS-Algorithmen:
Alte Daten holen, neue ausrechnen,
ein CAS machen, ev. wiederholen bis erfolgreich
- Den Code der meisten gebräuchlichen Datenstrukturen
kann man fast mechanisch in Lock-freien Code
mit Multiword CAS transformieren
(Balancierte Bäume sind eine Ausnahme, normale sind ok).
- Die entstehenden Algorithmen sind
einfach, elegant und offensichtlich korrekt.
- **Aber** (weil Multiword CAS so lange dauert):
Die Wahrscheinlichkeit von Kollisionen und Retries
steigt deutlich!

Vergleich

Library (produktiver C-Code) für

doppelt verkettete Listen

- **Sequentieller Code: ~ 830 Lines of Code**
- **Lösung mit Multiword CAS: ~ 1920 LoC**
(inclusive 900 LoC Multiword CAS Library)
- **Ad-hoc-Algorithmus mit einfachem CAS: ~ 1510 LoC**
 - **Läuft mehr als doppelt so schnell!**
 - **Aber brauchte vierfache Entwicklungs- & Test-Zeit!**
 - **... und hat schlechtere Daten-Konsistenz-Eigenschaften.**

Alle Probleme gelöst?

Lock-freie Algorithmen ...

- verhalten sich zwar ähnlich „Amdahl's Law“ (*Kollisionen und Retry's nehmen zu*), aber

*skalieren in der Praxis
viel besser als Locks!*

- kennen keine Deadlocks
(zumindest einer kommt immer voran)
- sind für Interrupt-Handler geeignet
- brauchen keine Syscalls und keine Taskwechsel

Ungelöste Probleme

Theoretisch sind

unendlich viele Retries möglich!

A stört B immer wieder

→ B wird trotz CPU-Verbrauch nie fertig!

Bei „echter“ Parallelität = Multi-Core:

Auch wenn A niedrigere Priorität als B hat

→ Effekt ähnlich „Priority Inversion“

→ Nicht für (beweisbar) „harte“ Echtzeit geeignet!

Und bei manchen Algorithmen:

Nicht resistent gegen Abstürze, Exceptions, ...!

Lösung aller Probleme: „Wait-frei“

Formale Anforderung:

Die gesamte noch verbleibende Arbeit
muss zu jedem Zeitpunkt weniger werden!

- Alle Threads (nicht nur einer wie bei „Lock-frei“)
- machen garantiert Fortschritte bzw. sinnvolle Arbeit,
wenn sie CPU brauchen
 - und enden in endlicher, deterministischer CPU-Zeit!

(Auch bei maximaler Konkurrenz wird keine Arbeit verschwendet,
und kein Thread wird mit unabsehbar viel Zusatzarbeit belastet)

→ „Probier's nochmal“-Schleifen sind verboten!!!

Gute „Wait-freie“ Algorithmen ...

- ... muss man individuell „erfinden“: Kein „Kochrezept“
- Sehr schwierig, bisher nur für wenige Probleme gelöst

Grundidee:

- Mach nur Arbeit, die **garantiert** „nützlich“ ist!
- Wenn du mit deiner Arbeit nicht mehr weiterkannst, weil zuerst andere ihre Arbeit fertig machen müssen:
 - Entweder: Mach **zuerst deren Arbeit**, dann deine!
(Die merken das dann bei ihrem CAS und freuen sich...)
 - Oder: Sorge dafür, dass andere deine Arbeit fertigstellen, nachdem sie ihre beendet haben!
(„Der Letzte räumt alles auf!“)

Transactional Memory (1)

Abstraktes Modell von Daten im Speicher,

Idee ähnlich wie bei Datenbanken:

- 1) “Begin transaction”
- 2) Gemeinsame Daten im Speicher
beliebig lesen & schreiben
- 3) “Commit” (oder “Abort”)

Transactional Memory (2)

“Commit” ist wie bei Datenbanken

**garantiert atomar:
“*Alles oder nichts*”**

=> Die Änderungen sind davor für andere *nicht* sichtbar!

=> Alle Änderungen werden auf einmal sichtbar,
andere sehen nie “*halbe*” Änderungen!

=> **Sehr universell, leicht zu verstehen / zu verwenden!**

Aber:

“Commit” kann bei konkurrierenden Schreibzugriffen
fehlschlagen! (=> *automatisches oder explizites Retry*)

Transactional Memory in SW

Implementierung:

- Für fast alle Sprachen:
Zahlreiche Libraries verfügbar
- Basierend auf verschiedenen Grund-Operationen:
Locks, Lock-frei (CAS), oder MMU- bzw. Paging-basiert
- Meist komplex und langsam,
einige closed-source und Patent-geschützt!
- Demnächst: ***Standardisierte Sprachkonstrukte***
in C / C++ (derzeit im Beta-Test von **gcc** und **icc**)

Transactional Memory in HW

Implementiert seit Intel Skylake
(+ gefixte Steppings von Broadwell, Haswell E):

“TSX” =

Transactional Synchronization Extensions

- Eigene Befehle
- Implementierung: Lock-frei!

Basierend auf erweiterter Cache-Logik:
Mehrere “private” Cache-Schattenkopien
desselben Speicherbereichs

- TSX-Software-Emulation u.a. in QEMU

“The end”

Fragen?