

Systemprogrammierung

Prozesssynchronisation: Nichtsequentialität

Wolfgang Schröder-Preikschat

Lehrstuhl Informatik 4

6. Mai 2013

Gliederung

- 1 Kausalitätsprinzip
 - Parallelisierbarkeit
 - Kausalordnung
- 2 Konkurrenz und Koordination
 - Koordinierung
 - Konkurrenz
- 3 Verfahrensweisen
 - Einordnung
 - Kritischer Abschnitt
 - Lebendigkeit
- 4 Zusammenfassung

Nebenläufige Programmabschnitte

Sequentielles $\mapsto$ Nichtsequentielles Programm

Nebenläufigkeit (engl. *concurrency*) bezeichnet das Verhältnis von nicht kausal abhängigen Ereignissen, die sich also nicht beeinflussen

- Aktionen können nebenläufig ausgeführt werden, wenn keine das Resultat des anderen benötigt

```

1:    foo = 4711;
2:    bar = 42;
3:  foobar = foo + bar;
4:  barfoo = bar + foo;
5:    hal = foobar + barfoo;
  
```


- Zeile 1 kann nebenläufig zu Zeile 2 ausgeführt werden
- Zeile 3 kann nebenläufig zu Zeile 4 ausgeführt werden

Kausalität (lat. *causa*: Ursache) ist die Beziehung zwischen **Ursache** und **Wirkung**, d.h., die ursächliche Verbindung zweier Ereignisse

- Ereignisse sind nebenläufig, wenn keines Ursache des anderen ist

Ursache und Wirkung

Nebenläufigkeit als relativistischer Begriff von Gleichzeitigkeit



- ein Ereignis **ist nebenläufig zu** einem anderen (e_i), wenn es im **Anderswo** des anderen Ereignisses (e_i) liegt
 - d.h., weder in der Zukunft noch in der Vergangenheit des anderen
- das Ereignis ist nicht Ursache/Wirkung des anderen Ereignisses (e_i)
 - ggf. aber Ursache/Wirkung anderer (von e_i verschiedener) Ereignisse

Rangfolge aus Gründen von Daten- und Zeitabhängigkeit

Aktionen können — um selbst ein korrektes Ergebnis zu produzieren — nebenläufig stattfinden, sofern:

allgemein keine das Resultat der anderen benötigt (S. 3)

- **Datenabhängigkeiten** gleichzeitiger Prozesse beachten

speziell (zusätzlich im Echtzeitbetrieb) keine die **Zeitbedingungen** der anderen verletzt

- Zeitpunkte dürfen nicht/nur selten verpasst werden
- Zeitintervalle dürfen nicht/nur begrenzt gedehnt werden

Umgang mit Ereignissen bzw. Aktionen gleichzeitiger Prozesse

$\left. \begin{array}{l} \text{„ist Ursache von“} \\ \text{„ist Wirkung von“} \end{array} \right\} \leadsto \text{Koordinierung (vor/zur Laufzeit)}$
 $\text{„ist nebenläufig zu“} \models \text{Parallelität (implizit)}$

Gliederung

1 Kausalitätsprinzip

- Parallelisierbarkeit
- Kausalordnung

2 Konkurrenz und Koordination

- Koordinierung
- Konkurrenz

3 Verfahrensweisen

- Einordnung
- Kritischer Abschnitt
- Lebendigkeit

4 Zusammenfassung

Serialisierung gleichzeitiger Aktivitäten

Maßnahme zum korrekten Zugriff gleichzeitiger Prozesse auf gemeinsame aber unteilbare Betriebsmittel, mit sehr unterschiedlicher Auswirkung:

- blockierend** • pessimistische Annahme einer Überlappung ☹️
- nichtblockierend** • optimistische Annahme keiner Überlappung 😊


Synchronisation (gr. *syn*: zusammen, *chrónos*: Zeit) bezeichnet allg. das **Herstellen von Gleichzeitigkeit**

- (a) Koordination der Kooperation und Konkurrenz zwischen Prozessen ✕
- (b) Abgleich von Echtzeituhren (oder Daten) in verteilten Systemen
- (c) Sequentialisierung von Ereignissen entlang einer Kausalordnung

Herangehensweisen

- analytisch** • Prozesseinplanung: implizite Synchronisation
- konstruktiv** • Programmiertechniken: **explizite Synchronisation** ✕

Betriebsmittel und Betriebsmittelarten



Hardware

- CPU, Speicher
- Geräte (Peripherie)
- *Signale*

Software

- Dateien, E/A-Puffer
- Seitenrahmen
- Deskriptoren, ...
- *Signale, Nachrichten*

Wettbewerb um Betriebsmittel (engl. *resource contention*)

Anzahl und Art der Betriebsmittel bedingen **problemspezifische Verfahren**:

- einseitige Synchronisation** • konsumierbare Betriebsmittel
- mehrseitige Synchronisation** • wiederverwendbare Betriebsmittel

Unteilbarkeit

Duden¹: Einheit, Ganzheit, Zusammengehörigkeit

(Wirtschaft) Umstand, der die Verteilung der Produktion auf mehrere Unternehmen oder Arbeitskräfte verhindert.

Sinnbild: Übertragung auf nichtsequentielle Programme

(Informatik, Betriebssysteme) Umstand, der die Verteilung der Betriebsmittel auf mehrere Prozessoren oder Prozesse verhindert.

- unteilbar ist ein Betriebsmittel, wenn es zu einem Zeitpunkt von nur genau einem Prozessor/Prozess genutzt werden darf
 - **Zugriffsoperationen** darauf können/dürfen nicht zeitlich zerteilt werden
 - sie müssen **atomar**, d.h., als **Elementaroperation** ausgeführt werden
- teilbar ist ein Betriebsmittel, wenn mehrere Prozessoren/Prozesse es gleichzeitig benutzen dürfen
 - es dem einem entzogen und einem anderen gegeben werden darf

¹<http://www.duden.de/rechtschreibung/Unteilbarkeit>

Konfliktfall bei der Benutzung von Betriebsmitteln

Prozesse befinden sich untereinander im **Konflikt**, wenn:

- ① nur eine begrenzte Anzahl gemeinsamer Betriebsmitteln vorrätig ist
- ② diese Betriebsmittel unteilbar und von derselben Art sind
- ③ ein Zugriff darauf gleichzeitig geschieht: **gleichzeitige Prozesse** [1]

Prozesse sind im **Wettstreit** (engl. *contention*) um ein Betriebsmittel, wenn einer das Betriebsmittel anfordert, das ein anderer bereits besitzt

- der anfordernde Prozess blockiert und wartet auf die Freigabe des Betriebsmittels durch den Prozess, der das Betriebsmittel belegt
- der das Betriebsmittel belegende Prozess löst den auf die Freigabe des Betriebsmittels wartenden Prozess aus, deblockiert ihn wieder

Wechselseitiger Ausschluss

- n -fach mehrseitige, für $n - 1$ blockierend wirkende Synchronisation
- eine **Option** zum Schutz eines kritischen Abschnitts

Wechselseitiger Ausschluss

Reihenschaltung von Prozessen mit begrenzten/unteilbaren Betriebsmitteln

Sequenzialisierung der Zugriffe gleichzeitiger Prozesse per Protokoll:

Vergabe $\mapsto$ das Betriebsmittel sperren und dem Prozess zuteilen

- beim Versuch, ein gesperrtes Betriebsmittel erneut zu belegen, wird der anfordernde Prozess blockiert
- der blockierende Prozess erwartet das Ereignis/Signal zur Freigabe des gesperrten Betriebsmittels, ihm wird die CPU entzogen

Freigabe $\mapsto$ das Betriebsmittel dem Prozess wieder entziehen

- sollten Prozesse die Freigabe dieses Betriebsmittels erwarten, wird es sofort der **Wiedervergabe** zugeführt; das bedeutet:
 - (a) das Betriebsmittel entsperren und alle Prozesse deblockieren, die sich dann wiederholt um die Vergabe zu bemühen haben *oder*
 - (b) einen Prozess auswählen und ihm das Betriebsmittel zuteilen
- nur der das Betriebsmittel „besitzende“ Prozess kann es freigeben

Reihenschaltung gleichzeitiger Prozesse: Koordinierung

Synchronisation $\equiv$ Koordination der Kooperation und Konkurrenz zwischen Prozessen

ko-or-di'nie-ren beiordnen; in ein Gefüge einbauen; aufeinander abstimmen; nebeneinanderstellen; Termine $\sim$.

- sich überlappen könnende Aktivitäten der Reihe nach ausführen
 - gleichzeitige Prozesse im kritischen Abschnitt koordinieren
- „der Reihe nach“ $\rightsquigarrow$ **Verzögerung gleichzeitiger Prozesse erzwingen**
 - (a) potentiell überlappende Prozesse verzögern, der Konflikt ist ungewiss
 - (b) den überlappten Prozess verzögern, der Konflikt ist gewiss

Synchronisationsverfahren...


- wirken einseitig oder mehrseitig
 - unterdrückend, blockierend, nichtblockierend
 - behinderungs-, sperr-, wartefrei



Gliederung

- 1 Kausalitätsprinzip
 - Parallelisierbarkeit
 - Kausalordnung
- 2 Konkurrenz und Koordination
 - Koordinierung
 - Konkurrenz
- 3 Verfahrensweisen
 - Einordnung
 - Kritischer Abschnitt
 - Lebendigkeit
- 4 Zusammenfassung

Arten der Synchronisation



SP: Untersuchte Verfahren

(Grau hinterlegte Techniken)

einseitig unterdrueckend: Ereignisse (Unterbrechungen, Verdraengungen)
mehrseitig blockierend bzw. nichtblockierend: Prozessinkarnationen

Ebene₅ Bedingungsvariable, Monitor

Ebene₃ Verdraengungen, Semaphore

Ebene₂ Unterbrechungen, Schlossvariable, CAS

Einseitige Synchronisation

Unilateral

Auswirkung haben die Verfahren nur auf einen der beteiligten Prozesse; zwei Begrifflichkeiten sind gebräuchlich:

Bedingungsynchronisation

- der Ablauf des einen Prozesses ist abhängig von einer Bedingung
- der andere Prozess erfährt keine Verzögerung in seinem Ablauf

logische Synchronisation

- die Maßnahme resultiert aus der logischen Abfolge der Aktivitäten
- vorgegeben durch das „Rollenspiel“ der beteiligten Prozesse

Beachte: Andere Prozesse sind jedoch nicht gänzlich unbeteiligt

- die Veränderung einer Bedingung, auf die ein Prozess wartet, ist z.B. von einem anderen Prozess herbeizuführen

Mehrseitige Synchronisation

Multilateral

Auswirkung haben die Verfahren ggf. auf alle beteiligten Prozesse:

- welche Prozesse verzögert werden, ist i.A. unvorhersehbar

Beispiel: Wechselseitiger Ausschluss (engl. *mutual exclusion*)

- erzwungene sequentielle Ausführung von Anweisungsfolgen
- im Regelfall zeitlich begrenzte, exklusive Betriebsmittelvergabe

Beispiel: Kritischer Abschnitt (engl. *critical section/region*)

wettlaufintolerant

- wechselseitiger Ausschluss
- Verzögerung ggf. folgender gleichzeitiger Prozesse

wettlauftolerant

- nichtsequentielle Ausführung
- Verzögerung überlappter gleichzeitiger Prozesse

Betriebsmittelart und Synchronisationstechnik

Artenspezifische Verfahren

Notwendigkeit des Ausschlusses gleichzeitiger Prozesse ist immer nur in folgenden Fällen gegeben $\leadsto$ **blockierende Synchronisation**:

- beim Zugriff auf unteilbare wiederverwendbare Betriebsmittel
- bei Inanspruchnahme eines konsumierbaren Betriebsmittels²

Schutz eines kritischen Abschnitts (KA) bedingt sich in anderer Weise und ist auf zwei verschiedenen Wegen möglich:

pessimistisch $\leftrightarrow$ **wechselseitiger Ausschluss** (block. Synchronisation) ☹️

- KA implementiert als sequentielles Programm
- entsprechend der „herkömmlichen Sichtweise“ (S. 18)

optimistisch $\leftrightarrow$ **nichtblockierende Synchronisation** 😊

- KA implementiert als *nichtsequentielles Programm*
- entsprechend der „alternativen Sichtweise“ (S. 18)

²Konsument erwartet Betriebsmittelbereitstellung durch den Produzenten.

Kritischer Abschnitt (KA)

Kennzeichnend für mehrseitige Synchronisation

Aspekte eines KA [4, S. 137], die die herkömmliche Sichtweise darlegen:

- sich gegenseitig ausschließende Aktivitäten
 - werden nie parallel ausgeführt
 - verhalten sich zueinander, als seien sie unteilbar, weil keine Aktivität die andere unterbricht
- Anweisungen, deren Ausführung wechselseitigen Ausschluss erfordert

Eine Frage der Abstraktionsebene $\leftrightarrow$ alternative Sichtweise

- der wechselseitige Ausschluss (von gleichzeitigen Prozessen) ist nicht zwingend, um einen kritischen Abschnitt zu schützen
- vielmehr gilt es sicherzustellen, dass die Ausführung eines solchen Abschnitts jederzeit ein **konsistentes Ergebnis** liefert

Atomarität kritischer Abschnitte

Beachte

Ein Programmabschnitt ist kritisch, wenn er bei Ausführung durch einen Prozessor vor dem Hintergrund gleichzeitiger Prozesse wenigstens eine Wettlaufsituation zeigt.

- unteilbarer KA
 - ist **blockierend** synchronisiert
 - wird von gleichzeitigen Prozessen immer **sequentiell** durchlaufen
- teilbarer KA
 - ist **nichtblockierend** synchronisiert
 - wird von gleichzeitigen Prozessen **nichtsequentiell** durchlaufen

KA durch prozedurale Abstraktion „verbergen“

- KA logisch als **Elementaroperation** (ELOP) auslegen $\leadsto$ Prozedur
- den ausgeklammerten Programmabschnitt problemgerecht schützen

Verhaltensregeln zum Durchlaufen kritischer Abschnitte

Betreten (engl. *enter*) und Verlassen (engl. *leave*) kritischer Abschnitte steuern **problemspezifische Protokolle**

Eintrittsprotokoll (engl. *entry protocol*)

- regelt die Belegung des kritischen Abschnitts durch einen Prozess
 - erteilt einem Prozess die Zugangsberechtigung
- bei bereits belegtem Abschnitt: **Wettstreitigkeit** (engl. *contention*)
 - blockierend** • den eintreffenden Prozess am Eintritt hindern
 - nichtblockierend** • den Abschnitt belegenden Prozess überlappen dürfen

Austrittsprotokoll (engl. *exit protocol*)

- regelt die Freigabe des kritischen Abschnitts durch einen Prozess
 - blockierend** • ggf. am Eintritt gehinderte(n) Prozess(e) freigeben
 - nichtblockierend** • den überlappten Prozess zurücksetzen/wiederholen
- Prozesse können den kritischen Abschnitt (wieder) belegen

- die Vorgehensweise variiert mit dem jew. Synchronisationsverfahren

Bedingter kritischer Abschnitt³

Betreten des kritischen Abschnitts ist von einer Wartebedingung abhängig, die nicht erfüllt sein darf, um den Prozess fortzusetzen

- die Bedingung ist als **Prädikat** über die im kritischen Abschnitt enthaltenen bzw. verwendeten Daten definiert
- typischerweise technisch realisiert durch eine **Bedingungsvariable**

Auswertung der Wartebedingung muss im kritischen Abschnitt erfolgen

- bei Nichterfüllung der Bedingung wird der Prozess auf Eintritt eines zur Wartebedingung korrespondierenden Ereignisses blockiert
 - damit das Ereignis später signalisiert werden kann, muss der kritische Abschnitt beim Schlafenlegen jedoch freigegeben werden
- bei (genauer: nach) Erfüllung/Signalisierung der Bedingung versucht der Prozess den kritischen Abschnitt wieder zu belegen
 - ggf. muss ein deblockierter Prozess die Bedingung neu auswerten

³engl. *conditional critical section* resp. *region*, [5].

Sprachunterstützung: Hoare [5]

Koordinierungsbefehle automatisch abgesetzt durch einen Kompilierer

Kritischer Abschnitt

```
resource r;
with r do
  begin
    :
  end
```

- with**
- Selektionsanweisung
 - *r* ist „beliebige“ Variable
 - assoziiert Daten mit KA
- do**
- Anweisung(en) des KA

Bedingter kritischer Abschnitt

```
resource r; boolean b;
with r when b do
  begin
    :
  end
```

- when**
- Fortführungsbedingung
 - *true* $\leadsto$ fortfahren
 - *false* $\leadsto$ warten

Wechselseitiger Ausschluss

- für die gesamte **do**-Anweisung

Signalisierung und Freistellung

- implizit bei Zustandswechsel

Fortschrittsgarantien

Aussagen zur Lebendigkeit (engl. *liveliness*) nichtsequentieller Programme [2, 3]

behinderungsfrei (engl. *obstruction-free*)

- ein einzelner, in Isolation ablaufender Faden wird seine Operation in begrenzter Anzahl von Schritten beenden
- ein Faden läuft in Isolation ab, wenn alle anderen Fäden, die ihn behindern könnten, in der Ausführung zurückgestellt sind

sperrfrei (engl. *lock-free*), umfasst Behinderungsfreiheit

- jeder bei Ablauf eines Fadens auszuführende Schritt trägt dazu bei, dass das nichtsequentielle Programm insgesamt voranschreitet
- garantiert systemweiten Durchsatz, erlaubt jedoch **Aushungerung** (engl. *starvation*) eines einzelnen Fadens

wartefrei (engl. *wait-free*), umfasst Sperrfreiheit

- die Anzahl der zur Beendigung einer Operation bei Fadenabläufen auszuführenden Schritte ist begrenzt
- garantiert systemweiten Durchsatz und ist frei von Aushungerung

Gliederung

1 Kausalitätsprinzip

- Parallelisierbarkeit
- Kausalordnung

2 Konkurrenz und Koordination

- Koordinierung
- Konkurrenz

3 Verfahrensweisen

- Einordnung
- Kritischer Abschnitt
- Lebendigkeit

4 Zusammenfassung

Dualität von Koordinierungstechniken

Theorie vs. Praxis

Problem:

- Erhöhung von Parallelität
- wechselseitiger Ausschluss
- explizite Prozesssteuerung
- bedingte Verzögerung
- Austausch von Zeitsignalen
- Austausch von Daten

Methode:

- nichtblockierende Synchronisation
- Schlossvariable
- Bedingungsvariable
- bedingter kritischer Abschnitt
- Semaphor
- Nachrichtenpuffer

logisch betrachtet sind alle Methoden äquivalent, da jede von ihnen hilft, ein beliebiges Steuerungsproblem zu lösen

praktisch betrachtet sind die Methoden nicht äquivalent, da einige von ihnen für ein gegebenes Problem zu komplexen und ineffizienten Lösungen führen

Resümee

- **Nebenläufigkeit** setzt voneinander unabhängige Prozesse voraus
 - bezeichnet das Verhältnis von nicht kausal abhängigen Ereignissen
 - schränkt sich ein aus Gründen von Daten- oder Zeitabhängigkeit
- gleichzeitige abhängige Prozesse implizieren **Koordinierung**
 - nämlich der Kooperation und Konkurrenz zwischen Prozessen
 - durch analytische (implizite) oder konstruktive (explizite) Techniken
- **Synchronisation** zeigt einen großen Facettenreichtum
 - klassifiziert nach der jeweiligen Auswirkung auf beteiligte Prozesse:
 - einseitig oder mehrseitig
 - unterdrückend, blockierend oder nicht-blockierend
 - behinderungs-, sperr- oder wartefrei
 - verschiedenen Abstraktionsebenen eines Rechensystems zugeordnet:
 - Hochsprachenebene** Bedingungsvariable, Monitor
 - Maschinenprogrammebene** Verdrängungssteuerung, Semaphor
 - Befehlssatzebene** Schlossvariable, Spezialbefehle (CPU)
- Aussagen zur „Lebendigkeit“ nichtsequentieller Programme leiten sich aus den **Fortschrittsgarantien** der Synchronisationsverfahren ab

Literaturverzeichnis

- [1] HANSEN, P. B.:
Operating System Principles.
Prentice Hall International, 1973
- [2] HERLIHY, M. :
Wait-Free Synchronization.
In: *ACM Transactions on Programming Languages and Systems* 11 (1991), Jan., Nr. 1, S. 124–149
- [3] HERLIHY, M. ; LUCHANGCO, V. ; MOIR, M. :
Obstruction-Free Synchronization: Double-Ended Queues as an Example.
In: *Proceedings of the 23rd International Conference on Distributed Computing Systems (ICDCS 2003), May 19–22, 2003, Providence, Rhode Island, USA*, IEEE Computer Society, 2003, S. 522–529
- [4] HERRTWICH, R. G. ; HOMMEL, G. :
Kooperation und Konkurrenz — Nebenläufige, verteilte und echtzeitabhängige Programmsysteme.
Springer-Verlag, 1989. –
ISBN 3–540–51701–4

Literaturverzeichnis (Forts.)

- [5] HOARE, C. A. R.:
Towards a Theory of Parallel Programming.
In: HOARE, C. A. R. (Hrsg.) ; PERROT, R. H. (Hrsg.): *Operating System Techniques*.
New York, NY : Academic Press, Inc., Aug. – Sept. 1971 (Proceedings of a Seminar at Queen's University, Belfast, Northern Ireland), S. 61–71