

Überblick

Zugriffskontrolle

Konkurrenz und Koordination
 Verdrängungssteuerung
 Prioritätsvererbung
 Prioritätsobergrenzen
 Zusammenfassung
 Bibliographie

Echtzeitsysteme Zugriffskontrolle

13. Dezember 2010

Nebenläufige Aktivitäten 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

Überblick


Zugriffskontrolle

Konkurrenz und Koordination
 Verdrängungssteuerung
 Prioritätsvererbung
 Prioritätsobergrenzen
 Zusammenfassung
 Bibliographie

Kausalordnung

Nebenläufigkeit als relativistischer Begriff von Gleichzeitigkeit

Relationen „ist Ursache von“, „ist Wirkung von“, „ist nebenläufig zu“:



- ▶ ein Ereignis **ist nebenläufig zu** einem anderen, wenn es im **Anderswo** des anderen Ereignisses liegt
 - ▶ d.h., weder in der Zukunft noch in der Vergangenheit des anderen
- ▶ das Ereignis ist weder Ursache oder Wirkung des anderen Ereignisses

Kausalordnung (Forts.)

Rangfolge aus Gründen von Daten- und Zeitabhängigkeit

„ist Ursache von“
„ist Wirkung von“
„ist nebenläufig zu“ } \rightsquigarrow **Sequentialisierung** von Ereignissen/Aktionen

Aktionen können im **Echtzeitbetrieb** nebenläufig stattfinden, wenn ...

- ▶ keine das Resultat der anderen benötigt (S. 7-2) ✓
- ▶ keine die (strikten) Zeitbedingungen der anderen verletzt
 - ▶ Zeitpunkte dürfen nicht bzw. nur selten verpasst werden
 - ▶ Zeitintervalle dürfen nicht bzw. nur begrenzt zeitlich gedehnt werden
 - ▶ Abstand zwischen Ursache (Ereigniszeitpunkt) und Wirkung (Termin)

☞ die Relationen unterliegen (weichen bis harten) Echtzeitbedingungen

Koordinierung

Reihenschaltung nebenläufiger Aktivitäten

Zugriffskontrolle koordiniert nebenläufige Zugriffe auf gemeinsame aber unteilbare Betriebsmittel \rightsquigarrow Synchronisation

- ▶ blockierend, wenn das Betriebsmittel nicht die CPU ist
- ▶ möglicherweise nicht-blockierend, sonst...
 - ▶ kritische Abschnitte


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

- ▶ Koordination der Kooperation und Konkurrenz zwischen Prozessen
- ▶ Abgleich von Echtzeituhren (oder Daten) in verteilten Systemen
- ▶ Sequentialisierung von Ereignissen entlang einer Kausalordnung
 - ▶ z.B. logische Uhren

☞ analytisch oder konstruktiv: Einplanung vs. Implementierung (S. 4-20)

Konkurrenz

Betriebsmittel und Betriebsmittelarten



Wettbewerb um Betriebsmittel (engl. *resource contention*) bezieht sich auf Anzahl und Art eines Betriebsmittels

einseitige Synchronisation \rightsquigarrow konsumierbare Betriebsmittel

mehrseitige Synchronisation \rightsquigarrow wiederverwendbare Betriebsmittel

- ▶ Begrenzung, gegenseitiger Ausschluss

Konkurrenz (Forts.)

Serialisierung von Arbeitsabläufen mit begrenzten/unteilbaren Betriebsmitteln

Betriebsmittel, die unteilbar sind, können von gleichzeitigen Prozessen bzw. Arbeitsaufträgen nur nacheinander belegt werden

Vergabe \rightsquigarrow das Betriebsmittel sperren und dem Job zuteilen P

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

Freigabe \rightsquigarrow das Betriebsmittel dem Job wieder entziehen V

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

Konfliktsituation

Blockierung von Arbeitsaufträgen

Arbeitsaufträge befinden sich untereinander im **Konflikt**, wenn...

- ▶ nur eine begrenzte Anzahl gemeinsamer Betriebsmitteln vorrätig ist
- ▶ sie unteilbare Betriebsmittel desselben Typs gemeinsam verwenden

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

- ▶ der anfordernde Job blockiert und wartet auf die Freigabe des Betriebsmittels durch den Job, der das Betriebsmittel belegt
- ▶ der das Betriebsmittel belegende Job löst den auf die Freigabe des Betriebsmittels wartenden Job aus, d.h., deblockiert in wieder

👉 Nutzung begrenzter/unteilbarer Betriebsmittel impliziert **Kooperation**

Wettstreit um Betriebsmittel

Beispiel: $J_l \mapsto 6(0, 18]$, $J_m \mapsto 7(2, 17]$, $J_h \mapsto 5(2, 14]$



J_l (niedrige Priorität)

- t_0 startet
- t_1 belegt R_i
- t_4 setzt Ausführung fort
- t_8 setzt Ausführung fort
- t_9 gibt R_i frei $\mapsto J_h$
- t_{17} setzt Ausführung fort
- t_{18} beendet die Ausführung

J_m (mittlere Priorität)


- t_2 startet, verdrängt J_l
- t_4 fordert R_i an, blockiert
- t_{12} belegt R_i
- t_{16} gibt R_i frei
- t_{17} beendet die Ausführung

J_h (hohe Priorität)

- t_6 startet, verdrängt J_l
- t_8 fordert R_i an, blockiert
- t_9 deblockiert, belegt R_i
- t_{11} gibt R_i frei $\leadsto J_m$
- t_{12} beendet die Ausführung

Anomalie im Laufzeitverhalten

Beispiel: $J_l \mapsto 4.5(0, 18]$, $J_m \mapsto 7(2, 17]$, $J_h \mapsto 5(2, 14]$; J_l mit kürzerer Belegungszeit



J_l (niedrige Priorität)

- t_0 startet
- t_1 belegt R_i
- t_4 setzt Ausführung fort
- $t_{5.5}$ gibt R_i frei $\mapsto J_m$
- $t_{11.5}$ setzt Ausführung fort
- $t_{16.5}$ beendet Ausführung

J_m (mittlere Priorität)


- t_2 startet, verdrängt J_l
- t_4 fordert R_i an, blockiert
- $t_{5.5}$ belegt R_i
- t_8 setzt Ausführung fort
- $t_{11.5}$ gibt R_i frei $\mapsto J_h$
- $t_{14.5}$ setzt Ausführung fort
- $t_{15.5}$ beendet Ausführung

J_h (hohe Priorität)

- t_6 startet, verdrängt J_m
- t_8 fordert R_i an, blockiert
- $t_{11.5}$ belegt R_i
- $t_{13.5}$ gibt R_i frei
- t_{14} **verletzt seinen Termin**
- $t_{14.5}$ beendet Ausführung

Anomalie im Laufzeitverhalten (Forts.)

Beispiel: $J_l \mapsto 7(0, 18]$, $J_m \mapsto 5(2, 17]$, $J_h \mapsto 5(2, 14]$; J_m fordert R_i nicht an



J_l (niedrige Priorität)

- t_0 startet
- t_1 belegt R_i
- t_4 setzt Ausführung fort
- t_{11} setzt Ausführung fort
- t_{13} gibt R_i frei $\mapsto J_h$
- t_{16} setzt Ausführung fort
- t_{17} beendet die Ausführung

J_m (mittlere Priorität)

- t_6 startet, verdrängt J_l
- t_{11} beendet die Ausführung

J_h (hohe Priorität)

- t_2 startet, verdrängt J_l
- t_4 fordert R_i an, blockiert
- t_{13} belegt R_i
- t_{14} **verletzt seinen Termin**
- t_{15} gibt R_i frei
- t_{16} beendet die Ausführung

Synchronisation *Considered Harmful*

Prioritätsorientierte Einplanung

Prioritätsumkehr (engl. *priority inversion*, S. 6-26), mögliches Phänomen abhängiger Tasks, vorausgesetzt zwei Bedingungen sind erfüllt:

notwendig ist, dass eine Task hoher Priorität auf eine Task niedriger Priorität wartet \mapsto **gegenseitiger Ausschluss**

hinreichend ist, dass die Task niedriger Priorität von einer oder mehrerer Tasks mittlerer Priorität verdrängt wird

▶ auch als **unkontrollierte Prioritätsumkehr** bezeichnet

Lösungsansätze sind, sofern blockierende Synchronisation in der jeweils gegebenen Situation nicht vermieden werden kann:

- ▶ Verdrängungssteuerung ☞ S. 7-13
- ▶ Prioritätsvererbung ☞ S. 7-18
- ▶ Prioritätsobergrenzen ☞ S. 7-22

Verdrängung zeitweise unterbinden

Verdrängungsfreie kritische Abschnitte (engl. *non-preemptive critical sections*, NPCS)

Arbeitsaufträge werden für die **Gesamtzeit der Belegung** von (unteilbaren) Betriebsmitteln nicht von anderen Arbeitsaufträgen verdrängt

- ▶ die Benutzung der Betriebsmittel kontrolliert ein **Monitor** [1, 2]
 - ▶ **kernelized monitor** [3]

Eintrittsprotokoll \mapsto Verdrängung abwehren

- ▶ ausgelöste Jobs einplanen, aber nicht einlasten

Austrittsprotokoll \mapsto Verdrängung wieder zulassen

- ▶ höher priorisierte Jobs (nachträglich) einlasten


- ▶ belegt ein Job ein Betriebsmittel, läuft er unverdrängbar weiter

- ▶ **verklemmungsfreies Verfahren** durch **Verklemmungsvorbeugung**
 - ▶ engl. *deadlock prevention*

☞ Taktsteuerung unterstützt unverdrängbare Ausführung rahmenweise

Kernelized Monitor

Beispiel (S. 7-11): $J_l \mapsto 7(0, 18]$, $J_m \mapsto 5(2, 17]$, $J_h \mapsto 5(2, 14]$



J_l (niedrige Priorität)

- t_0 startet
- t_1 belegt R_i unverdrängbar
- t_6 gibt R_i frei $\mapsto J_h$
- t_{16} setzt Ausführung fort
- t_{17} beendet die Ausführung

J_m (mittlere Priorität)

- t_6 wird ausgelöst
- t_{11} startet
- t_{16} beendet die Ausführung

J_h (hohe Priorität)

- t_2 wird ausgelöst
- t_6 startet
- t_8 belegt R_i unverdrängbar
- t_{10} gibt R_i frei
- t_{11} beendet die Ausführung

Blockierungszeit (1)

Feste obere Schranke

Verzögerungen nebenläufiger Arbeitsaufträge durch die Zugriffskontrolle sind **nach oben begrenzt**

- ▶ die feste obere Schranke bt bestimmt sich aus der größten WCET aller kritischen Abschnitte aller niedriger priorisierten Jobs: $\max(cs)$
- ▶ höher priorisierte Jobs werden schlimmstenfalls einmal durch einen niedriger priorisierten Job blockiert

NPCS verzögert eine periodische Task T_i von n periodischen Tasks im taktweisen Betrieb um $bt_i = \max(cs_k)$, für $i + 1 \leq k \leq n$:

fixed-priority bei Abarbeitung nach absteigender Priorität

dynamic-priority z.B. EDF: Jobs in T_i mit relativem Termin D_i können nur durch Jobs mit längeren relativen Terminen als D_i blockiert werden $\iff i < j$ wenn $D_i < D_j$

Pragmatischer Ansatz

Effektiv, bei vergleichsweise geringem Aufwand

Vorteil: erfordert kein *à priori* Wissen über Betriebsmittelanforderungen

- ▶ beugt unkontrollierter Prioritätsumkehr vor
 - ▶ J_h blockiert nur wenn bei Auslösung J_l bereits das Betriebsmittel hält
 - ▶ beendet J_l seinen kritischen Abschnitt, sind alle Betriebsmittel frei
 - ▶ Jobs geringerer Priorität als J_h können ihm diese nicht streitig machen
- ▶ beugt Verklemmung (engl. *deadlock*) vor, da Nachforderungen von Betriebsmitteln implizit unteilbar geschehen werden
 - ▶ eine notwendige Verklemmungsbedingung [4, VIII-60] wird entkräftet
 - ▶ genauer: der „*hold and wait*“ Fall kann nicht eintreten
- ▶ einfach zu implementieren; ein gutes Verfahren, wenn...
 - ▶ alle Belegungszeiten aller Betriebsmittel kurz sind
 - ▶ die meisten Jobs im Konflikt zueinander stehen

☞ eignet sich für Systeme mit fester und dynamischer Priorität

Pragmatischer Ansatz mit Schönheitsfehlern

Alternativen, sofern bestimmte Voraussetzungen gegeben sind

Nachteil: höher priorisierte Jobs können durch niedriger priorisierte Jobs blockiert werden, obwohl zwischen ihnen kein Konflikt besteht

- ▶ im Beispiel (S. 7-14) wird J_m durch J_l blockiert, obwohl beide Jobs nicht im gegenseitigen Ausschluss zueinander stehen

Verbesserungsmöglichkeiten...

- ▶ so Verklemmungen nicht auftreten können oder durch eine andere Technik vorgebeugt oder vermieden werden:
 - ▶ den ein Betriebsmittel haltenden Job für die restliche Belegungszeit ggf. auf die Priorität des jeweils anfordernden Jobs hochsetzen
 - ▶ er wird durch **Prioritätsvererbung** (S. 7-18) „beschleunigt“
- ▶ so Betriebsmittelanforderungen *à priori* bekannt sind:
 - ▶ der ein Betriebsmittel haltende Job läuft mit der höchsten Priorität aller Jobs, die das Betriebsmittel beanspruchen
 - ▶ das Betriebsmittel besitzt eine **Prioritätsobergrenze** (S. 7-22)

Priorität zeitweise erhöhen

Wechsel zwischen zugewiesene und aktuelle (geerbte) Priorität

Arbeitsaufträge werden für die **Restzeit der Belegung** von (unteilbaren) Betriebsmitteln durch andere Arbeitsaufträge höher priorisiert

- ▶ fordert ein Job ein gesperrtes Betriebsmittel an, vererbt er seine Priorität an den das Betriebsmittel haltenden Job
 - ▶ der anfordernde Job hat zu dem Zeitpunkt die höchste Priorität
 - ▶ er hat den das Betriebsmittel haltenden Job (indirekt) verdrängt
 - ▶ die Priorität des das Betriebsmittel haltenden Jobs wird erhöht
- ▶ gibt der Job das durch ihn gesperrte Betriebsmittel frei, nimmt er die ihm ursprünglich zugewiesene Priorität wieder an
 - ▶ der das Betriebsmittel freigebende Job wird ggf. sofort verdrängt
 - ▶ der auf die Freigabe wartende Job wird ggf. sofort eingelastet

Prioritätsumkehr wird nicht wirklich vermieden, jedoch entschärft:

- ▶ wie bei NPCS behalten niedriger priorisierte Jobs die CPU zuteil, obwohl höher priorisierte Jobs auf Zuteilung der CPU warten

Priority Inheritance

Beispiel (S. 7-11): $J_l \mapsto 7(0, 18]$, $J_m \mapsto 5(2, 17]$, $J_h \mapsto 5(2, 14]$



J_l (niedrige Priorität)

t_0 startet

t_1 belegt R_i

t_4 läuft mit Priorität J_h

t_8 gibt R_i frei $\mapsto J_h$

t_{16} läuft mit alter Priorität

t_{17} beendet die Ausführung

J_m (mittlere Priorität)

t_6 wird ausgelöst

t_{11} startet

t_{16} beendet die Ausführung

J_h (hohe Priorität)

t_2 startet

t_4 fordert R_i an $\mapsto J_l$

t_8 belegt R_i

t_{10} gibt R_i frei

t_{11} beendet die Ausführung

Transitive Blockierung

Nachforderung unteilbarer Betriebsmittel

Zugriffskontrolle durch Prioritätsvererbung bedeutet zunächst zweierlei:

- direkte Blockierung** eines höher priorisierten Jobs (J_h), der ein gesperrtes Betriebsmittel anfordert, das ein niedriger priorisierter Job (J_l) belegt
- Blockierung durch Vererbung** (engl. *inheritance blocking*) eines nicht im gegenseitigen Ausschluss befindlichen höher priorisierten Jobs (J_m)
 - ▶ der einen Job (J_l) gemäß dessen „Altpriorität“ verdrängen würde
 - ▶ dies jedoch wegen dessen aktuellen (geerbten) Priorität nicht kann

Blockierungen wirken ggf. transitiv: **geschachtelte kritische Abschnitte**

1. J_l startet zuerst, belegt R_1 und wird von J_m verdrängt
2. J_m belegt R_2 und wird von J_h verdrängt
3. J_h fordert R_2 an und vererbt seine Priorität an J_m
4. J_m läuft weiter, fordert R_1 an und vererbt „seine“ Priorität an J_l

Priorität zeitweise deckeln

Vorabwissen über Arbeitsaufträge und Betriebsmittel

Prioritätsobergrenze (engl. *priority ceiling*) eines Betriebsmittels R_i ist die höchste Priorität aller Arbeitsaufträge, die R_i benötigen

- ▶ die **aktuelle Prioritätsobergrenze** des Systems gleicht der höchsten Prioritätsobergrenze der zur Zeit belegten Betriebsmittel
 - ▶ $\hat{\Pi}(t)$, in Abhängigkeit vom betrachteten Zeitpunkt t
- ▶ ist kein unteilbares Betriebsmittel belegt, existiert die aktuelle Prioritätsobergrenze (theoretisch) nicht
 - ▶ sie ist dann niedriger als die niedrigste Priorität aller Jobs
- ▶ die jeweiligen Werte sind für alle Betriebsmittel im Voraus bekannt

Arbeitsaufträge können während ihrer Ausführung (d.h., bei Anforderung eines gesperrten Betriebsmittels) eine durch x begrenzte Priorität erben

- ▶ wenn sie ein Betriebsmittel mit Prioritätsobergrenze x benötigen

 Prioritätsobergrenzen sind eine Variante von Prioritätsvererbung

Blockierungszeit (2)

Feste obere Schranken, die kaskadenartig zur Wirkung kommen können

Arbeitsaufträge höherer Priorität werden nur einmal direkt blockiert, wenn die Nachforderung unteilbarer Betriebsmittel ausgeschlossen ist

- ▶ für die Dauer der WCET des äußersten kritischen Abschnitts

Situation des schlimmsten Falls: höher priorisierter Job benötigt $n > 1$ Betriebsmittel, steht mit $k > 1$ niedriger priorisierten Jobs im Konflikt

- ▶ der höher priorisierte Job kann $\min(n, k)$ -mal blockiert werden
- ▶ jeweils für die Dauer der WCET des äußersten kritischen Abschnitts

GAU: $n > 1$ Betriebsmittel; $k > 1$ Jobs; J_i Vorrang vor J_j , wenn $i < j$

1. J_k startet zuerst, belegt R_n ; J_{k-1} verdrängt J_k , belegt R_{n-1} ; ...
2. J_1 verdrängt J_2 , belegt R_1
3. J_0 verdrängt J_1 , fordert R_i an in der Reihenfolge $i = 1, 2, 3, \dots, n$

Betriebsmittelvergabe und Prioritätsvererbung

Vorabwissen über Arbeitsaufträge und Betriebsmittel

Vergabe von Betriebsmittel R zum Zeitpunkt t an Arbeitsauftrag J hängt ab vom Zustand von R und von der aktuellen Priorität $\pi(t)$ von J :

belegt $\mapsto R$ ist gesperrt, J blockiert

frei $\mapsto R$ wird J zugeteilt und gesperrt, falls. . .

1. $\pi(t) > \hat{\Pi}(t)$: J hat die aktuell höchste Priorität
2. $\pi(t) \leq \hat{\Pi}(t)$: J ist ein Job, der zum Zeitpunkt t mindestens ein Betriebsmittel mit Prioritätsobergrenze $\hat{\Pi}(t)$ hält
 - ▶ anderenfalls bleibt R frei und J blockiert (S. 7-24)

Prioritätsvererbung findet (auch hier) nur statt, wenn J suspendiert wird:

- ▶ J_l , der J blockiert, erbt die aktuelle Priorität $\pi(t)$ von J
- ▶ J_l behält diese Priorität, bis er alle Betriebsmittel freigibt, deren Prioritätsobergrenze größer oder gleich $\pi(t)$ ist
 - ▶ er nimmt dann Priorität $\pi(t')$ an, die er zum Zeitpunkt $t' < t$ hatte
 - ▶ d.h., als ihm die freigegebenen Betriebsmittel zugeteilt wurden

Verklemmungsvorbeugung

Entkräftung der hinreichenden Bedingung [4, VIII-60]: zirkulares Warten

Betriebsmittelvergabe kontrolliert durch Prioritätsobergrenzen ist weniger „gefäßig“ (engl. *greedy*), als bloße Prioritätsvererbung

- ▶ die Anforderung von J kann zurückgewiesen werden, obwohl das angeforderte Betriebsmittel R frei ist
- ▶ dies ist der Fall, wenn die durch die Menge von Prioritätsobergrenzen definierte (ansteigende) **lineare Ordnung** verletzt werden sollte
 - ▶ $\pi(t) \leq \hat{\Pi}(t)$ trifft zu und J hält kein Betriebsmittel mit $\hat{\Pi}(t)$
 - ▶ d.h., die direkte/indirekte Priorität von J durchbricht die Ordnung
- ▶ alle Betriebsmittel des Systems sind linear geordnet aufgestellt

Blockierung durch Prioritätsobergrenzen wird auch als **Aufhebungssperre** (engl. *avoidance blocking*) bezeichnet

- ▶ da implizit Kosten anfallen, um auch Verklemmungen vorzubeugen

Blockierungszeit (3)

Feste obere Schranke

Zugriffskontrolle durch Prioritätsobergrenzen impliziert drei Arten der Blockierung nebenläufiger Arbeitsaufträge:


1. direkte Blockierung,
 2. Blockierung durch Vererbung,
 3. Blockierung durch Aufhebungssperre
- } **Prioritätsvererbung**

Effekt von 3. ist, dass jeder Arbeitsauftrag höchstens einmal blockiert und dass eine Blockierung nicht transitiv ist [5]

- ▶ die Blockierungszeit ist begrenzt durch die größte WCET aller kritischen Abschnitte aller niedriger priorisierten Jobs
- ▶ unabhängig von der Anzahl der im Konflikt stehenden Jobs
 - (a) wenn ein Job blockiert, dann nur durch höchstens einen Job
 - (b) ein Job, der einen anderen blockiert, wird selbst von keinem anderen blockiert

Priority Ceiling

Jobs blockieren nicht transitiv und höchstens einmal im Konfliktfall



J_l (niedrige Priorität)	J_m (mittlere Priorität)	J_h (hohe Priorität)
t_0 startet	t_2 verdrängt J_l	t_5 verdrängt J_m
t_1 belegt $R_x \rightsquigarrow \hat{\Pi}(t_1)$	t_3 belegt R_y , $\pi_m > \hat{\Pi}(t_1)$	t_6 blockiert

- ▶ direkte Blockierung von J_h durch J_l ist nicht möglich: (a) sonst wäre $\hat{\Pi}(t_3)$ wenigstens π_h und (b) J_m könnte R_y überhaupt nicht belegen
- ▶ werden alle ab t_2 angeforderten Betriebsmittel zum Zeitpunkt t_6 nur von J_m belegt, kann J_h nur durch J_m blockiert werden
- ▶ würde ein Job J_k bei t_4 Betriebsmittel R_z belegen, wäre J_h aus demselben Grund nicht mehr durch J_m blockierbar, wie J_h nicht durch J_l blockierbar ist

Bestimmung von Blockierungszeiten

Betriebsmittelanforderungsgraph (engl. *resource requirement graph*)

Ansatz zur Bestimmung von Blockierungszeiten ist ein **Wartegraph**, der Jobs mit Betriebsmitteln und umgekehrt in Verbindung bringt¹

Knoten repräsentieren Jobs bzw. Betriebsmittel, annotiert mit einem Namen und der Betriebsmittellanzahl (nur Betriebsmittelknoten)

Kanten drücken „wartet auf“- bzw. „belegt von“-Beziehungen aus und sind mit einem 2-Tupel (n, t) annotiert

- ▶ Betriebsmittellanzahl n , Belegungszeit t

- ▶ Pfade zwischen Jobknoten führen immer über Betriebsmittelknoten
 - ▶ J_x belegt n Einheiten R_i für t Zeiten, worauf J_y wartet
 - ▶ führt ein Pfad von J_h zu J_l , ist J_h durch J_l direkt blockiert
- ▶ Zyklen im Wartegraph zeigen **Verklemmungen** an \rightsquigarrow „Abfallprodukt“ **Verklemmungserkennung** (engl. *deadlock detection*) beim Entwurf
 - ▶ Verklemmungsvorbeugung als Zusicherung (engl. *assertion*)

¹Wenn Verklemmungserkennung gleich mit erledigt werden soll. Ansonsten reicht es, den längsten kritischen Abschnitt aller niedrigeren Tasks zu finden.

Vereinfachung durch Stapelorientierung

Stapelbezogene Einplanung (engl. *stack-based scheduling*)

Ausgangspunkt ist die **stapelorientierte Einplanung von Prozessen**, so dass N Prozesse einen Stapel gemeinsam nutzen können [6, 7]

- ▶ nicht immer ist es möglich, jeden Job durch einen eigenen Faden zu repräsentieren bzw. mit einem eigenen Stapel zu versehen
 - ▶ wenn die Jobanzahl zu hoch und/oder der Speicherplatz zu gering ist
- ▶ gemeinsame Nutzung desselben Stapels setzt voraus, dass kein Job bei Anforderung eines gemeinsamen Betriebsmittels blockiert
 - ▶ sonst droht die Überschreitung der Stapelbereiche anderer Jobs
- ▶ die **Jobs dürfen ihre Ausführung niemals selbst aussetzen**, sie dürfen jedoch von höher priorisierten Jobs verdrängt werden
 - ▶ oben auf dem Stapel läuft immer der Job mit der höchsten Priorität
 - ▶ die logische Konsequenz, wenn Selbstausschaltung ausgeschlossen ist

☞ **stapelbezogene Prioritätsbergrenzen** (*stack-based priority ceiling*)

Stapelbezogene Grenzprioritäten

Regeln

1. Aktualisierung der **Grenzpriorität** (*ceiling priority*, S. 7-22) $\hat{\Pi}(t)$
 - ▶ erfolgt mit jeder Vergabe/Freigabe von Betriebsmitteln
 - ▶ sind alle Betriebsmittel frei, gibt es keine Grenzpriorität
2. Einplanung und Einlastung von Jobs
 - ▶ nach erfolgter Auslösung muss ein Job ggf. solange warten, bis die ihm zugewiesene Priorität die Grenzpriorität übersteigt
 - ▶ Jobs werden jeweils entsprechend ihrer zugewiesenen Priorität und verdrängend ausgeführt
3. Zuteilung eines Betriebsmittels
 - ▶ erfolgt sofort, wann immer ein Job das Betriebsmittel anfordert

Jobs blockieren nicht, indem ihnen die Betriebsmittelzuteilung nach Ausführungsbeginn verweigert werden würde

- ▶ im Gegensatz zum Grundmodell von Prioritätsbergrenzen (S. 7-23)

Stapelbezogene Grenzprioritäten (Forts.)

Implikationen

Verklebungen nebenläufig ausgeführter Arbeitsaufträge sind durch eine **indirekte Methode zur Verklebungsvorbeugung**² ausgeschlossen

- (a) beginnt ein Job seine Ausführung, sind alle von ihm im weiteren Verlauf benötigten Betriebsmittel frei
 - ▶ sonst wäre die Grenzpriorität größer oder gleich seiner Priorität
 - ▶ in dem Fall wäre jedoch die Einlastung des Jobs verzögert worden
- (b) bei Verdrängung eines Jobs sind alle von ihm benötigten Betriebsmittel (noch oder bereits wieder) frei
 - ▶ sonst hätte die Grenzpriorität eine Verdrängung unterbunden
 - ▶ der verdrängende Job wird also immer komplett durchlaufen können
- (c) auf ein benötigtes Betriebsmittel kann direkt zugegriffen werden

²zirkulares Warten wird vorgebeugt (siehe auch S. 7-24)

Grundmodell und Stapelorientierung

Feste vs. dynamische Priorität (vergleiche S. 6-6)

feste Priorität \mapsto einfach, wegen *à priori* Wissen

dynamische Priorität \mapsto Prioritäten periodischer Aufgaben ändern sich, während die von ihnen beanspruchten Betriebsmittel konstant bleiben:

- ▶ **Grenzprioritäten der Betriebsmittel ändern sich mit der Zeit**
- ▶ Aktualisierung der Grenzprioritäten bei jeder Auslösung eines Jobs
 1. dem ausgelösten Job zum Ereigniszeitpunkt eine Priorität zuweisen
 - ▶ relativ zu den anderen bereits eingepflanzten/laufbereiten Jobs
 - ▶ (dynamische) prioritätsorientierte Einplanung je nach Verfahren
 2. Grenzprioritäten aller Betriebsmittel aktualisieren
 - ▶ auf Basis der neuen Taskprioritäten
 3. Grenzpriorität des Systems aktualisieren
 - ▶ auf Basis der neuen Grenzprioritäten der Betriebsmittel
- ▶ für, auf Jobebene, statische oder dynamische Prioritäten (S. 6-7)

Resümee

Konkurrenz und Koordination nebenläufiger Aktivitäten

- ▶ Nebenläufigkeit, Kausalität, Kausalordnung
- ▶ Konfliktsituationen \leadsto **synchronisieren ohne Prioritätsumkehr**

Verdrängungssteuerung \mapsto verdrängungsfreie kritische Abschnitte

- ▶ benötigt kein *à priori* Wissen; Verklemmungsvorbeugung
- ▶ pragmatisch/effektiv, beeinträchtigt unabhängige Jobs

Prioritätsvererbung \mapsto Priorität zeitweise erhöhen

- ▶ benötigt kein *à priori* Wissen
- ▶ direkte Blockierung, Blockierung durch Vererbung; transitiv

Prioritätsobergrenzen \mapsto Priorität zeitweise deckeln

- ▶ benötigt *à priori* Wissen; Verklemmungsvorbeugung
- ▶ Grundmodell vs. (einfachere) stapelorientierte Variante

Literaturverzeichnis

- [1] Per Brinch Hansen.
Operating System Principles.
Prentice Hall International, 1973.
- [2] Charles Antony Richard Hoare.
Monitors: An operating system structuring concept.
Communications of the ACM, 17(10):549–557, October 1974.
- [3] Aloysius K.-L. Mok.
Fundamental Design Problems of Distributed Systems for Hard Real-Time Environments.
PhD thesis, Massachusetts Institute of Technology, MIT, Cambridge, MA, USA, May 1983.
Technical Report MIT/LCS/TR-297.

Literaturverzeichnis (Forts.)

- [4] Wolfgang Schröder-Preikschat.
Softwaresysteme 1.
www4.informatik.uni-erlangen.de/Lehre/SS07/V_S0S1, 2007.
Lecture Notes.
- [5] Lui Sha, Ragunathan Rajkumar, and John P. Lehoczky.
Priority inheritance protocols: An approach to real-time synchronization.
IEEE Transactions on Computers, 39(9):1175–1185, September 1990.
- [6] Theodore P. Baker.
A stack-based resource allocation policy for real-time processes.
In *Proceedings of the 11th IEEE Real-Time Systems Symposium (RTSS '90)*, pages 191–200, Lake Buena Vista, FL, USA, December 5–7, 1990. IEEE.

Literaturverzeichnis (Forts.)

- [7] Theodore P. Baker.
Stack-based scheduling of realtime processes.
Real-Time Systems, 3(1):67–99, 1991.