Echtzeitsysteme

Physikalisches System ⟷ Kontrollierendes Rechensystem

Peter Wägemann

Lehrstuhl für Verteilte Systeme und Betriebssysteme

Friedrich-Alexander-Universität Erlangen-Nürnberg

`https://sys.cs.fau.de/lehre/ss22/ezs/`

3. Mai 2022

Fragestellungen

⚠ Echtzeitbetrieb bedeutet Rechtzeitigkeit (vgl. Folie II/11 ff)
- Die funktionale Korrektheit ist nicht ausreichend

→ Zeitliche (temporale) Korrektheit!

⚠ Geschwindigkeit ist keine Garantie
- Komplexität des Echtzeitrechensystems

→ Entscheidend ist das tatsächliche Laufzeitverhalten

⚠ Terminvorgaben sind anwendungsabhängig
- Komplexität des physikalischen Systems (vgl. Folie II/20 ff)

→ Bestimmt durch die Kopplung an die (reale) Umwelt

☞ Woher kommen die zeitlichen Vorgaben und Eigenschaften?
- Wo sind die Berührungspunkte mit dem physikalischen System?
- Welche Rolle spielt das Echtzeitrechensystem?

Exkurs: Funktionale und nicht-funktionale Eigenschaften

- Funktionale Eigenschaften
  - Werden direkt implementiert

Eine Funktion

```
uint16_t regelschritt(uint8_t sensorwert)
```

- Nicht-funktionale Eigenschaften
  - Beispielsweise Energie, Speicherverbrauch, Laufzeitverhalten
  - Lassen sich nicht direkt implementieren
  - Sind querschneidend ⇝ erst im konkreten Kontext bestimmt

⚠ Zeit aus Sicht des Softwareengineering nicht-funktional
- Führt häufig zu Verwirrung im Kontext von Echtzeitsystemen

→ Die rechtzeitige Auslösung des Airbags ist funktional?!

☞ Es kommt auf die Betrachtungsebene an!

Gliederung

1 Physikalisches System und Echtzeitanwendung
- Kontrolliertes Objekt
- Zusammenspiel

2 Echtzeitrechensystem
- Grundlagen: Programmunterbrechungen
- Ausnahmebehandlung
- Zustandssicherung
- Ableitung des Zeitbedarfs

3 Zusammenfassung

Aufbau des Demonstrators

Eine elementare Kontrollschleife: Die Fluglageregelung

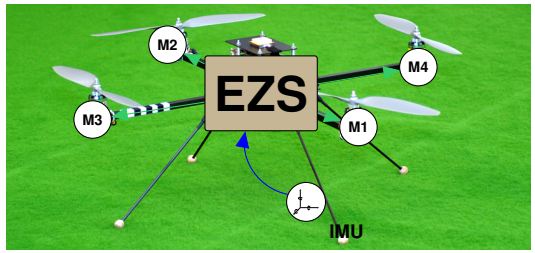

⚠ Quadrokopter sind inhärent instabil ⇝ ständige, aktive Kontrolle

- Aufgabe des Echtzeitsystems: Fluglageregelung (Stabilisierung)
  - Bewegung im Raum bestimmen (engl. ***i**nertial **m**easurement **u**nit*)
  - Vorgabe der Motor- und damit der Rotordrehzahl

☞ Physikalisches Objekt, Echtzeit-Anwendung und -Rechensystem

Kontrolle und Regelung des physikalischen Objekts

Übertragungsfunktion und Antwortfunktion

- Lage im Raum wird durch Änderung der Rotordrehzahl des Quadrokopter beeinflusst, bis Gleichgewicht zwischen Ist- und Sollzustand

⚠ Wie lange dauert es bis zum Gleichgewicht?

- Gewicht, Leistungsfähigkeit der Motoren, Bauart der Rotorblätter, . . .

→ Objektdynamik und -physik

☞ Dies ist die Welt der Steuerungs- und Regelungsanwendungen

- Regelungstechnische Abstraktion des Quadrokopters: Dynamisches System welches Eingangs- in Ausgangssignale überführt
- Ziel ist die mathematische Beschreibung des Systemverhaltens mittels einer Übertragungsfunktion (engl. *transfer function*)

→ Reaktion kann errechnet und gezielt beeinflusst werden

Zeitparameter des physikalischen Objekts

Die Physik kommt ins Spiel . . . [3, Kapitel 1.3]

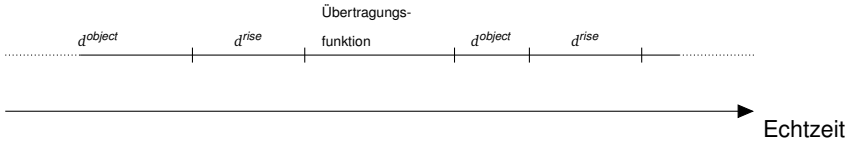

☞ Zeitverzögerung (d, delay) des Quadrokopters:

d^{object} Zeitdauer bis zum Beginn der Lageänderung

- Hervorgerufen durch die (initiale) Trägheit des Objektes

→ Prozessverzögerung (engl. *process/object delay*)

d^{rise} Zeitdauer bis zum (erneuten) Gleichgewicht

- Allgemein: Erreichen der Zielgröße (typ. 66 % bzw. 90 %)
- Bestimmt durch die Fähigkeit der Aktorik ↦ Einschwingverhalten

→ Anregel-/ Anlaufzeit (engl. *rise time*) einer Sprungantwort

Zeitparameter des Rechensystems

Berechnung der Übertragungsfunktion: Alles braucht seine Zeit

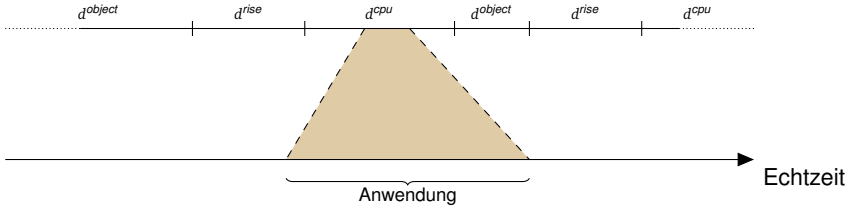

☞ Zeitverzögerung des Rechensystems

→ Auswertung: Abweichung (Soll/Ist) und Übertragungsfunktion (Regler)

⚠ Das Rechensystem benötigt Zeit für die Berechnung

d^{cpu} Zeitdauer bis zur Ausgabe des neuen Stellwertes

- Erfassung der Umgebung durch Sensoren
- Berechnung des Regelungsalgorithmus
- Kontrollieren des Objekts durch Aktorik

Schwankungen (engl. *jitter*) in den Zeitparametern

Der komplexe Einfluss des Echtzeitrechensystems

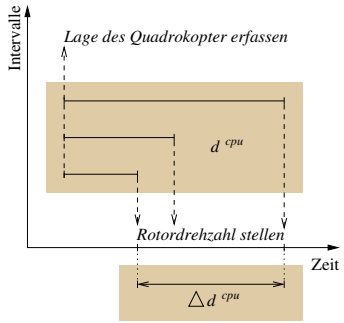

d^{cpu} Auch bei konstantem Rechenaufwand zur Stellwertbestimmung variabel

- Verdrängende Einplanung
- Überlappende Ein-/Ausgabe
- Programmunterbrechungen
- Busüberlastung, DMA

Δd^{cpu} Fügt Unschärfe zum Zeitpunkt der Lagebestimmung hinzu

- Bewirkt zusätzlichen Fehler
- Beeinträchtigt die Dienstgüte

⚠ Unbekannte variable Verzögerungen (engl. *jitter*) schwer kompensierbar

- Bekannte konstante Verzögerungen schon $\rightsquigarrow d^{dead}$
- Randbedingung: $\Delta d^{cpu} \ll d^{cpu}$

Physikalisches Objekt ⟷ Echtzeitrechensystem

☞ Zeitverzögerung des Regelkreises: Totzeit (engl. *dead time*)

- Entsteht aus dem Zusammenspiel zwischen Objekt und Rechensystem

d^{dead} Zeitintervall zwischen Berechnungsbeginn und Wahrnehmung einer Reaktion nach erfolgter Steuerung

- setzt sich zusammen aus d^{cpu} und d^{object}:

1. Implementierung des kontrollierenden Rechensystems
2. Dynamik des kontrollierten Objektes

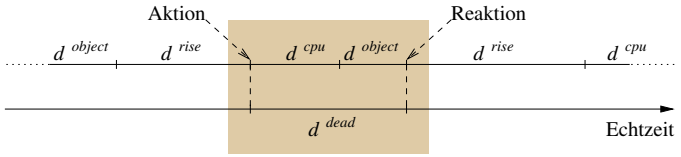

⚠ Auswirkung Güte und Stabilität der Regelung

- Insbesondere bei hoher Varianz von $\Delta d^{dead} \mapsto$ Jitter

→ Beeinflusst Aussagekraft über die erzielte Wirkung

Gliederung

1 Physikalisches System und Echtzeitanwendung
- Kontrolliertes Objekt
- Zusammenspiel

2 Echtzeitrechensystem
- Grundlagen: Programmunterbrechungen
- Ausnahmebehandlung
- Zustandssicherung
- Ableitung des Zeitbedarfs

3 Zusammenfassung

Zeitliches Verhalten von Echtzeitanwendungen

Allgemeine Kosten des Echtzeitrechensystems

- Welche Elemente müssen betrachtet werden?
  - Beschränkung auf die Echtzeitanwendung (Regelung)?
  - Vernachlässigung des Echtzeitbetriebssystem?
  - Wie stark hängt dies vom verwendeten Prozessor ab?
- Auf welcher Ebene muss die Betrachtung durchgeführt werden?
  - Genügt es eine hohe Abstraktionsebene heranzuziehen?
  - Wo entscheidet sich das zeitliche Ablaufverhalten?

⚠ Verwaltungsgemeinkosten (engl. *overheads*) der Laufzeitumgebung

☞ Exemplarische Illustration anhand von Programmunterbrechungen

Unterbrechungsarten

☞ Zwei Arten von Programmunterbrechungen:

synchron die „Falle“ (engl. *trap*)
asynchron die „Unterbrechung“ (engl. *interrupt*)

- Unterschiede ergeben sich hinsichtlich:
  - Quelle
  - Synchronität
  - Vorhersagbarkeit
  - Reproduzierbarbeit

⚠ Behandlung ist zwingend und grundsätzlich prozessorabhängig

Wiederholung/Vertiefung empfohlen. . .

Unterbrechungen siehe auch Vorlesung „Betriebssysteme“ [4, Kapitel 2-3]

Synchrone Programmunterbrechung (engl. *trap*)

☞ Ursachen einer synchronen Programmunterbrechung:

- Unbekannter Befehl, falsche Adressierungsart oder Rechenoperation
- Systemaufruf, Adressraumverletzung, unbekanntes Gerät

Trap ↦ synchron, vorhersagbar, reproduzierbar

- Abhängig vom Arbeitszustand des laufenden Programms:
  - Unverändertes Programm, mit den selben Eingabedaten versorgt
  - Auf ein und dem selben Prozessor zur Ausführung gebracht

→ Unterbrechungsstelle im Programm ist vorhersehbar

⚠ Programmunterbrechung/-verzögerung ist deterministisch

Asynchrone Programmunterbrechung (engl. *interrupt*)

☞ Ursachen einer asynchronen Programmunterbrechung:

- Signalisierung „externer“ Ereignisse
- Beendigung einer DMA- bzw. E/A-Operation

Interrupt ↦ asynchron, unvorhersagbar, nicht reproduzierbar

- Unabhängig vom Arbeitszustand des laufenden Programms:
  - Hervorgerufen durch einen „externen Prozess“ (z.B. ein Gerät)
  - Signalisierung eines Ereignis

→ Unterbrechungsstelle im Programm ist nicht vorhersehbar

⚠ Programmunterbrechung/-verzögerung ist nicht deterministisch

Ausnahmesituationen (engl. *exception*) – Beispiele

- Ereignisse, oftmals unerwünscht aber nicht immer eintretend:
  - Signale von der Peripherie (z.B. E/A, Zeitgeber oder „Wachhund“)
  - Wechsel der Schutzdomäne (z.B. Systemaufruf)
  - Programmierfehler (z.B. ungültige Adresse)
  - unerfüllbare Speicheranforderung (z.B. bei Rekursion)
  - Einlagerung auf Anforderung (z.B. beim Seitenfehler)
  - Warnsignale von der Hardware (z.B. Energiemangel)

- Ereignisbehandlung, die problemspezifisch zu gewährleisten ist:
  - Ausnahme während der „normalen“ Programmausführung

Ausnahmebehandlung (engl. *exception handling*)

Abrupter Zustandswechsel

⚠ Programmunterbrechungen implizieren nicht-lokale Sprünge:

- vom { unterbrochenen / behandelnden } zum { behandelnden / unterbrochenen } Programm

☞ Sprünge (und Rückkehr davon) ziehen Kontextwechsel nach sich:

- Maßnahmen zur Zustandssicherung/-wiederherstellung erforderlich
- Mechanismen dazu liefern das behandelnde Programm selbst
  - bzw. eine tiefer liegende Systemebene (Betriebssystem, CPU)

⚠ Prozessorstatus unterbrochener Programme muss invariant sein

Zustandssicherung

Prozessorstatus invariant halten

Hardware (CPU) sichert einen Zustand minimaler Größe[1]

- Statusregister (SR)
- Befehlszeiger (engl. *program counter*, PC)

Software (Betriebssystem/Kompilierer) sichert den Rest

- alle { dann noch ungesicherten / flüchtigen / im weiteren Verlauf verwendeten } CPU-Register

⚠ Abhängig von der CPU werden wenige bis sehr viele Daten(bytes) bewegt

⇝ Zeitbedarf!

[1] Möglicherweise aber auch den kompletten Registersatz.

Prozessorstatus sichern und wiederherstellen

Unabhängigkeit von der Sprachebene der Behandlungsprozedur

- Sichern aller ungesicherten Register auf Befehlssatz-Ebene:

Zeile	x86	m68k
1:	`train:`	`train:`
2:	`  pushal`	`  moveml d0-d7/a0-a6,a7@-`
3:	`  call handler`	`  jsr handler`
4:	`  popal`	`  moveml a7@+,d0-d7/a0-a6`
5:	`  iret`	`  rte`

- `train` (trap/interrupt):
  - Arbeitsregisterinhalte im RAM sichern (2) und wiederherstellen (4)
  - Unterbrechungsbehandlung durchführen (3)
  - Ausführung des unterbrochenen Programms wieder aufnehmen (5)

Prozessorstatus sichern und wiederherstellen (Forts.)

Abhängigkeit von den Eigenschaften des Kompilierers

- Kontextsicherung durch Instrumentierung des Compilers:

gcc

```
void __attribute__ ((interrupt)) train () {
    handler();
}
```

- `__attribute__ ((interrupt))`
  - Generierung der speziellen Maschinenbefehle durch den Kompilierer
    - Sicherung/Wiederherstellung der Arbeitsregisterinhalte
    - Wiederaufnahme der Programmausführung
  - Nicht jeder „Prozessor“ (für C/C++) implementiert dieses Attribut

Aktivierungsblock (engl. *activation record*)

Sicherung/Wiederherstellung nicht-flüchtiger Register (engl. *non-volatile register*)

Türme von Hanoi

```
void hanoi (int n, char from, char to, char via) {
    if (n > 0) {
        hanoi(n - 1, from, via, to);
        printf("schleppe Scheibe %u von %c nach %c\n", n, from, to);
        hanoi(n - 1, via,  to,  from);
    }
}
```

Aufwand je nach CPU, Prozedur, Kompilierer: `gcc -O6 -S hanoi.c`

`hanoi()`-Eintritt

```
pushl %ebp
movl  %esp,%ebp
pushl %edi
pushl %esi
pushl %ebx
subl  $12,%esp
```

`hanoi()`-Austritt

```
leal  -12(%ebp),%esp
popl  %ebx
popl  %esi
popl  %edi
popl  %ebp
ret
```

Für eine Prozedur aufrufende Ebene inhaltsinvariante Register der CPU, deren Inhalte jedoch innerhalb einer aufgerufenen Prozedur verändert werden:

gcc/x86 ∼ `ebp`, `edi`, `esi`, `ebx`

Verwaltungsgemeinkosten des schlimmsten Falls

(engl. ***w**orst-**c**ase **a**dministrative **o**verhead*, WCAO)

- Latenz bis zum Start der Unterbrechungsbehandlung:
  1. Annahme der Unterbrechung durch die Hardware
  2. Sicherung der Inhalte der (flüchtigen) CPU-Register
  3. Aufbau des Aktivierungsblocks der Behandlungsprozedur
- Latenz bis zur Fortführung des unterbrochenen Programms:
  4. Abbau des Aktivierungsblocks der Behandlungsprozedur
  5. Wiederherstellung der Inhalte der (flüchtigen) CPU-Register
  6. Beendigung der Unterbrechung

⚠ Zeitpunkte und Häufigkeit der Gemeinkosten sind i. A. unbestimmbar

Verwaltungsgemeinkosten des schlimmsten Falls (Forts.)

Speicherplatz vs. Laufzeit

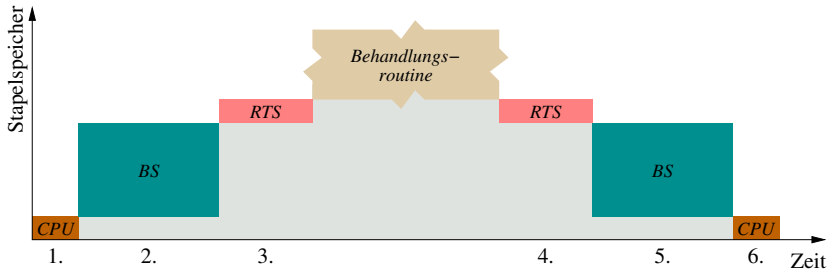

⚠ Werte mit fester oberer Schranke sind gefordert:

- Prozessor respektive Rechensystem (z.B. ADCs)
- Echtzeitbetriebssystem (engl. *real-time operating system*, RTOS)
- Echtzeitanwendung (Behandlungsroutine)

Zeitbedarf im Echtzeitrechensystem

Welche Komponenten benötigen wie viel Zeit?

⚠ Häufig ist eine eigenständige Beurteilung des Zeitbedarfs nicht möglich

☞ Herstellerangaben ermöglichen die Abschätzung des schlimmsten Falls

- Beispiel Quadrokopter:
  - d^{imu} Gyroskop ITG-3200 – Abtastrate: 4 Hz – 8 kHz [1]
  - d^{adc} Infineon TriCore ADC: 280 ns – 2,5 μs @ 10 Bit [2]
  - d^{irq} Infineon TriCore Arbitrierung: 5 - 11 Takte @ 150 MHz [2]
  - d^{OS} CiAO OS Fadenwechsel: $\leq$ 219 Takte @ TriCore (50 MHz) [5]

⚠ Alleine die Anwendung kann (fast) komplett kontrolliert werden[2]

[2] Lässt man zugelieferte Bibliotheksfunktionen oder zugekaufte Codegeneratoren außer Acht.

Abbildung der Fluglageregelung

Ein paar Daumenregeln

- Die Lage des Quadrokopter wird zyklisch abgetastet, um Abweichungen der aktuellen Lage vom Gleichgewicht zu erkennen:

$d^{control}$ Zeitabstand (konstant) zwischen zwei Regelschritten
- Faustregel: $d^{sample} < (d^{rise}/10)$

→ Quasi-kontinuierliches Verhalten des diskreten Systems

f^{sample} Abtastfrequenz, entspricht $1/d^{sample}$
- Analoge auf digitale Werte abbilden ⇝ A/D-Wandlung

→ Nyquist-Shannon-Abtasttheorem

The Big Picture – Rechenzeitbedarf

Aus welchen Komponenten setzt sich d^{cpu} zusammen?

☞ Ein Echtzeitsystem setzt sich aus verschiedenen Hardware, Sensoren, Peripherie-Elementen, Echtzeitbetriebssystem und Softwarekomponenten zusammen.

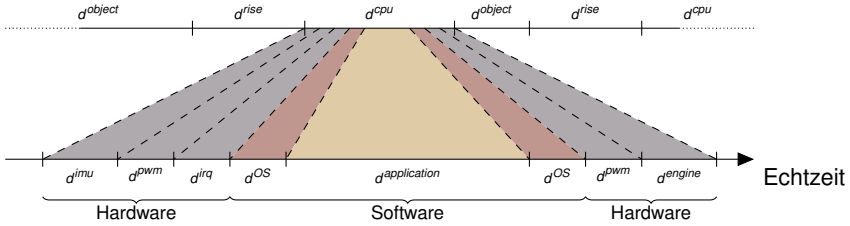

⚠ Alle Komponenten müssen bedacht werden!

Sensoren/Aktoren	Abtastrate (⇝ d^{imu}), Motorleistung (⇝ d^{engine})
Mikrocontroller	Signalverarbeitung (⇝ d^{pwm}), IRQ (⇝ d^{irq})
Betriebssystem	Unterbrechungslatenz, Kontextwechsel (⇝ d^{OS})
Anwendung	Steuerung, Regelung (⇝ $d^{application}$)

Gliederung

1 Physikalisches System und Echtzeitanwendung
- Kontrolliertes Objekt
- Zusammenspiel

2 Echtzeitrechensystem
- Grundlagen: Programmunterbrechungen
- Ausnahmebehandlung
- Zustandssicherung
- Ableitung des Zeitbedarfs

3 Zusammenfassung

Resümee

Zusammenspiel kontrolliertes Objekt ⟷ kontrollierendes Rechensystem
- Die Objektdynamik definiert den zeitlichen Rahmen durch Termine
- Die Echtzeitanwendung muss diese Termine einhalten

Programmunterbrechung in synchroner oder asynchroner Ausprägung
- Beeinflussen den Ablauf der Echtzeitanwendung
- Zustandssicherung, Verwaltungsgemeinkosten des schlimmsten Falls

Literaturverzeichnis

[1] Inc., I. :
ITG-3200 Product Specification Revision 1.4.
http://invensense.com/mems/gyro/documents/PS-ITG-3200A.pdf, 2010. –
Data Sheet

[2] Infineon Technologies AG (Hrsg.):
TC1796 User's Manual (V2.0).
St.-Martin-Str. 53, 81669 München, Germany: Infineon Technologies AG, Jul. 2007

[3] Kopetz, H. :
Real-Time Systems: Design Principles for Distributed Embedded Applications.
First Edition.
Kluwer Academic Publishers, 1997. –
ISBN 0–7923–9894–7

[4] Lohmann, D. :
Vorlesung: Betriebssysteme, Friedrich-Alexander-Universität Erlangen-Nürnberg.
https://www4.cs.fau.de/Lehre/WS15/V_BS, 2015

[5] Lohmann, D. ; Hofer, W. ; Schröder-Preikschat, W. ; Streicher, J. ; Spinczyk, O. :
CiAO: An Aspect-Oriented Operating-System Family for Resource-Constrained Embedded Systems.
In: *Proceedings of the 2009 USENIX Annual Technical Conference*.
Berkeley, CA, USA : USENIX Association, Jun. 2009. –
ISBN 978–1–931971–68–3, S. 215–228

Literaturverzeichnis (Forts.)

EZS – Cheat Sheet

Typographische Konvention

Der erste Index gibt die Aufgabe an (z. B. D_i), der Zweite (optional) bezieht sich auf den Arbeitsauftrag (z. B. $d_{i,j}$). Exponenten zeigen verschiedene Varianten einer Eigenschaft an (z. B. T^{HI},T^{MED}, T^{LO}). Funktionen beschreiben zeitlich variierende Eigenschaften (z. B. $P(t)$).

Eigenschaften

t (Real-)Zeit
d Zeitverzögerung (engl. delay)