Echtzeitsysteme

Zeitliche Analyse von Echtzeitanwendungen

Peter Ulbrich

Lehrstuhl für Verteilte Systeme und Betriebssysteme

Friedrich-Alexander-Universität Erlangen-Nürnberg

`https://www4.cs.fau.de`

13. November 2017

Die **maximale** Ausführungszeit

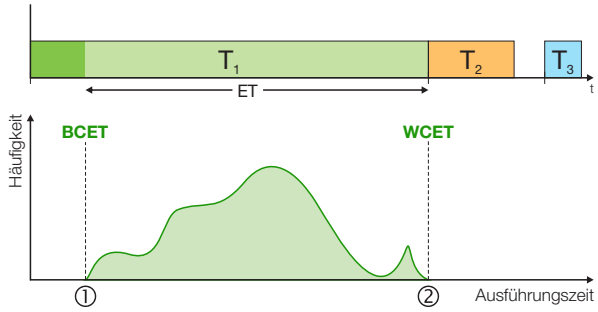

- Alle sprechen von der maximalen Ausführungszeit
  - Worst-Case Execution Time (WCET) e_i (vgl. III-2/26)

  → Unabdingbares Maß für zulässigen Ablaufplan (vgl. III-2/31)
- Tatsächliche Ausführungszeit bewegt sich zwischen:
  1. Bestmöglicher Ausführungszeit (Best-Case Execution Time, BCET)
  2. Schlechtest möglicher Ausführungszeit (besagter WCET)

Gliederung

Bestimmung der WCET – eine Herausforderung

Wovon hängt die maximale Ausführungszeit ab?

Beispiel: Bubblesort

```
void bubbleSort(int a[],int size) {
  int i,j;

  for(i = size - 1; i > 0; --i) {
    for (j = 0; j < i; ++j) {
      if(a[j] > a[j+1]) {
        swap(&a[j],&a[j+1]);
      }
    }
  }
  return;
}
```

Programmiersprachenebene:

- Anzahl der Schleifendurchläufe hängt von der Größe des Feldes `a[]` ab
- Anzahl der Vertauschungen `swap()` hängt von dessen Inhalt

⚠ Exakte Vorhersage ist kaum möglich
- Größe und Inhalt von `a[]` kann zur Laufzeit variieren

→ Welches ist der längste Pfad?

Maschinenprogrammebene:

- Ausführungsdauer der Elementaroperationen (`ADD`, `LOAD`, ...)

⚠ Prozessorabhängig und für moderne Prozessoren sehr schwierig
- Cache ⇝ Liegt die Instruktion/das Datum im schnellen Cache?
- Pipeline ⇝ Wie ist der Zustand der Pipeline an einer Instruktion?
- Out-of-Order-Execution, Branch-Prediction, Hyper-Threading, ...

Ausführungszeit von Elementaroperationen

☞ Ausführungszeit von Elementaroperationen ist essentiell

- Die Berechnung ist alles andere als einfach, ein Beispiel:

```
1  /* x = a + b */
2  LOAD r2, _a
3  LOAD r1, _b
4  ADD r3,r2,r1
```

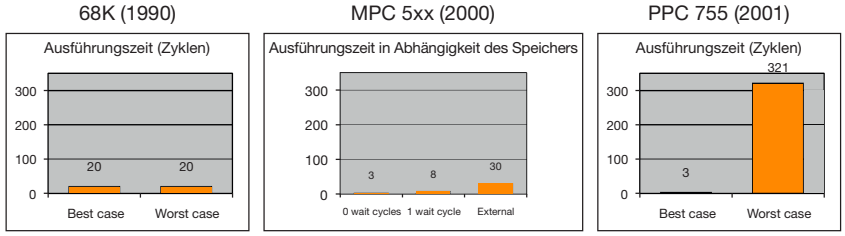

Quelle: Christian Ferdinand [1]

⚠ Laufzeitbedarf ist hochgradig Hardware- und kontextspezifisch

Gliederung

Messbasierte WCET-Analyse [3]

☞ Idee: Prozessor selbst ist das präziseste Hardware-Modell

→ Dynamische Ausführung und Beobachtung der Ausführungszeit

- Messbasierte WCET-Analyse:

→ Intuitiv und gängige Praxis in der Industrie

- Weiche/feste Echtzeitsysteme erfordern keine sichere WCET
- Einfach umzusetzten, verfügbar und anpassbar
  - Verschafft leicht Orientierung über die tatsächliche Laufzeit
  - Geringer Aufwand zur Instrumentierung (Plattformwechsel)
  - Eingeschränkte Verfügbarkeit statischer Analysewerkzeuge (HW-Plattform)
- Sinnvolle Ergänzung zur statischen WCET-Analyse (III-3/12 ff)
  - Validierung statisch bestimmter Werte
  - Ausgangspunkt für die Verbesserung der statischen Analyse

⚠ Das Richtige zu messen ist das Problem!

Problem: Längster Pfad

Beispiel: Bubblesort

```
void bubbleSort(int a[],int size) {
  int i,j;

  for(i = size - 1; i > 0; --i) {
    for (j = 0; j < i; ++j) {
      if(a[j] > a[j+1]) {
        swap(&a[j],&a[j+1]);
      }
    }
  }
  return;
}
```

Aufruf: `bubbleSort(a, size)`

- **D**urchläufe, **V**ergleiche und Vertauschungen (engl. ***S**wap*)
- `a = {1, 2}, size = 2`
  → D = 1, V = 1, **S = 0**;
- `a = {1, 3, 2}, size = 3`
  → D = 3, V = 3, **S = 1**;
- `a = {3, 2, 1}, size = 3`
  → D = 3, V = 3, **S = 3**;

⚠ Für den allgemeinen Fall nicht berechenbar ⇝ Halteproblem

- Wie viele Schleifendurchläufe werden benötigt?

☞ In Echtzeitsystemen ist dieses Problem häufig lösbar

- Kanonische Schleifenkonstrukte beschränkter Größe ⇝ `max(size)`
- Pfadanalyse ⇝ Nur maximale Pfadlänge von belang

Problem: Längster Pfad (Forts.)

Die möglichen Wege lassen sich durch Kontrollflussgraphen beschreiben

☞ Kontrollflussgraph (engl. *control flow graph*)

- Gerichteter Graph aus Grundblöcken (engl. *basic blocks*)
- Grundblöcke sind sequentielle „Code-Schnipsel“
  - hier wird gearbeitet ⇝ Grundblöcke verbrauchen Rechenzeit
- Kanten im Kontrollflussgraphen ⇝ Sprünge zwischen Grundblöcken

Beispiel: Bubblesort

```
void bubbleSort(int a[],int size) {
  int i,j;

  for(i = size - 1; i > 0; --i) {
    for (j = 0; j < i; ++j) {
      if(a[j] > a[j+1]) {
        swap(&a[j],&a[j+1]);
      }
    }
  }
  return;
}
```

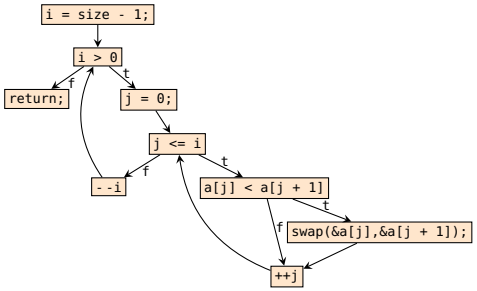

Herausforderungen der Messung

☞ Messungen umfassen stets das Gesamtsystem

→ Hardware, Betriebssystem, Anwendung(en), . . .

⚠ Fluch und Segen

- Mögliches Ergebnis einer Messung:

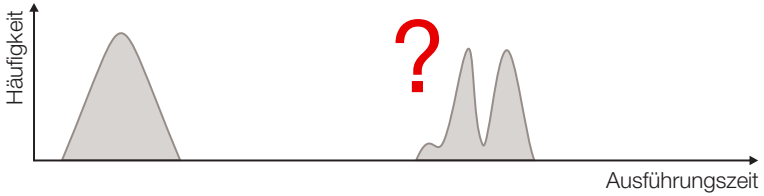

⚠ Probleme und Anomalien

- Nebenläufige Ereignisse unterbinden ↦ Verdrängung
- Gewählte Testdaten führen nicht unbedingt zum längsten Pfad
- Seltene Ausführungsszenarien ↦ Ausnahmefall
- Abschnittsweise WCET-Messung ↛ Globalen WCET
- Wiederherstellung des Hardwarezustandes schwierig/unmöglich

Aussagekraft messbasierter WCET-Analyse

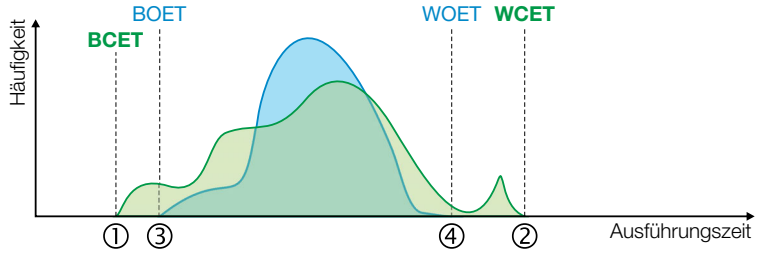

- Dynamische WCET-Analyse liefert Messwerte:

3 Bestmögliche beobachtete Ausführungszeit
(Best Observed Execution Time, BOET)

4 Schlechtest mögliche beobachtete Ausführungszeit
(Worst Observed Execution Time, WOET)

⚠ Messbasierte Ansätze unterschätzen die WCET meistens

Gliederung

Überblick: Statische WCET-Analyse

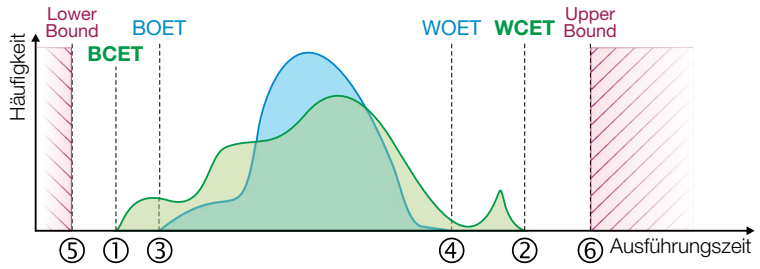

- Statische WCET-Analyse liefert Schranken:
  5. Geschätzte untere Schranke (Lower Bound)
  6. Geschätzte obere Schranke (Upper Bound)

☞ Die Analyse ist vollständig (engl. *sound*) falls Upper Bound $\geq$ WCET

Berechnung der WCET?

Mit der Anzahl f_i der Ausführungen einer Kante E_i bestimmt man die WCET e durch Summation der Ausführungszeiten des längsten Pfades:

$$e = \max_P \sum_{E_i \in P} f_i e_i$$

Problem: Erfordert die explizite Aufzählung aller Pfade

→ Das ist algorithmisch nicht handhabbar

Lösung: Vereinfachung der konkreten Pfadsemantik

→ Abstraktion und Abbildung auf ein Flussproblem

- Flussprobleme sind mathematisch gut untersucht
- Im folgenden zwei Lösungswege: Timing Schema und IPET

Lösungsweg$_1$: Timing Schema

Eine einfache Form der Sammelsemantik

Sequenzen ⇝ Hintereinanderausführung

```
S1();
S2();
```

Summation der WCETs:
$e_{seq} = e_{S1} + e_{S2}$

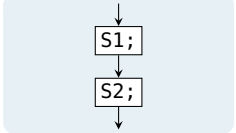

Verzweigung ⇝ bedingte Ausführung

```
if(P1())
  S1();
else S2();
```

Maximale Gesamtausführungszeit:
$e_{cond} = e_{P1} + \max(e_{S1}, e_{S2})$

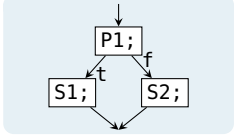

Schleifen ⇝ wiederholte Ausführung

```
while(P1())
  S1();
```

Schleifendurchläufe berücksichtigen:
$e_{loop} = e_{P1} + n(e_{P1} + e_{S1})$

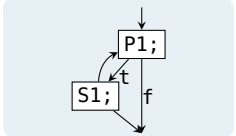

Timing Schema: Bubblesort

Beispiel: Bubblesort

```
void bubbleSort(int a[],int size) {
  int i,j;

  for(i = size - 1; i > 0; --i) {
    for (j = 0; j < i; ++j) {
      if(a[j] > a[j+1]) {
        swap(&a[j],&a[j+1]);
      }
    }
  }
  return;
}
```

- Funktionsaufruf
  S_1 = `swap(&a[j],&a[j + 1])`
  - Analog zum hier vorgestellten Verfahren
- Verzweigung
  C_1: P_1 = `a[j] > a[j + 1]`
  - S_1 = `swap(&a[j],&a[j + 1])`

  → $e_{C_1} = e_{P_1} + max(e_{S_1}, 0)$
- Schleife L_2: P_2 = `j < i`
  - Rumpf: C_1; `++j;`
  - Durchläufe: `size - 1`

  → $e_{L_2} = e_{P_2} + (size-1)(e_{P_2} + e_{C_1} e_{++j})$
- Schleife L_1: P_3 = `i > 0`
  - Rumpf: L_2; `--i;`
  - Durchläufe: `size - 1`

  → $e_{L_1} = e_{P_3} + (size-1)(e_{P_1} + e_{L_2} + e_{--i})$

Timing Schema: Eigenschaften, Vor- und Nachteile

- Eigenschaften
  - Traversierung des abstrakten Syntaxbaums (AST) bottom-up
    - An den Blättern beginnend, bis zur Wurzel
    - → Ausgangspunkt sind also explizite Pfade
  - Aggregation der maximale Ausführungszeit nach festen Regeln
    - Für Sequenzen, Verzweigungen und Schleifen
- Vorteile
  - \+ Einfaches Verfahren mit geringem Berechnungsaufwand
  - \+ Skaliert gut mit der Programmgröße
- Nachteile
  - – Informationsverlust durch Aggregation
    - – Korrelationen (z. B. sich ausschließende Zweige) nicht-lokaler Codeteile lassen sich nicht berücksichtigen
    - – Schwierige Integration mit einer separaten Hardware-Analyse
  - – Nichtrealisierbare Pfade (infeasible paths) nicht ausschließbar
    - → Unnötige Überapproximation

Lösungsansatz$_2$: Implicit Path Enumeration Technique

⚠ Explizite Pfadanalyse ohne Vereinfachung nicht handhabbar

☞ Lösungsansatz$_2$: Nutzung impliziter Pfadaufzählungen
⇝ Implicit Path Enumeration Technique (IPET) [2]

- Vorgehen: Transformation des Kontrollflussgraphen in ein ganzzahliges, lineares Optimierungsproblem (ILP)
  1. Bestimmung des Zeitanalysegraphs aus dem Kontrollflussgraphen
  2. Abbildung auf ein lineare Optimierungsproblem
  3. Annotation von Flussrestriktionen
     - Nebenbedingungen im Optimierungsproblem
  4. Lösung des Optimierungsproblems (z.B. mit gurobi[1])

☞ Globale Vereinfachung des Graphen statt lokaler Aggregierung

[1] http://gurobi.com/

Der Zeitanalysegraph (engl. *timing analysis graph*)

- Ein Zeitanalysegraph (T-Graph) ist ein gerichteter Graph mit einer Menge von Knoten $\mathcal{V} = \{V_i\}$ und Kanten $\mathcal{E} = \{E_i\}$
  - Mit genau einer Quelle und einer Senke
  - Jede Kante ist Bestandteile eines Pfads P von der Senke zur Kante

→ Jeder Kante wird ihre WCET e_i zugeordnet
⚠ Verzweigungen benötigen Dummy-Kanten d_i

Sequenz

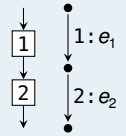

Verzweigung

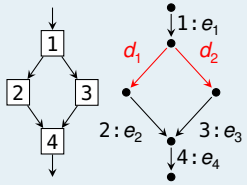

Schleife

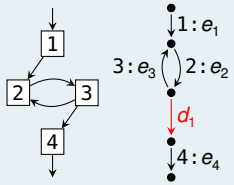

⚠ Graphentheorie annotiert Kosten klassischerweise an Kanten

Zirkulationen

☞ Abbildung $f : \mathcal{E} \mapsto \mathcal{R}$ heißt Zirkulation, falls sie den Fluss erhält
- Kanten wird die Zahl der Ausführungen f_i als Fluss zugeordnet
- Flusserhaltung: Jeder Knoten wird gleich oft betreten und verlassen
  - Erfordert die Einführung einer Rückkehrkante E_e mit $f_e = 1$

- Ausschluss ungültiger Abarbeitungen durch Flussrestriktionen
  - Formulierung als Nebenbedingungen des Optimierungsproblems
  - Beschränkung der maximalen Anzahl von Schleifendurchläufen

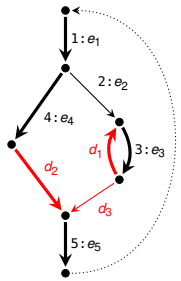

- Beispiel
  - $f_1 = f_2 + f_4$ wird durch die Zirkulation garantiert
  - gültige Zirkulation: $\{E_1, E_4, d_2, E_5, E_e\} \cup \{E_3, d_1\}$
    - → aber keine gültige Abarbeitung
  - Flussrestriktion $f_3 \leq 5 f_2$ löst dieses Problem
    - wird E_2 nicht abgearbeitet, so gilt $f_3 \leq 5 \cdot 0 = 0$
    - hier: Beschränkung auf 5 Schleifendurchläufe
    - → Nebenbedingung des Optimierungsproblems

Beispiel: Bubblesort

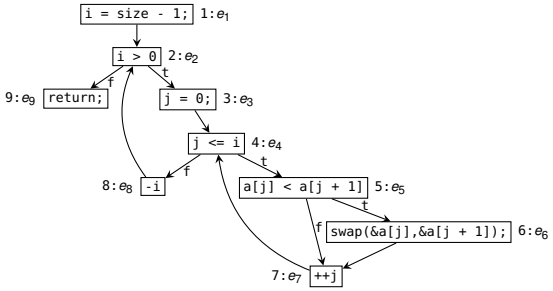

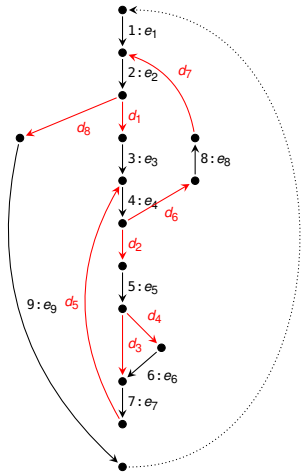

- Flussrestriktionen, die sich aus Schleifen ergeben:
  - Äußere Schleife: $f_2 \leq (size-1)f_1$
  - Innere Schleife: $f_4 \leq (size-1)f_3$
- Flussrestriktionen, die sich aus Verzweigungen ergeben:
  - Bedingte Vertauschung: $f_{d_3} + f_6 = f_7$

Ganzzahliges Lineares Optimierungsproblem

☞ Zielfunktion: Maximierung des gewichteten Flusses

$$\text{WCET}e = \max_{(f_1,\ldots,f_e)} \sum_{E_i \in \mathcal{E}} f_i e_i$$

→ der Vektor $(f_1, \ldots, f_e)$ maximiert die Ausführungszeit

☞ Nebenbedingungen: Garantieren tatsächlich mögliche Ausführungen

- Flusserhaltung für jeden Knoten des T-Graphen

$$\sum_{E_j^+ = V_i} f_j = \sum_{E_k^- = V_i} f_k$$

- Flussrestriktionen für alle Schleifen des T-Graphen, z.B.

$$f_2 \leq (size-1)f_1$$

- Rückkehrkante kann nur einmal durchlaufen werden: $f_{E_e} = 1$

IPET: Eigenschaften, Vor- und Nachteile

- Betrachtet implizit alle Pfade des Kontrollflussgraphen
  - Erzeugung des Zeitanalysegraphen
  - Überführung in ganzzahliges lineares Optimierungsproblem
- Vorteile
  - \+ Möglichkeit komplexer Flussrestriktionen
    - – z. B. sich ausschließende Äste aufeinanderfolgender Verzweigungen
  - \+ Nebenbedingungen für das ILP sind leicht aufzustellen
  - \+ Viele Werkzeuge zur Lösung von ILPs verfügbar
- Nachteile
  - – Lösen eines ILP ist im Allgemeinen NP-hart
  - – Flussrestriktionen sind kein Allheilmittel
    - – Beschreibung der Ausführungsreihenfolge ist problematisch

Gliederung

WCET eines Code-Schnipsels?

Werte der Grundblöcke sind Eingabe für die Flussanalyse

☞ Grundproblem: Ausführungszyklen von Instruktionen zählen

```
1  _getop:
2    link    a6,#0         // 16 Zyklen
3    moveml  #0x3020,sp@-  // 32 Zyklen
4    movel   a6@(8),a2     // 16 Zyklen
5    movel   a6@(12),d3    // 16 Zyklen
```

Quelle: Peter Puschner [2]

- Ergebnis: $e_{\texttt{\_getop}} = 80$ Zyklen
- Annahmen:
  - Obere Schranke für jede Instruktion
  - Obere Schranke der Sequenz durch Summation

⚠ Äußerst pessimistisch und zum Teil falsch

- Falsch für Prozessoren mit Laufzeitanomalien
  - WCET der Sequenz > Summe der WCETs aller Instruktionen
- Pessimistisch für moderne Prozessoren
  - Pipeline, Cache, Branch Prediction, Prefetching, . . . haben großen Anteil an der verfügbaren Rechenleistung heutiger Prozessoren
  - Blanke Summation einzelner WCETs ignoriert diese Maßnahmen

Hardware-Analyse

☞ Hardware-Analyse teilt sich in verschiedene Phasen

- Aufteilung ist nicht dogmenhaft festgeschrieben

- Integration von Pfad- und Cache-Analyse
  1. Pipeline-Analyse
     - Wie lange dauert die Ausführung der Instruktionssequenz?
  2. Cache- und Pfad-Analyse sowie WCET-Berechnung
     - Cache-Analyse wird direkt in das Optimierungsproblem integriert

- Separate Pfad- und Cache-Analyse
  1. Cache-Analyse
     - Kategorisiert Speicherzugriffe mit Hilfe einer Datenflussanalyse
  2. Pipeline-Analyse
     - Ergebnisse der Cache-Analyse werden anschließend berücksichtigt
  3. Pfad-Analyse und WCET-Berechnung

Beispiel: Cache-Analyse [4, Kapitel 22]

☞ Cache: ein kleiner, schneller Zwischenspeicher

- Zugriffszeiten variieren je nach Zustand des Caches enorm:
  - Treffer (engl. *hit*), Daten/Instruktion sind im Cache $\rightsquigarrow e_h$
  - Fehlschlag (engl. *miss*), Daten/Instruktion sind nicht im Cache $\rightsquigarrow e_m$

⚠ Hits sind schneller als Misses: $e_m \gg e_h$

→ Strafe liegt schnell bei > 100 Taktzyklen

- Eigenschaften von Caches mit Einfluss auf deren Analyse
  - Typ
    - Cache für Instruktionen
    - Cache für Daten
    - kombinierter Cache für Instruktionen und Daten
  - Auslegung
    - direkt abgebildet (engl. *direct mapped*)
    - vollassoziativ (engl. *fully associative*)
    - satz- oder mengenassoziativ (engl. *set associative*)
  - Seitenersetzungsstrategie
    - engl. *(pseudo) least recently used*, (Pseudo-)LRU
    - engl. *(pseudo) first in first out*, (Pseudo-)FIFO

Ergebnisse der Cache-Analyse

- Wissen ob eine Instruktion / ein Datum im Cache ist, oder nicht:

must, die Instruktion ist garantiert im Cache

→ man kann immer die schnellere Ausführungszeit e_h annehmen

- wird für die Vorhersage von Treffern verwendet

may, die Instruktion ist vielleicht im Cache

→ ist dies nicht der Fall, muss man die Ausführungszeit e_m annehmen

- wird für die Vorhersage von Fehlschlägen verwendet

persistent, die Instruktion verbleibt im Cache

→ erster Zugriff ist ein Fehlschlag, alle weiteren sind Treffer

→ erster Zugriff: e_m, weitere Zugriffe: e_h

- ist besonders für Schleifen interessant, die den Cache „füllen“

Werkzeugkette für die WCET-Analyse [3]

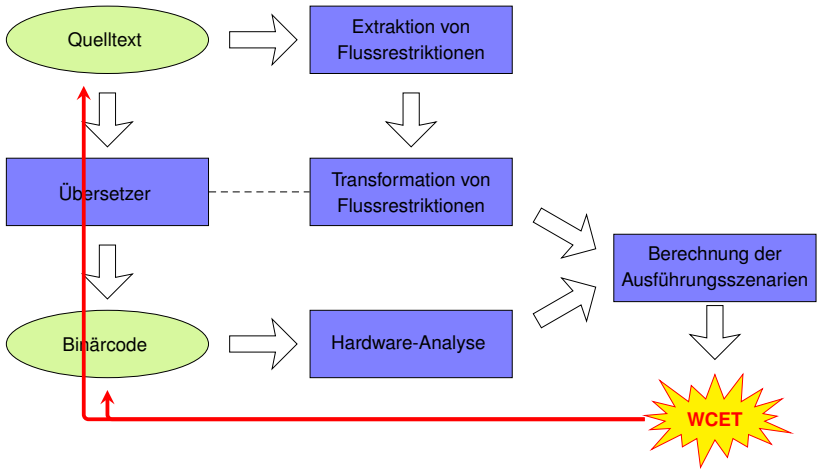

Gliederung

Resümee

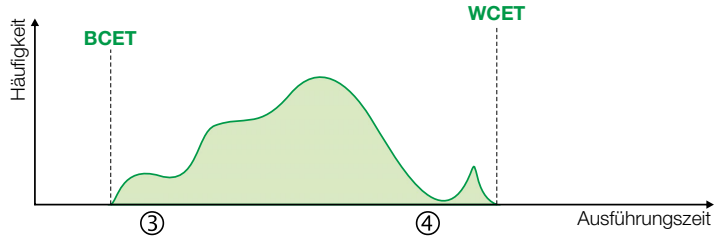

☞ WCET-Bestimmung gliedert sich grob in zwei Teilprobleme

- Programmiersprachenebene (makroskopisch) ⇝ finde die längsten Pfade durch ein Programm
- Maschinenprogrammebene (mikroskopisch) ⇝ bestimmte die WCET der Elementaroperationen

⚠ Tatsächliche Ausführungszeit: BCET / WCET

Resümee

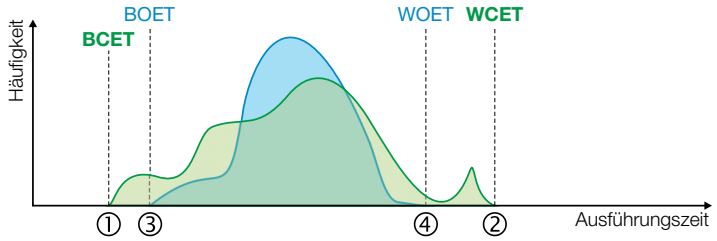

☞ Dynamische Analyse ↦ Beobachtung der Ausführungszeit

- Messung bezieht beide Ebenen mit ein
- Vollständige Messung im Allgemeinen nicht möglich ⇝ Unterapproximation

⚠ Gemessene Ausführungszeit: BOET / WOET

Resümee

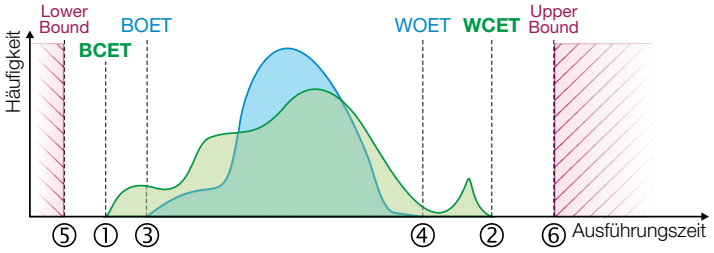

☞ Statische Analyse ↦ schätzt die Ausführungszeit

- Pfadanalyse (Programmiersprachenebene)
- Lösungswege: Abstraktion (Timing Schema vs. IPET)
- Gibt pessimistische Schranken an ⇝ Überapproximation

⚠ Geschätzte Ausführungszeitgrenzen: Lower- / Upper Bound

Resümee

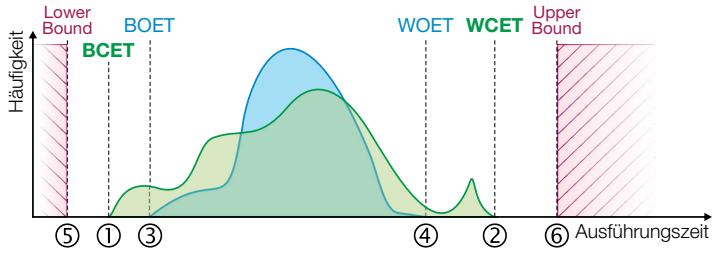

☞ Hardware-Analyse ↦ Eingaben für die WCET-Berechnung

- Hauptaufgaben: Cache- und Pipeline-Analyse
- must-Approximation und may-Approximation

⚠ Werkzeugunterstützung kombiniert Ebenen und macht die WCET-Analyse handhabbar

Literaturverzeichnis

[1] Ferdinand, C. ; Heckmann, R. ; Wolff, H.-J. ; Renz, C. ; Parshin, O. ; Wilhelm, R. :
Towards model-driven development of hard real-time systems.
In: *Model-Driven Development of Reliable Automotive Services.*
Springer, 2008, S. 145–160

[2] Puschner, P. :
Zeitanalyse von Echtzeitprogrammen.
Treitlstr. 1-3/182-1, 1040 Vienna, Austria, Technische Universität Wien, Institut für Technische Informatik, Diss., 1993

[3] Puschner, P. ; Huber, B. :
Zeitanalyse von sicherheitskritischen Echtzeitsystemen.
http://ti.tuwien.ac.at/rts/teaching/courses/wcet, 2012. –
Lecture Notes

[4] Wilhelm, R. :
Embedded Systems.
http://react.cs.uni-sb.de/teaching/embedded-systems-10-11/lecture-notes.html, 2010. –
Lecture Notes

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)

Strukturelemente

E_i Ereignis (engl. event)
R_i Ergebnis (engl. result)
T_i Aufgabe (engl. task)
$J_{i,j}$ Arbeitsauftrag (engl. job) der Aufgabe T_i

Temporale Eigenschaften

Allgemein
r_i Auslösezeitpunkt (engl. release time)
e_i Maximale Ausführungszeit (WCET)
D_i Relativer Termin (engl. deadline)
d_i Absoluter Termin
ω_i Antwortzeit (engl. response time)
σ_i Schlupf (engl. slack)