



Verteilte Betriebssysteme

10. Kapitel Globaler Zustand


Matthias Werner
Professur Betriebssysteme

10.1 Motivation

- ▶ Mitunter ist der globale verteilte Zustand einer verteilten Anwendung (oder ein Teil davon) interessant
- ▶ Problem der **Beobachtbarkeit**
 - ▶ Lokale Zustände können nur lokal beobachtet werden
 - ▶ Kommunikation kann **nur indirekt** über Send- und Empfangsereignisse beobachtet werden, nicht direkt
- ▶ Beispiel: verbundene Geldkonten


Beispiel: verbundene Geldkonten

- ▶ Bei mehreren, zusammengehörigen Geldkonten kann jederzeit Geld überwiesen werden oder eingehen
- ▶ Was ist der **Gesamtbetrag** auf den verbundenen Konten?



Beispiel: verbundene Geldkonten (Forts.)


- ▶ 1. Fall:



- ▶ **Beobachten:** $450€ + 200€ = 650€ \Rightarrow$ **inkorrekt**
- ▶ **Erkenntnis:** Konzept des **Kanals** als zu untersuchendes Objekt

Beispiel: verbundene Geldkonten (Forts.)

► 2. Fall:



- **Beobachten:** $500€ + 50€ + 250€ = 800€ \Rightarrow$ **inkorrekt**
- **Erkenntnis:** Konsistenz ist ein Problem (mal wieder 😞)

10.2 Konzepte


Definitionen: Historien und Schnitte

- Gegeben sei eine Menge von Prozessen $\mathbf{P} = \{P_1, P_2, \dots, P_n\}$, wobei jeder Prozess auf einem anderen Knoten läuft
- Die Folge **lokaler Ereignisse** im Prozess P_i heißt **Historie** von P_i : $h_i = \langle e_{i,1}, e_{i,2}, \dots \rangle$
 - **Beachte:** Auch Sende-/Empfangsereignisse sind lokale Ereignisse
- Betrachtung einer Historie bis zu einem bestimmten Zeitpunkt $k \Rightarrow$ **Präfix** der Historie $h_i(k) = \langle e_{i,1}, e_{i,2}, \dots, e_{i,k} \rangle$
- $s_{i,k}$ bezeichnet den **Zustand** eines Prozesses P_i unmittelbar nach Ereignis $e_{i,k}$
- Der **initiale Zustand** heißt $s_{i,0}$

Definitionen: Historien und Schnitte (Forts.)

- Durch Vereinigungsbildung lokaler Historien entsteht eine **globale Historie** $H = h_1 \cup h_2 \cup \dots \cup h_n$
- Ein **Schnitt** C einer globalen Historie ist die Vereinigung lokaler Präfixe:
 $C \stackrel{def}{=} h_1(c_1) \cup h_2(c_2) \cup \dots \cup h_n(c_n)$
- Verbunden mit einem Schnitt C ist
 - ein **globale Zustand** des Systems $S(C) = (s_{1,c_1}, s_{2,c_2}, \dots, s_{n,c_n})$,
 - die (linkseitige) **Grenzlinie** des Schnitts $E(C) = (e_{1,c_1}, e_{2,c_2}, \dots, e_{n,c_n})$


Schnitt




- Der Schnitt hat die (linkseitige) Grenzlinie $(e_{1,3}, e_{2,2}, e_{3,1})$

Konsistenter Schnitt


- Ein Schnitt partitioniert die globale Historie H in zwei Teile, den Schnitt C (Vergangenheit) und sein Komplement $H - C$ (Zukunft)
- Ein Schnitt C heißt **konsistent**, wenn $\forall e \in C, e' \prec e \Rightarrow e' \in C$
- Es darf keine kausalen Abhängigkeiten aus der „Zukunft“ geben



„Gummibandtransformation“



- Zur „Überprüfung“, ob ein Schnitt konsistent ist, kann man die lokalen Zeitachsen so dehnen oder stauchen, dass die Schnittlinie eine vertikale Gerade ergibt
- Alle Pfeile müssen in die Zukunft (nach rechts) zeigen
- Beispiel mit inkonsistentem Schnitt



10.3 Terminierung und Schnappschuss

- Mit Hilfe des konsistenten Schnittes kann das Problem des konsistenten globalen Zustands neu formuliert werden

Ein konsistenter Zustand ist die Summe der Teilzustände an einem konsistenten Schnitt.


- Wir betrachten zunächst „kleines“ Zustandsproblem: **Terminierung**
- Terminierungsproblem**
 - Feststellen, ob bei einem konsistenten Schnitt alle Prozesse endgültig terminiert sind.
- Darauf aufbauend betrachten wir das allgemeinere **Schnappschussproblem**
- Schnappschussproblem**
 - Feststellen der lokalen Zustände und gesendeten Nachrichten zu einem konsistenten Schnitt

Terminierung – Modell

- Aktivitätszustände:** verteilte Komponenten (Knoten) in einem verteilten Algorithmus können bzgl. der Terminierung zwei (lokale) Zustände haben:
 - Aktiv:**
 - Nachrichten können verschickt werden
 - Kann jederzeit „von allein“ in Zustand „terminiert“ wechseln
 - Terminiert:**
 - Kann keine Nachrichten verschicken
 - Kann **nur durch empfangene Nachrichten** in den Zustand „aktiv“ wechseln
- Kurz wird nur vom „Zustand“ gesprochen
- Wenn ein Terminierungsalgorithmus (Kontrollalgorithmus) bei mindestens einem Knoten einen aktiven Anwendungsalgorithmus(teil) entdeckt, ist dieser offensichtlich nicht terminiert
 - wir „kondensieren“ Aktivitätszeiten zu einem Punkt (**Atommodell**)
 - Nur die noch nicht ausgelieferten Nachrichten sind interessant

Einfaches Zählverfahren


- ▶ Ein „Beobachter“ besucht nacheinander jeden Knoten und summiert getrennt die **gesendeten** und die **empfangenen** Basisnachrichten auf
- ▶ An ungleichen Summen lässt sich erkennen, dass Nachrichten abgeschickt, aber noch nicht angekommen sind!
- ▶ Daher: Sind beide Summen identisch, dann ist keine Nachricht mehr unterwegs und der Algorithmus ist terminiert, *oder?*



- ▶ Beobachter meldet:
 - ▶ 3 Nachrichten gesendet
 - ▶ 2 Nachrichten empfangen
- ▶ $3 \neq 2$, keine Terminierung

Einfaches Zählverfahren (Forts.)

- ▶ Leider funktioniert dieses Verfahren so **nicht**, da die Bedingung nur **notwendig**, aber **nicht hinreichend** ist
- ▶ Beispiel: Beobachter meldet 3 Nachrichten empfangen und 3 Nachrichten gesendet ➔ **Phantom-Terminierung**
- ▶ Dies liegt an Nachrichten die in der „Zukunft“ gesendet wurden aber in der „Vergangenheit“ empfangen werden
 - ▶ Diese gleichen die Summendifferenz aus



- ▶ Beobachter meldet:
 - ▶ 3 Nachrichten gesendet
 - ▶ 3 Nachrichten empfangen
- ▶ $3 = 3$, Terminierung (**falsch!**)

Lösungsideen

- ▶ Vermeiden von Nachrichten aus der Zukunft
 - ➔ **Einfrieren** der Kommunikation im gefährlichen Bereich
- ▶ Nachträgliches Überprüfen mit zwei Wellen
 - ➔ **Doppelzählverfahren**
- ▶ Differenzierteres Zählen
 - ➔ **Vektorverfahren**

Einfrieren des Systems


- ▶ Erste Welle **friert** das System ein
 - ▶ Kein Prozess nimmt mehr eine (Basis-)Nachricht an
 - ▶ Zwischenzeitlich ankommende Nachrichten werden gepuffert und als „noch unterwegs“ betrachtet
 - ➔ Im eingefrorenen Teil des Systems, werden keine Nachrichten mehr gesendet
- ▶ Zweite Welle **summiert** die gesendeten und die empfangenen Nachrichten auf
 - ▶ Sind beide Summen gleich, ist das System terminiert
- ▶ Dritte Welle **taut** das System wieder auf

Problem

Verfahren setzt die Nebenläufigkeit **stark** herab und greift in den Basisalgorithmus ein!

Doppelzählverfahren

- Ein Beobachter besucht **zweimal** hintereinander alle Knoten und bestimmt jeweils die Summen der empfangenen und gesendeten Nachrichten
- Sind **alle vier Summen** gleich, dann ist der Basisalgorithmus terminiert: $S_1 = R_1 = S_2 = R_2$
- Falls keine Terminierung: Benutze zweite Welle der vorherigen Runde als erste Welle der neuen Runde




Doppelzählverfahrens: Eigenschaften

- Anzahl der Kontrollrunden ist a priori nicht durch die Anzahl der Basisnachrichten begrenzt
 - Es kann eine ganz langsame Basisnachricht geben; während ihrer Übertragung können **beliebig viele** Kontrollrunden gestartet werden
 - Variante beseitigt diese Eigenschaft: Prozess, der eine Basisnachricht erhält ohne eine neue auszusenden, **startet** eine neue Runde
- Das Doppelzählverfahren ist **ablaufinvariant**
 - Die lokalen Zustände der besuchten Prozesse werden nicht verändert
 - Mehrere konkurrierende Initiatoren können gleichzeitig die mögliche Terminierung testen

Vektorverfahren

- Jeder Prozess P_i führt einen lokalen Vektor $\vec{V}_i$ der Länge n
- $\vec{V}_i$ wird mit dem Nullvektor initialisiert
- Wenn P_i eine Basisnachricht an P_j verschickt, wird $\vec{V}_i[j]$ um 1 erhöht
- Wenn P_j eine Basisnachricht erhält, wird $\vec{V}_j[j]$ um 1 erniedrigt
- Ein Kontrollvektor $\vec{C}$ besucht reihum alle Prozesse
 - Bei einem Besuch, wird der lokale Vektor $\vec{V}$ zu $\vec{C}$ hinzuaddiert und $\vec{V}$ selbst wieder auf den Nullvektor gesetzt
 - Terminierung wird erkannt, sobald der Kontrollvektor zum **Nullvektor** wird
 - Keine Täuschung der Zähler möglich!



Vektorverfahren: Diskussion

► Verbesserung

- Falls die Komponente des als nächstes zu besuchenden Knotens 0 ist, diesen zunächst auslassen
- ➔ Potentiell nutzlose Besuche eines solchen Knotens werden vermieden

► Vorteile


- Unabhängig von der Netztopologie
- Meist geringe Anzahl von Kontrollnachrichten
- Basisnachrichten bleiben unberührt (Zähler wird **nicht** mitgeschickt)

► Nachteile

- Länge der Kontrollnachrichten (Vektor) $\mathcal{O}(n)$
- Verfahren ist **nicht** ablaufinvariant

Einfrieren des Systems

- Nutzung eines Wellenalgorithmus (z.B. Echo)
- Erste Welle friert das System ein
 - Kein Prozess sendet nach Empfang einer Ersten-Wellen-Nachricht mehr eine Nachricht
- Zweite Welle summiert lokalen Zustände auf
- Dritte Welle taut das System wieder auf
- **Problem:** Basisalgorithmus wird erheblich beeinträchtigt.



Quelle: F. Mattern, Verteilte Basisalgorithmen

Konsistente Schnappschüsse

Konsistenter Schnappschuss

Ein konsistenter Schnappschuss entspricht der Summe der Zustände der lokalen Knoten **und** Kanäle zu einem **konsistenten Schnitt**.

- Kanäle können nicht direkt beobachtet werden
- **Aber:** Bei festgestellter Terminierung sind Kanäle leer
- ➔ Jede Summe lokaler Zustände (ohne Berücksichtigung der Kanäle) nach (bei) Feststellung einer korrekten Terminierung, bilden eine konsistenten Schnappschuss
- Verteilte Terminierungsalgorithmen lassen sich aber **nicht direkt** zur Schnappschusserhebung einsetzen, da
 - auch Schnappschüsse **vor Terminierung** interessant sind
 - manche Algorithmen **nicht terminieren**
- **Aber:** Ideen lassen sich nutzen

CHANDY-LAMPORT Algorithmus (1985)

- **Annahmen:**
 - Gerichtete FIFO-Kommunikationskanäle
 - Zusammenhängender Kommunikationsgraph (Spezialfall: vollständig vernetzt)
 - Nachrichten des Basisalgorithmus werden nur einmal gesendet (Fehler sind ausgeschlossen)
 - Kanalübermittlung und lokale Zustandsnahme sind zeitbeschränkt (synchron)
- **Eigenschaften:**
 - Algorithmus kann von beliebigem Prozess ausgelöst werden
 - Nebenläufige Auslösung möglich
 - Der Algorithmus hat keinen Einfluss auf den Basisalgorithmus

CHANDY-LAMPORT Algorithmus (1985) (Forts.)

```

1 I: {NOT marked}; // initiator
2 Si := ZL; // take local state
3 marked := TRUE;
4 DO FOR ALL channel co IN set-of-out-channels
5   SEND <Marker> VIA co;
6 DONE
7
8 Ri: { message <Marker> is received via channel C}
9 IF NOT marked THEN
10  marked := TRUE;
11  Si := ZL; // take local state
12  Si,C := {};
13  DO FOR ALL channel co IN set-of-out-channels
14    SEND <Marker> VIA co;
15  DONE
16 ELSE
17  Si := Si + Si,C
18 FI
19
20 Ri: { message Msg != <Marker> is received via channel C}
21 IF marked THEN
22  Si,C := Si,C + Msg;
23 FI;

```


WS X - 25 von 34 osg.informatik.tu-chemnitz.de

CHANDY-LAMPORT Algorithmus (1985) (Forts.)

- Die Marker trennen auf den Kanälen die Nachrichten **vor** und **nach** dem Nehmen des lokalen Schnappschusses des Senders
- Das Verfahren terminiert, wenn alle Teilnehmer über alle Eingangskanäle einen Marker erhalten haben
 - Globaler Zustand: Summe aller lokalen (Knoten-)Zustände + aller (In-)Kanalzustände
 - Der Zustand kann eingesammelt werden, z.B. durch Senden der Knoten und Kanalzustände an den Initiator
- Modifikation:** Lokale Schnappschüsse und Empfangs-Ereignisse werden **sofort** an den Initiator gesendet und dort der konsistente Zustand zusammengesetzt

Nutzung der Vektorzeit

- Konstruieren einer **Schnittmatrix**
- Kann erkannt werden, ob die Schnittmatrix für einen konsistenten Schnitt steht?



Konsistente Schnittmatrix

- Sei **S** eine Schnittmatrix
 - dia(S)** sei der **Diagonalenvektor**

$$\text{dia}(\mathbf{S}) = (s_{1,1}, s_{2,2}, \dots, s_{n,n})^T$$

$$\mathbf{S} = \begin{pmatrix} 5 & 0 & 0 \\ 5 & 3 & 0 \\ 1 & 1 & 1 \end{pmatrix} \Rightarrow \text{dia}(\mathbf{S}) = \begin{pmatrix} 5 \\ 3 \\ 1 \end{pmatrix}$$
 - sup(S)** sei der **maximum row vector**


$$\text{sup}(\mathbf{S}) = (\max(s_{1,1}, \dots, s_{1,n}), \dots, \max(s_{n,1}, \dots, s_{n,n}))^T$$

$$\mathbf{S} = \begin{pmatrix} 5 & 0 & 0 \\ 5 & 3 & 0 \\ 1 & 1 & 1 \end{pmatrix} \Rightarrow \text{sup}(\mathbf{S}) = \begin{pmatrix} 5 \\ 5 \\ 1 \end{pmatrix}$$

Konsistente Schnittmatrix (Forts.)


Konsistente Schnittmatrix

Ein Schnitt ist genau dann konsistent, wenn für seine Schnittmatrix S gilt: $\text{dia}(S) = \text{sup}(S)$.



inkonsistenter Schnitt

$$\text{dia}(S) = \begin{pmatrix} 5 \\ 3 \\ 1 \end{pmatrix} \neq \text{sup}(S) = \begin{pmatrix} 5 \\ 5 \\ 1 \end{pmatrix}$$



konsistenter Schnitt

$$\text{dia}(S) = \begin{pmatrix} 4 \\ 3 \\ 1 \end{pmatrix} = \text{sup}(S) = \begin{pmatrix} 4 \\ 3 \\ 1 \end{pmatrix}$$

Vom Schnitt zum Schnappschuss

- ▶ Wie kommt man zum konsistenten Schnitt?
 - ▶ **Trivialer Ansatz:**
Wiederholt Vektoren anfordern und abwarten, bis $\text{dia}(S) = \text{sup}(S)$
- ▶ Was ist mit den Nachrichten?
 - ▶ **Trivialer Ansatz:**
Lokale Sende- und Empfangsereignisse zählen. Wenn die Summen zu einem konsistenten Schnitt gleich sind, sind keine Nachrichten unterwegs
- ▶ **Nachteil:** Es können sehr viele¹ Versuche nötig sein, um zum Schnappschuss zu kommen

¹Im Extremfall sogar unendlich viele

MATTERNS Lösung (1993)

- ▶ Initiator denkt sich einen Zeitstempel s in der **Zukunft** aus und schickt ihn an alle Knoten
- ▶ Alle Knoten merken ihn sich und schicken eine Bestätigung (falls lokale Zeit nicht kleiner $s \Rightarrow$ negative Bestätigung)
- ▶ Wenn der Initiator von allen Knoten positive Bestätigung erhalten hat, setzt er seine Vektorzeit auf s und sendet eine **Dummy-Nachricht**
- ▶ Jeder Knoten nimmt lokalen Schnappschuss, unmittelbar bevor er sein Vektorzeit zu einem Wert $\geq s$ setzt
- ▶ Der globale Schnappschuss ist die Summe der lokalen Schnappschüsse zuzüglich aller Nachrichten, die nach einem lokalen Schnappschuss mit einem Zeitstempel kleiner s ankommen

Diskussion

- ▶ Der Initiator darf bis zum Eintreffen aller Bestätigungen nicht aktiv werden
 - ➔ Basis-Algorithmen auf dem Initiator werden beeinträchtigt
- ▶ Terminierung ist nicht offensichtlich
 - ➔ Terminierungstest nötig (z.B. Nachrichten zählen)
- ▶ **Optimierungen**
 - ▶ Initiator als „virtueller“ Prozess ➔ kein Einfrieren
 - ▶ Wenn s hinreichend groß ist, kann auf Bestätigungen verzichtet werden

Kausaler Multicast

- ▶ Wenn kausaler Multicast (→ Kapitel 4) verwendet wird, erhält man „automatisch“ konsistente Schnitte
- ▶ Müssen noch Kanäle beobachtet werden
- ▶ Ansatz nach ACHARYA/BADRINATH (1992)
 - ▶ Jeder Prozess P_i zählt Sende- und Empfangsnachrichten zu/von jedem Prozess in $\vec{S}_i$ und $\vec{R}_i$, d.h. z.B. eine von P_j empfangene Nachricht inkrementiert $r_{i,j}$
 - ▶ Nachrichten mit Sequenznummern zwischen $r_{j,i} + 1$ und $s_{i,j}$ sind im Kanal zwischen P_i und P_j unterwegs
- ▶ Ansatz nach ALAGAR/VENKATESAN (1994)
 - ▶ Ab lokalem Schnappschuss werden „alte“ Nachrichten protokolliert
 - ▶ Initiator sendet Terminate-Nachricht zum Beenden der Protokollierung, nachdem er eine Bestätigung für das Nehmen der lokalen Schnappschüsse erhalten hat

Literatur

-  [TaSt02] Tanenbaum, A. S. und M. van Steen: *Distributed Systems*. Prentice Hall, 2002, Abschnitt 6.2
-  [CDK05] Coulouris, G., J. Dollimore und T. Kindberg: *Distributed Systems: Concepts and Design*. Prentice Hall, 2005, Kapitel 18