

Verteilte Systeme

5. Zeit

Ansätze

Pragmatisch: Uhrensynchronisation

- Abgleich der lokalen Uhren
- Beispiele
 - Zeitabgleich nach F. Cristian
 - Berkeley-Algorithmus
 - Verteilte Synchronisation
 - Network Time Protocol (NTP)

Theoretisch: Logische Uhren

- Vergleichbarkeit kausal abhängiger Ereignisse
- Reicht in vielen Fällen aus
- Beispiele
 - Lamport-Zeit
 - Vektor-Zeit



4.1 Uhrensynchronisation

Uhrensynchronisation

Zwei Grundtechniken:

- 1 Rechner hat die exakte Uhr (z.B. Empfang des DCF77-Signals)
exaktes Nachziehen aller anderen Uhren im System
- Jeder Rechner hat eine mehr oder weniger exakte Uhr
Ständiger Uhrenvergleich und -abgleich

Grundannahme:

- Uhren haben nur eine lineare Abweichung von der Idealzeit
Für ausreichend kleine Intervalle legitim

Ziel: Vor Überschreitung der maximal tolerierbaren Abweichung synchronisieren

- Funktioniert in der Praxis bei nicht übertriebenen Anforderungen :-)
- Beispiel: Uhrensynchronisation beim Empfang eines Ethernet-Frames (Preamble)

Lineare Uhrenabweichung

Perfekte Rechneruhr tickt mit n Hz

Genauigkeit moderner Quarzuhren:

- $\sim 10^{-5}$ (< 1 Sekunde / Tag)

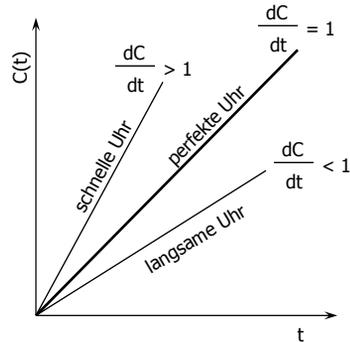
Lineare Abweichung:

$$\exists p > 0: 1 - p < \frac{dC}{dt} < 1 + p$$

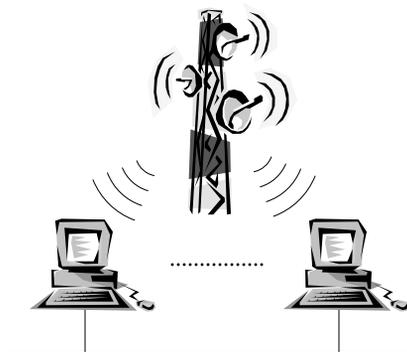
Maximale Abweichung zweier Uhren nach Δt : $2p \Delta t$

Beispiel: $p = 10^{-5}$, $\Delta t = 60s$:

- max. Abweichung 1.2 ms



DCF77-basierte Synchronisation



Zentraler Zeit-Server

- Atomuhr in Braunschweig
- Sender in Offenbach bei Frankfurt

Empfangsmodul in jedem Rechner

Maximale Drift

- Reichweite 1500 km (DCF77)
- 5 ms Differenz
- Warum nicht 10 ms?

Bedingungen für eine erfolgreiche DCF77-basierte Synchronisation?

Variante

- Zusätzliches Clock-Signal im Netz

Pech :-(

S = DCF77-Sender

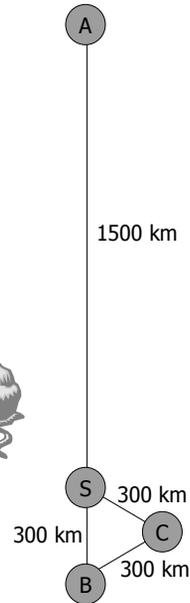
GZ = Globale Zeit

Szenario:

- A sendet um 14.000 GZ an B
 "Sie haben 1e10 DM gewonnen!"
- C sendet um 14.001 GZ an B
 "Pokerschulden in Höhe 1e9 DM!"

Reaktionen

- B erhält zuerst Nachricht von A
- B erhält zuerst Nachricht von C



Uhrenabgleich nach F. Christian

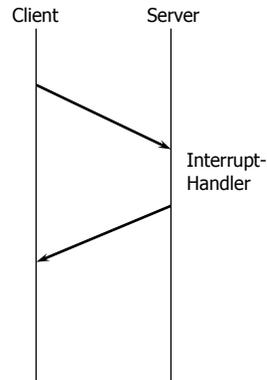
Uhrenabgleich mit passivem,
 zentralem Zeit-Server

Vorgabe: maximale Abweichung
 zwischen zwei Rechnern < a:

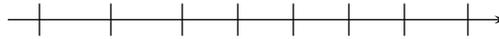
- Abgleichintervalle < a/2p

Zeit-Server sendet auf Anfrage
 schnellst-möglich aktuelle
 Uhrzeit:

- Vgl. ICMP-Nachricht
 (Timestamp Request)
- Übertragenen Uhrenwert
 übernehmen!?



Zwei Probleme



Empfänger Zeitwert kleiner als lokale Uhr:

- Lokale Uhr läuft schneller
- Zeit schreitet nur voran
- Bis zum Angleich werden die Zeittakte kürzer (Anti-Schaltmillisekunden)
- Um abrupte Zeitsprünge zu vermeiden auch beim Hochsetzen (Schaltmillisekunden)

Empfänger Zeitwert berücksichtigt Transportzeit nicht

- Lokale Sende- und Empfangszeit messen
- Korrekturfaktor:

$$\frac{t_{Empfang} - t_{Senden}}{2}$$

wenn möglich lokal verbrauchte Zeit bei Server berücksichtigen
mehrere Messungen: Schnellste = geringste Verfälschung

Berkeley-Algorithmus

Aktiver, zentraler Zeit-Server

Ablauf:

- Server sendet periodisch seine Zeit an alle Rechner
- Klienten antworten mit ihrer jeweiligen Zeitverschiebung
- Server berechnet eine mittlere Zeit und teilt diese den anderen Rechnern mit
- Klienten gleichen ihre Zeiten in kleinen Schritten an
 - Schaltmillisekunden
 - Anti-Schaltmillisekunden

Network Time Protocol (NTP)

UDP-basiertes Protokoll
(Port 123)

Hierarchische Struktur

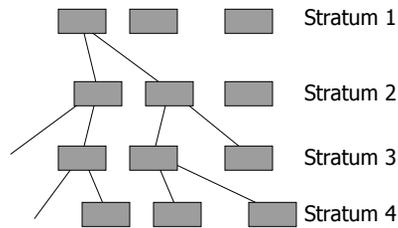
- Primary Server werden z.B. über DCF77 synchronisiert
- Secondaries gleichen zur nächst höheren Ebene ab
- Minimaler Spannbaum (Bellman-Ford)

Gewicht: Stratum+Distanz

Protokoll liefert

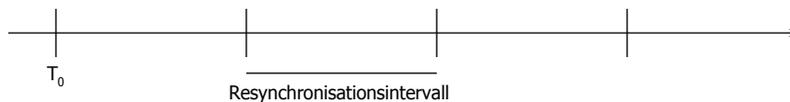
- Clock Offset
- Roundtrip Delay
- Dispersion (max. Fehler)

relativ zu einem Referenz-Server



Auflösung 232ps

Verteilter Uhrenabgleich



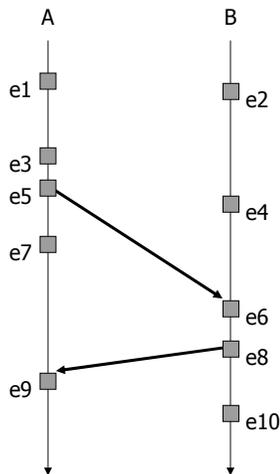
T_0 akzeptierter gemeinsamer Zeitpunkt

Ablauf:

- Zu Beginn eines Resynchronisationsintervalls sendet jeder Rechner seine aktuelle Zeit per Broadcast
aufgrund der Drift geschieht das nicht gleichzeitig
- Einsammeln weiterer Broadcasts
- Mittelwert bilden und neue Zeit berechnen
m beste und m schlechteste Werte ignorieren (kein Abgleich mit maximal m kaputten Uhren)

4.2 Logische Uhren

Kausalität



Ereignisse

- Lokale Ereignisse
- Sende- und Empfangereignisse

Kausalität

- Ursache vor Wirkung
- Ereignis e_n ist kausal abhängig von e_m , wenn e_n Auswirkungen auf e_m haben kann:

$$e_n <_k e_m$$

- Kausal unabhängige Ereignisse
- Transitivität
- Partielle Ordnung

Kausale Abhängigkeit lokaler Ereignisse

$$(A, e_n) <_k (A, e_{n+l}) \quad l > 0$$

Kausalität bei Senden und Empfangen

$$(A, e_{Senden}) <_k (B, e_{Empfangen})$$

Logische Uhren

Ereignissen logische Zeit zuordnen

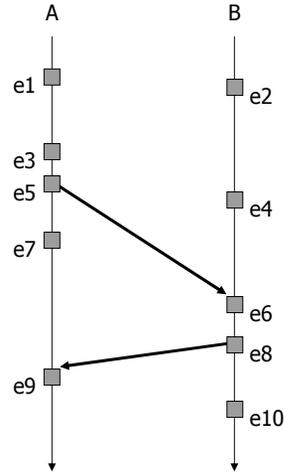
Gesucht: Abbildung $LC : E \rightarrow H$

- E: Menge der Ereignisse mit Kausalrelation
- H: Zeitbereich (halbgeordnete Menge; "früher", "später")

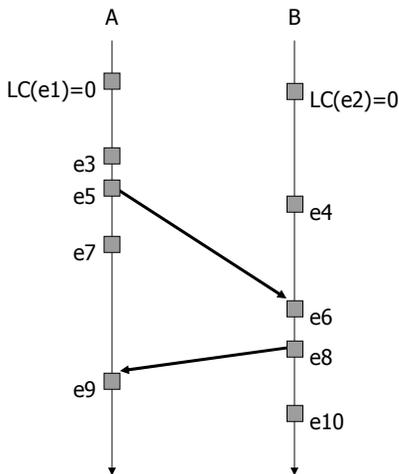
Zeitstempel $LC(e)$

Uhrenbedingung

$$e_n <_k e_m \Rightarrow LC(e_n) < LC(e_m)$$



Lamportzeit



Logische Uhr LC pro Rechner

- n Bit-Zähler

Logische Uhr tickt bei Ereignissen

- Lokales Ereignis

```
LC := LC + 1;
```

- Sendeereignis

```
LC := LC + 1;
Send(Message, LC);
```

- Empfangsereignis

```
Receive(Message, LC_Sender);
LC := Max(LC, LC_Sender) + 1;
```

Gilt die Uhrenbedingung?

Eigenschaften der Lamportzeit

Kausale Unabhängigkeit

$$LC(a) = LC(b) \Rightarrow a \parallel b$$

$$a \parallel b \Leftrightarrow \neg(a <_k b) \wedge \neg(b <_k a)$$

Umkehrung der Uhrenbedingung gilt nicht

$$LC(a) < LC(b) \not\Rightarrow a <_k b$$

$$LC(a) < LC(b) \Rightarrow (a <_k b) \vee (a \parallel b)$$

- d.h. aus den Zeitstempeln läßt sich nicht immer eindeutig festlegen, ob zwei Ereignisse kausal voneinander abhängen

Zukunft kann Vergangenheit nicht beeinflussen

$$LC(a) < LC(b) \Rightarrow \neg(b <_k a)$$

Erweiterte Lamportzeit

Lamportzeit ist nicht injektiv

$$LC(a) = LC(b) \not\Rightarrow a = b$$

Erweiterung zu einer totalen Ordnung

- Hinzufügen eines zusätzlichen Kriteriums, z.B. Rechnernummer
- Zeitstempel für Ereignis e auf Rechner A: $LC_E(A, e)$

$$LC_E(A, a) < LC_E(B, b)$$

$$\Leftrightarrow LC(a) < LC(b) \vee (LC(a) = LC(b) \wedge A < B)$$

- Alle Ereignisse haben verschiedene Zeitstempel

Erweiterte Lamportzeit kausalitätserhaltend

$$a <_k b \Rightarrow LC(a) < LC(b) \Rightarrow LC_E(A, a) < LC_E(B, b)$$

Überläufe der logischen Uhr

Überläufe praktisch ausschließen

- Abschätzung der maximalen Ereignisrate pro Rechner und der maximalen Laufzeit
- Bitanzahl von LC geeignet wählen
- Beispiel
 - Maximal 1000 Ereignisse pro Sekunde
 - 32 Bit Zähler: 49 Tage, 17 Stunden, 2 Minuten, 47 Sekunden
 - 64 Bit Zähler: ca. 584 Millionen Jahre

Spezieller Algorithmus bei Überlauf

- Auslöser: LC-Überlauf auf einem Rechner
- Lösungsansätze?



Verteilte Systeme, Winter 2002

Folie 5.19

Zusammenfassung Lamportzeit

Einfache Realisierung

- Verschicken zusätzlicher Information in jeder Nachricht
 - Identifikation des sendenden Rechners
 - Zeitstempel des Sendeereignisses

Uhrenbedingung erfüllt

$$a <_k b \Rightarrow LC(a) < LC(b) \Rightarrow LC_E(A, a) < LC_E(B, b)$$

Umkehrung der Uhrenbedingung gilt nicht

$$LC_E(A, a) < LC_E(B, b) \not\Rightarrow LC(a) < LC(b) \not\Rightarrow a <_k b$$

- d.h. aus den Zeitstempeln kann i.A. nicht auf eine kausale Abhängigkeit geschlossen werden

Verteilte Systeme, Winter 2002

Folie 5.20

Vektorzeit

Beliebige aber feste Menge von n Rechnern

- Erweiterung auf dynamische Rechnermengen möglich

Zeitstempel eines Ereignisses a ist ein Vektor der Größe n

Verschiedene Realisierungsvarianten

Schreibweisen

- Sei VC_k die logische Uhr von Rechner k
- $VC_k[j]$ bezeichne die j .te Komponente in VC_k

$$VC(a) = \begin{pmatrix} VC_0 \\ \vdots \\ VC_{n-1} \end{pmatrix}$$

Realisierung [Mattern 1989]

Initialisierung von VC auf Rechner k

```
for (i=0; i<n; i++) VC_k[i] := 0;
```

Lokales Ereignis auf Rechner k

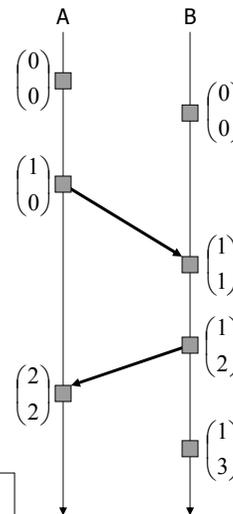
```
VC_k[k] := VC_k[k] + 1;
```

Sendeereignis auf Rechner k

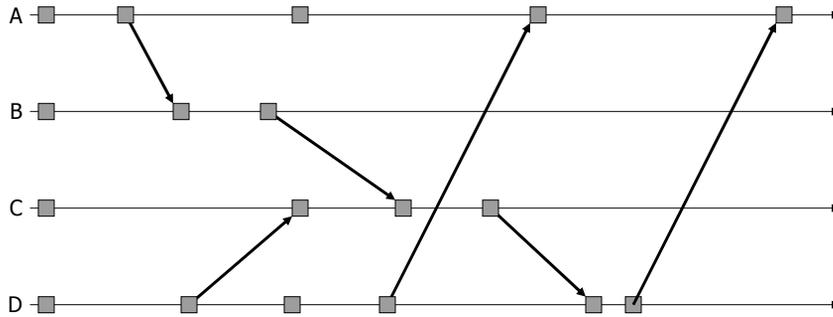
```
VC_k[k] := VC_k[k] + 1;
Send (Message, VC_k);
```

Empfangereignis auf Rechner k

```
VC_k[k] := VC_k[k] + 1;
Receive (Message, VC_sender);
for (i=0; i<n; i++)
    VC_k[i] := max (VC_k[i], VC_sender[i]);
```

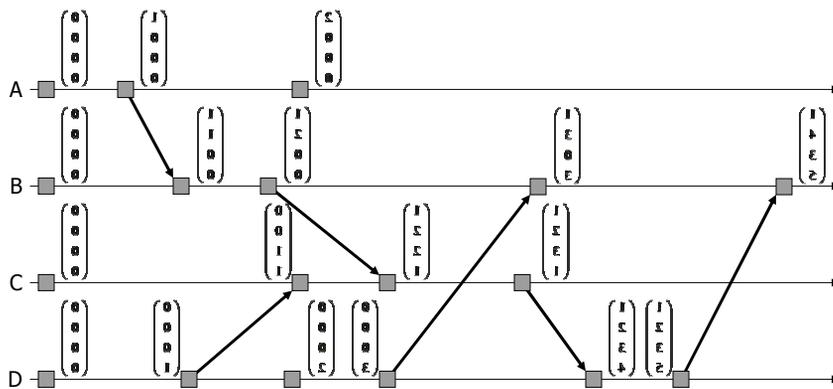


Beispiel



Wann sind Ereignisse kausal abhängig?
 Wann sind Ereignisse kausal unabhängig?

Lösung



Eigenschaften der Vektorzeit

Sei $va=VC(a)$ und $vb=VC(b)$

Definition:

Für 2 Zeitstempel $VC(a)$ und $VC(b)$ gilt:

$$va \leq vb \Leftrightarrow \forall i : va[i] \leq vb[i]$$

$$va < vb \Leftrightarrow (va \leq vb) \wedge (va \neq vb)$$

$$va \parallel vb \Leftrightarrow \neg(va < vb) \wedge \neg(vb < va)$$

Kausale Abhängigkeit

$$va \leq vb$$

Kausale Unabhängigkeit

$$va \parallel vb \Rightarrow \exists i, j \in \{0, \dots, n-1\} : (va[i] < vb[i]) \wedge (vb[j] < va[j])$$

Zusammenfassung Vektorzeit

Einfache Realisierung

- Verschicken zusätzlicher Information in jeder Nachricht
 - Identifikation des sendenden Rechners
 - Zeitvektor des Sendeereignisses

Problematik dynamischer Rechnermengen

Uhrenbedingung erfüllt

$$a <_k b \Rightarrow VC(a) < VC(b)$$

Umkehrung der Uhrenbedingung gilt ebenfalls

$$VC(a) < VC(b) \Rightarrow a <_k b$$

- d.h. aus den Zeitstempeln kann auf eine kausale Abhängigkeit geschlossen werden
- Beweis?

Zusammenfassung

Uhrensynchronisation

- Reicht in vielen Fällen meist aus
- Uhrenbedingung
 - Sanfter Abgleich einer ev. Uhrenabweichung notwendig
 - Dann gilt natürlich auch die Umkehrung

Logische Uhren

- Beschränkung auf kausal abhängige Ereignisse
- Häufig Erweiterung auf totale Ordnung
 - Kausalität bleibt weiterhin erhalten
 - "Willkürliches" Zusatzkriterium bei unabhängigen Ereignissen
- Lamportzeit ist einfachste Realisierung
 - Erfüllt Umkehrung der Uhrenbedingung nicht
- Vektorzeit
 - "Hoher" Aufwand
 - Erfüllt Umkehrung der Uhrenbedingung

Literatur

F. Christian

Probabilistic Clock Synchronization

Distributed Computing, Vol. 3, pp. 146-158, 1989

R. Gusella, S. Zatti

The Accuracy of the Clock Synchronization Achieved by TEMPO in Berkeley UNIX 4.3 BSD

IEEE Trans. on SE, Vol. 15, pp. 847-853, 1989

(Berkeley-Algorithmus zur Uhrensynchronisation)

L. Lamport

Time, clocks and the ordering of events in a distributed system

CACM, Vol. 21, Nr. 7, pp. 558-565

(Kausalität, Vektorzeit)

F. Mattern
Verteilte Basisalgorithmen
Informatik-Fachberichte 226, Springer-Verlag, 1989

D.L. Mills
Network Time Protocol (NTP) Version 3
RFC1305