Verteilte Systeme SS2002:

Konsens und Verlässlichkeit

Marcel Waldvogel

Ordnung und Gleichzeitigkeit

- Einzelner Master
  - Globales Locking
  - Optimismus
  - Vorteile?
- Verteilte Master
  - Zeitstempel
  - Abstimmung
  - Byzantinische Entscheidungsfindung
  - Vorteile?

Übersicht

- Problemstellung
  - Fehler und -erkennung
- Lösungsmöglichkeiten
  - Ausschluss
  - Abstimmungen
  - Konsens
- Offene Probleme
  - Unzuverlässigkeit

Fehler

- Annahmen
  - Zuverlässige Kanäle
    - Endliche Auslieferungsverzögerung
  - Unabhängigkeit
  - Prozesse können terminieren (Crash)
- Weitere Möglichkeiten
  - Synchrone Kommunikation
  - Hardware-Multicast
- Fehlertypen
  - Netzwerkpartitionierung
  - Asymmetrie
  - Intransitivität

Fehlererkennung

- *Typischerweise unzuverlässig*
  - *Nicht Verdächtig, Verdächtig*
  - *Richtung des Irrtums?*
- *Zuverlässige Erkennung*
  - *Nicht Verdächtig, Fehlerhaft*
- *Timeouts*
- *Synchrone Systeme*

Gegenseitiger Ausschluss

- *Grundmechanismus*
- *Eigenschaften*
  1. *Sicherheit: Maximal ein Prozess in kritischem Bereich*
  2. *Lebendigkeit: Ein-/Austritt erfolgt nach endlicher Zeit*
  3. *Ordnung (optional, fair): Anfragen in Happened-Before-Ordnung werden auch in dieser Reihenfolge bearbeitet*
     - *Korollar: Kein Prozess erhält ein zweites Mal Zugriff auf den kritischen Bereich, bevor nicht alle länger anstehenden Wünsche befriedigt wurden*

Zentraler Server

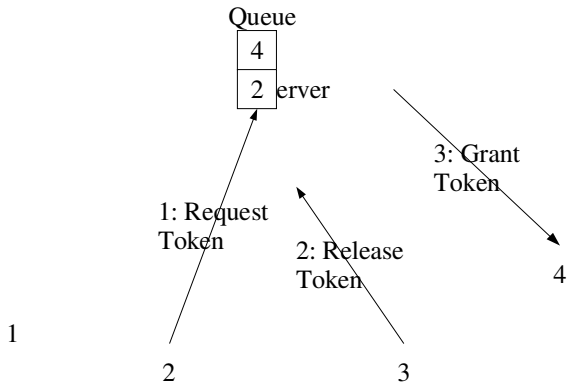

Ring

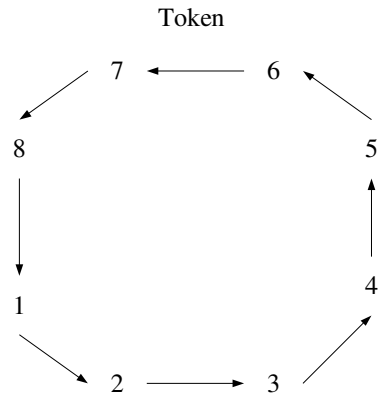

Leistung

	Server	Ring	
Bandbreite	3	∞	[Msg/Entry]
Wartezeit	2	n	[Transmission]
Durchsatz	2	n	[Transmission]

Ausschluss mit Logischen Uhren

- *Initialisierung*
  - *status := FREI;*
- *Eintritt*
  - *status := ICH_WILL;*
  - *Multicast Anfrage an alle;*
  - *T := logische Zeit der Anfrage;*
  - *Warte auf alle Antworten;*
  - *status := BESETZT;*
- *Erhalt Anfrage $<T_i, p_i>$ bei p_j*
  - *Falls Anfrage besser, beantworte sie; ansonsten stelle sie in Warteschlange.*
- *Austritt*
  - *status := FREI;*
  - *Sende Antwort an alle in Warteschlange;*

Abstimmung zum Ausschluss

- *Erkenntnis*
  - *Nicht alle müssen zustimmen, es reicht, wenn jeder eine Teilmenge anfragt, und alle möglichen Teilmengen sich in mindestens einem Element überlappen*
- *Problem*
  - *Deadlock*
- *Lösung*
  - *Komplex*

1	2	3	4	5
6	7	8	9	10
11	12	13	14	15
16	17	18	19	20
21	22	23	24	25

Fehlertoleranz

- *Auswirkungen von*
  - *Verlust einer Nachricht*
  - *Absturz eines Prozesses*
- *Umgehung des Problems?*
  - *Verfügbarkeit eines zuverlässigen Fehlerdetektors*
  - *Rekonstruktion des Systemzustandes vor Absturz?*

Wahlen

- Zuverlässig auch bei Abstürzen
- Voraussetzungen
  - Sicherheit: Wenn ein Prozess einen anderen gewählt hat, sind sich alle einer Meinung
  - Lebendigkeit: Alle (funktionierenden) Prozesse nehmen teil und bilden sich irgendwann eine Meinung
- Möglichkeiten
  - Ring (siehe Occam)
  - Tyrann

Bully Algorithm

- Synchrones System
  - Timeout
- Erkennen von Abstürzen
- Kenntnis aller höher priorisierten Prozesse
- Nachrichten
  - Wahl ("Der König ist tot!")
  - Antwort (ich lebe noch)
  - Koordinator ("Es lebe der König!")
- Effizienz?

Multicast

- Implosion
- Offene und geschlossene Gruppen
- Zuverlässigkeit
- Ordnung
  - Sinn?

Zuverlässiger Multicast

- Kriterien
  - At-most-once
  - Auslieferung in endlicher Zeit
  - Alle oder keiner (für korrekte Prozesse)
- Senden
  - Zuverlässiges Multi-Unicast an alle (inklusive Sender);
- Empfang bei p
  - Wenn Nachricht kein Duplikat ist:
    - Falls p nicht originaler Sender ist, dann schicke Meldung mit zuverlässigem Multi-Unicast an alle (inklusive Sender);
  - Liefere Nachricht lokal aus;

Ordnung bei Multicast

- *Unabhängig von Zuverlässigkeit*
- *FIFO-Ordnung*
  - *Meldungen eines Senders werden nicht umsortiert*
    - *Sequenznummern*
- *Kausale Ordnung*
  - *Happened-Before bleibt erhalten*
    - *Vektorzeiten*
- *Totale Ordnung*
  - *Jeder Prozess erhält jede Nachricht in derselben Reihenfolge*
  - *Empfangsreihenfolge unabhängig von Sendereihenfolge*
    - *Zentraler Server für Sequenznummern*
    - *Hardware-Multicast (Vorsicht bei Ethernet!)*

Verteilte Totale Ordnung

- *Nachricht mit zuverlässigem Multi-Unicast verschicken*
- *Alle Antworten mit einer vorgeschlagenen Sequenznummer*
  - $P_q := Max(A_q, P_q)+1$
- *Grösste Antwort als Sequenznummer a senden*
  - $A_q := Max(A_q, a)$
- *Ausliefern*

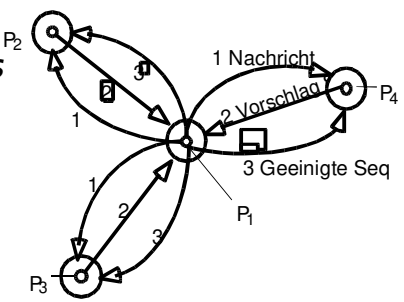

Beispiel: Diskussionsgruppen

Total: Alle Nummern sind überall dieselben

Bulletin board: *os.interesting*

Item	From	Subject
23	A.Hanlon	Mach
24	G.Joseph	Microkernels
25	A.Hanlon	Re: Microkernels
26	T.L'Heureux	RPC performance
27	M.Walker	Re: Mach
end		

Kausale Ordnung: Original vor Antworten darauf

FIFO: Senderreihenfolge

Konsens

- *Frage*
  - *Wie einigt man sich auf einen Entscheid, wenn einiges schief läuft?*
- *Annahmen*
  - *Kommunikation zuverlässig*
  - *Prozesse nicht*
- *Weitere Annahmen*
  - *Byzantinische Fehler möglich*

Konsens: Ablauf

- Jeder Prozess ist unentschieden
- Jeder schlägt einen Wert vor
- Kommunikationsphase
  - Crash möglich
- Jeder Prozess entscheidet sich irgendwann für einen der vorgeschlagenen Werte
- Ziel: Alle korrekten Prozesse einigen sich innert nützlicher Frist auf dasselbe Resultat

Byzantinische Entscheidungsfindung

- Byzanz/Konstantinopel, 1453
  - Mehrere Generäle mit Truppen
  - Nur gleichzeitiger Angriff möglich
  - Widrige Umstände
    - Klassisch: Konspiration einiger Generäle
    - Alternative: Meldungsübertragung gestört
- Modern
  - Einigung mehrerer Rechner/Programme eines Verteilten Systems auf gemeinsames Resultat
    - Fehler im System (absichtlich und unabsichtlich)

Byzantinische Generäle

- Problem
  - 4 Generäle
  - Nicht alle loyal
    - Verräter geben falsche Informationen weiter
    - Verräter befolgen Befehle
  - Direkte, perfekte Kommunikation
  - Eine (korrekte) Entscheidung
- Einfache Lösung
  - Abstimmung
    - Jeder schickt seine Stimme an alle
    - Jeder errechnet "lokal" die Stimmenmehrheit
    - Verräter befolgen Ergebnis auch
    - Funktioniert nicht
- Viele Varianten, komplexere Lösungen

Anwendungen

- Klassisch: Militärische Koordination
- Informatik: Fehlertoleranz
  - Flugzeugsteuerung
  - Zuverlässige Rechnersysteme
  - Verteilte Systeme
    - Nutzung von Rechnern unter unbekannter Administration
    - Peer-to-peer-Systeme