Willkommen bei Verteilte Systeme!

Von Datenbanken
über Webdienste
bis zu p2p und Sensornetzen.

:)

Heute: **Koordinator, Synchronisierer, Fehlertoleranz, Konsens**.

Zusammenfassung von Vorlesung 4 I

- Replikation
  - Single, Multi, Leaderless
  - Quorum Bedingung: $r + w > n$
  - kann zu Inkonsistenzen führen
  - Konsistenzmodelle definieren Garantien
  - Beispiel: Sticky Available
- CRDTs und CALM
  - Koordination vermeiden oder zumindest einschränken.
  - benötigen für Performance Garbage Collection ⇒ Koordination
  - Genutzt in Riak, Redis, Dynamo

Zusammenfassung von Vorlesung 4 II

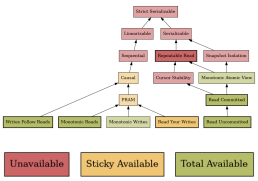

Literatur

Distributed Systems - An Algorithmic Approach – Sukumar Ghosh (2015).

Ablauf heute

- Koordinator
- Synchronisierung

```
--- PAUSE 14:15 ---
```

- Fehlertoleranz
- Konsens

Koordinator

Verteilte, asynchrone Handlungen für ein gemeinsames Ziel

Ziele für Koordination

- Sie erkennen Algorithmen zur Wahl des Koordinators — leader election

Online-Versuch: Warum Koordination?

- Schalten Sie bitte Ihre Mikrophone a
- Bis 10 zählen
- Es spricht immer nur Einer oder Eine
- Wenn zwei sich unterbrechen, fangen wir neu an

Präsenz-Versuch: Warum Koordination?

- Schließen Sie bitte die Augen
- Versuchen Sie, bis 10 zu zählen
- Es spricht immer nur Einer oder Eine
- Jede Person darf nur eine Zahl nennen
- Wenn zwei sich unterbrechen, fangen wir neu an

Wie lange brauchen wir?

Wahl eines Koordinators

- Vereinfacht viele Algorithmen
- Koordinator steuert das System
- Wenn ein Koordinator stirbt, wird ein neuer gewählt
- Wenn sich zwei Netze verbinden, wählen die Knoten einen gemeinsamen Koordinator

Konzeptuell

Für die Algorithmen zur Wahl muss gelten:

- Alle korrekt funktionierenden Knoten eines Netzes haben den selben Koordinator.
- Der Koordinator ist Teil des Netzes.
- Der Koordinator funktioniert korrekt.

Bully-Algorithmus

- Auswahl nach ID: laufender Prozess mit höchster ID wird Koordinator
- Annahmen:
  - Vollständig verbundenes Netz, alle erreichbar und bekannt
  - Fehlerfreie Kommunikation
  - Einziger Knoten-Defekt: Sterben
  - Es gibt einen Mechanismus zur Erkennung von Defekten
  - Es gibt eindeutig sortierte IDs.
  - Die IDs sind allen bekannt

Von Garcia-Molina (1982).

Bully-Algorithmus: Ablauf

Nachrichten: election, reply, leader

1. `election` an alle mit **höherer** ID: „Kann ich Koordinator sein?“
2. Warten auf `reply`.
   1. Falls min. 1 `reply`: Warte auf `leader`.
   2. Falls timeout oder keine höhere ID bekannt: `leader`-Nachricht an **alle**.
3. Bei `election` Anfrage: Reply und weiter bei 1.
4. Falls kein `leader` nach `reply` (mit timeout): Neustart.

Connected Bully Algorithmus

- N Prozesse $\{P_0 ... P_{N-1}\}$.
- Wenn P_k bemerkt, dass der Koordinator nicht reagiert:
  - Sende WAHL Nachricht an alle Prozesse mit größerer ID ($\{P_{k+1} ... P_{N-1}\}$).
  - Wenn niemand antwortet, gewinnt P_k die Wahl und wird Koordinator.
  - Wenn ein höherer Prozess antwortet, scheidet P_k aus der Wahl aus.
- Ist die Wahl beendet, werden alle Prozesse informiert.

Connected Bully - Beispiel 1

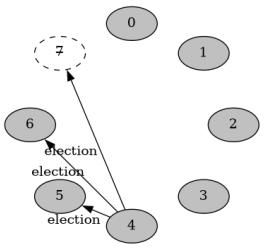

Connected Bully - Beispiel 2

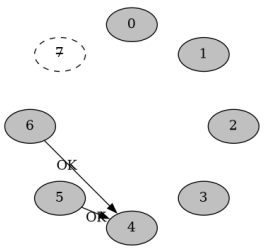

Connected Bully - Beispiel 3

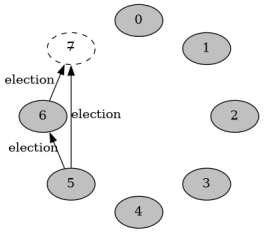

Connected Bully - Beispiel 4

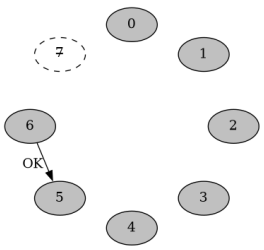

Connected Bully - Beispiel 5

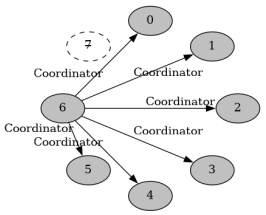

Ring basierte Algorithmen

- Prozesse sind in einem Ring angeordnet
- Wahl starten: WAHL Nachricht an Nachfolger
  - Ausfallende Knoten werden übersprungen
- Verschiedene Algorithmen für lokale Entscheidung, welche ID gesendet wird
- Erreicht einen Knoten die eigene ID, sendet dieser eine COORDINATOR Nachricht um den Ring

Maxima auf Ring-Topologie

- Bully wählt höchste ID auf verbundenem Netz → alle können alle erreichen.
- Auf Ring:
  - unidirektional : Chang-Roberts
  - bidirektional : Franklin
  - unidirektional : Peterson - in O(N log (N))

Maximum auf unidirektionalem Ring nach Chang-Roberts

- Alle starten aktiv
- schicken Token: Prozess-ID.
- verschlucken Token mit niedrigerer ID.
- Wenn sie ein höheres Token erhalten, sind sie nicht das Maximum, leiten weiter.
- Wenn sie ihr eigenes Token erhalten, sind sie das Maximum und schicken ein `leader` token.

Worst case: O(N(N+1)/2) Nachrichten.

Was ist der Worst-Case?

Chang-Roberts: Worst Case

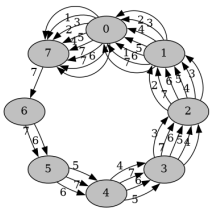

Online-Versuch: Unidirektionaler Chat

- Ich gebe den Bildschirm frei
- Meine Matrix ist die Reihenfolge
- Erzeugt euch eine zufällige ID auf `https://www.random.org/integers/?num=1&min=1&max=100000&col=1&base=10&format=html&rnd=new`
- Schreibt im Chat an die nächste Person in der Reihe
- Wir nutzen Chang-Roberts, um die Person mit der höchsten ID zu finden

Maximum auf Ring nach Franklin

- Wie Chang-Roberts, aber in beide Richtungen.
- In Runden[1]
- Jede Runde wird mindestens die Hälfte der Prozesse inaktiv.

O(log(N)) Runden → Worst-Case: O(N log(N)) Nachrichten.

Was ist der Worst-Case?

[1] Eine Runde: Alle Knoten gehen einen Schritt weiter. Synchronisiert.

Maximum auf Ring nach Peterson

- Schicke jede Runde mein Alias und das meines Vorgängers
- Erhalte jede Runde das Alias meines Vorgängers und des Vor-Vorgängers
- Wenn das Alias meines Vorgängers größer ist als meins und als das des Vor-Vorgängers, nimm das des Vorgängers an und bleibe aktiv.
- Ansonsten werde inaktiv (leite nur noch weiter)
- Zwei Vergleiche pro Runde → wie Franklin!

Worst-Case: O(N log(N)) Nachrichten, Koordinator hat höchstes Alias, aber nicht höchste Prozess-ID — wurde weitergeleitet!

Maximum auf beliebiger Topologie

- Fluten, aber sende nur die höchste erhaltene weiter
- Anzahl Runden aus Netzwerk-Durchmesser (D) → muss bekannt sein!

Anzahl der Nachrichten: O(Δ D)

Delta = maximale Zahl Nachbarn (max degree)./

Koordinator-Wahl in anonymen Netzen

- Braucht Symmetriebruch, z.B. Zufallszahlen
- Beispiel:
  - Wirf eine Münze.
  - Bei Zahl benachrichtige *alle* aktiven Prozesse.
  - Bei Kopf werde passiv. Wenn du keine Nachricht erhältst, werde wieder aktiv und wiederhole.
  - Wenn du aktiv bist und keine Benachrichtigungen erhältst, bist du Koordinator.

Ohne volles Vertrauen an Alle

- Komplexer
- Commit-Reveal-Protokolle
- Konkrete Möglichkeit: Mental Poker

Zusammenfassung Koordinator

- Die Wahl eines Koordinators erleichtert den Algorithmus-Entwurf.
- Je nach Topologie unterschiedliche Algorithmen.
- Petersons Algorithmus erreicht auf einem unidirektionalen Ring die skalierung des Bidirektional, tauscht dafür allerdings IDs aus.
- Netze ohne IDs brauchen Symmetriebrüche.

Ziele für Synchronisierer

- Sie kennen Methoden zur Synchronisierung

Synchronisierer

- Teilen die Berechnung in Diskrete Schritte (ticks).
- Ermöglichen synchrone Algorithmen in asynchronen, verteilten Systemen.
- Nachrichten-Overhead oft durch günstigere Algorithmen ausgeglichen.

Präsenz-Versuch: Zählen mit Koordination

- Schließen Sie bitte die Augen
- Koordinator-Wahl:
  - Ich nenne den Namen der startenden Person
  - Wer startet, nennt Namen Anderer früher im Alphabet
  - Wenn Sie ihren Namen hören, antworten Sie „hier“
  - Wenn niemand früher im Alphabet „hier“ sagt, sagen Sie „Koordinator“
- Zählen:
  - Als Koordinator rufen Sie Leute mit Namen auf, die hochzählen
  - Wir versuchen, bis 10 zu zählen
  - Jede Person darf nur eine Zahl nennen
  - Wenn zwei sich unterbrechen, ist die nächste Zahl wieder 1

Wie lange brauchen wir mit Koordinatorwahl?

Online-Versuch: Smiley-Teppich im Chat

Ziele:

- wir schreiben im jitsi-chat erst alle :-), dann ;-), dann :-D
- möglichst schnell
- alle schreiben, bevor der nächste Smiley kommt
- kein Überlappen

Zeit läuft ab . . .

Aktionen pro Tick

Jeder Prozess kann:

- Berechnungen ausführen
- Nachrichten schicken

Asynchronous bounded delay (ABD)-Synchronisierer

- Braucht Uhren mit ausreichend niedrigem Drift
- Maximalverzögerung von Nachrichten: δ

Ablauf:

- Stelle C auf 0 + sende start(C=0) an Nachbarn
- Starte C=1 erst bei $2 \cdot \delta$.

Awerbuch (α) Synchronisierer

- Funktioniert ohne Uhren und Maximalverzögerung.
- Methode: Nachrichten → Acks → Safe.
- Verschiedene Zeit- und Nachrichtenkomplexität

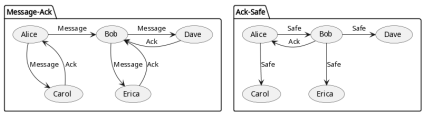

α-Synchronisierer

- Sende Nachrichten <m, i> für Tick i
- Sende <ack, i> für jede empfangene Nachricht und warte auf <ack, i> für jede deiner Nachrichten
- Sende <safe, i> für jeden Nachbar.
- Warte auf <safe, i> von jedem Nachbar.
- Starte Tick i+1

Nachrichtenkomplexität: $M(\alpha) = O(|E|)$.

Zeitkomplexität: $T(\alpha) = 3 \rightarrow$ m, ack, safe.

$|E|$: Die Anzahl der Kanten (edges).

Online-Versuch: Synchronisierte Smileys

- Vollverbundenes Netz (unser Chat)
- Ack: Gleichen Smiley eintragen. Alle Acks empfangen, wenn alle Smileys gepostet sind.
- Safe: Hand heben

Ablauf: :-) → ;-) → :-D

- Trage den ersten oder den selben Smiley ein
- Warte, bis alle anderen den selben Smiley eingetragen haben
- Hebe die Hand
- Wenn alle die Hand oben haben, senke sie wieder => nächster Smiley

Online-Versuch: Ist das genau α?

- Ack für Nachricht — Smiley sehen?
- Safe sehen — alle Smileys sehen?
- Was ist „ich sehe alle Smileys“?

Brauchen wir hier einen vollen α-Synchronisierer?

Asynchrone Komplexität mit Synchronisierer

$$M_A = M_S + T_S \cdot M(A) \quad (1)$$
$$T_A = T_S \cdot T(\alpha) \quad (2)$$

Zusätzliche Nachrichten pro Zeitschritt.

Multiplikator der Zeit.

β-Synchronisierer

- Wähle Koordinator.
- Spanning tree, Koordinator ist Wurzel.
- Koordinator started Tick i mit <next, i> den Baum entlang.
- Knoten senden <m, i> an Zielprozesse.
- Knoten senden und empfangen <ack, i> für Nachrichten.
- Knoten senden <safe, i> an Eltern.
- Koordinator wartet auf <safe, i>, startet dann Tick i+1.

β-Kosten

Nachrichtenkomplexität: $M(\beta) = O(n)$ – statt $|E|$ für α.

Zeitkomplexität: $T(\beta) = \Omega(\log(n))$, worst case: (n-1).

γ-Synchronisierer

- Netz in Cluster aufteilen
- Jeden Cluster hierarchisch via β-Synchronisierer
- Zwischen Clustern α-Synchronisierer

Zusammenfassung Synchronisierer

Synchronisierer ermöglichen die Nutzung der einfacheren synchronen Algorithmen in asynchronen Systemen.

$$\text{Zeit: } T_A = T(x) \cdot T_S \quad (3)$$
$$T(\alpha) = 3 \text{ ; message, ack, safe} \quad (4)$$
$$T(\beta) = O(\mathit{height}) \text{ ; path to root} \quad (5)$$
$$\text{Nachrichten: } M_A = M_S + T_S \cdot M(x) \quad (6)$$
$$M(\alpha) = O(|E|) \quad (7)$$
$$M(\beta) = O(n) \quad (8)$$
$$(9)$$

Zusammenfassung Koordination

- Die Wahl eines **Koordinators** erleichtert den Algorithmus-Entwurf.
- **Synchronisierer** ermöglichen die Nutzung der einfacheren **synchronen Algorithmen** in asynchronen Systemen.

Fehler-Tolerante Systeme

Fehler sind unvermeidbar. Problem: Häufigkeit von Fehlern.

Ziele:

- Sie kennen verschiedene Klassen von Knoten-Defekten
- Sie kennen Eigenschaften von Systemen zur Erkennung von Knotenverlusten
- Sie wissen um selbststabilisierende Algorithmen

Fehler: Definition

Fehler Nicht-erwartetes Verhalten.

Fehlertoleranz Maskiert Fehler oder stellt das erwartete Verhalten wieder her.

Arten von Fehlern

Crash Endet für immer

Auslassung Verliert Nachrichten (omission)

Vorübergehend Verändert den globalen Zustand zufällig (transient)

Byzantinisch Jede vorstellbare Art fehlerhaften Verhaltens

Software Verschiedene Gründe (nächste Folie)

Zeitlich Deadline verpasst

Sicherheit Viren, Trojaner, Würmer, ...

Heisenbugs Nicht verlässlich reproduzierbar

Software-Fehler

Coding/menschlich 23. September 1999 rechnete die NASA die Höhe über dem Mars in Fuß und Metern

Design Vertauschte Prioritäten im Mars pathfinder real-time kernel — Kommunikation verhungerte.

Memleaks Verbraucht Resourcen

Spezifikationsfehler Fehler in Annahmen. Beispiel: Annahme: Ich kann mein Objekt über JSON serialisieren. Realität: JSON-keys sind immer Strings.

```
# python
a = {1: 2}
json.loads(json.dumps(a))
# {'1': 2}
```


Beispiel-Fehler

```
define : faulty-system-1
  define x #t
  while-any
    x : send 'correct
    #t : send 'faulty
```

Scheduler: Schwach fair → Fehler wird garantiert sichtbar.

Fehlertolerante Systeme

Maskierend *Sicherheit + Lebendigkeit* → Flugzeugturbine (kann weiterfliegen)

nicht-maskierend nur Lebendigkeit, Sicherheit zeitweise nicht → GC pause

Fail-safe nur Sicherheit → Raketenstart abbrechen

Graceful degradation Noch akzeptabel → nächste Folie

Beispiele für graceful degradation

- Taxi: ?
- Paketweiterleitung: ?
- Kaffeeautomat: ?
- Dateisystem: ?

Progressive improvement

- Aktuell für Webseiten verwendet
- Umgekehrte graceful degradation
- Erst Basisdienst definieren und implementieren
- Für bestimmte Plattformen bessere Qualität

Fehlertoleranz (Minimal)

Crash Redundanz

Auslassung Bestätigungen → Sequenznummern (TCP!)

Andere Fail-safe + Crash

Zusammenfassung Fehler

- Fehlerhäufigkeit minimieren
- Fehlerarten: Crash, Auslassung, Vorübergehend, Byzantinisch, Software, Zeitlich, Sicherheit, Heisenbugs
- Toleranz: Maskierend, nicht-maskierend, Fail-safe, Graceful degradation

Erkennung von Knotenverlusten

Klassifizierung von Erkennungssystemen zur Analyse.

Vollständigkeit Welche Prozesse werden sicher gefunden?

Korrektheit Gibt es Falschmeldungen? Von wie vielen?

Starke Erkennung

Vollständigkeit Jeder verlorene Prozess wird von allen erkannt

Korrektheit Kein aktiver Prozess wird je verdächtigt

Schwache Erkennung

Vollständigkeit Jeder verlorene Prozess wird von mindestens einem erkannt und bleibt danach verdächtigt

Korrektheit Mindestens ein aktiver Prozess wird nie verdächtigt

Aus schwacher Vollständigkeit lässt sich starke Vollständigkeit rekonstruieren.

Eventually correct

Schwächste Form: Irgendwann gibt es mindestens einen aktiven Prozess, der nicht verdächtigt wird, fehlerbehaftet zu sein.

Aktiver Prozess heißt: Korrekt funktionierender Prozess.

Implementierung

- Üblicherweise Timeouts
- z.B. Heartbeat + Ack

Wieso das ganze?

Klassifizierung der Erkennung, um Algorithmen beweisen zu können.

Zusammenfassung Fehlererkennung

Vollständigkeit Wer weiß was?

Korrektheit Falschmeldungen?

Implementierung Timeouts

PAUSE

Selbststabilisierung

Rückführung auf gültigen Zustand als Teil des Algorithmus.

- Zeitweise Fehler: Stromschlag frisst Token
- Topologie-Änderungen: „Churn“
- Umgebungsänderungen: Morgens gültig, Abends nicht, dazwischen?

Beispiel: Tokenwiederherstellung

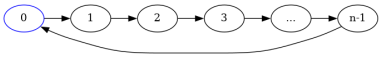

- Sie können durch Zählen ein fehlendes Token erkennen.
- Können Sie Tokenfehler unproblematisch machen?

Beispiel: Tokenwiederherstellung (Algorithmus)

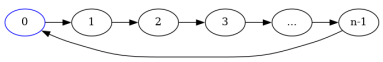


```
define : ring i
  cond
    {i = 0}
      while-any
        {(ref s 0) = (ref s n-1)}
          list-set! s 0 : +1modk (ref s 0)
    else
      while-any
        : not {(ref s i) = (ref s {i - 1})}
          list-set! s i : ref s {i - 1}
```

```
define N 10
define k 11 ; k > N!
define s : make-list N
define n-1 {N - 1}
define : +1modk x
  modulo {x + 1} k
define ref list-ref
```

Dijkstra (1974)

Zusammenfassung Fehler

- Wichtigste **Fehlerarten**: Crash, Auslassung, Byzantinisch.
- Wichtigste **Fehlertoleranz**: Maskierend, nicht-maskierend.
- **Crash-Erkennung**: Klassifiziert nach **Vollständigkeit** und **Korrektheit**
- **Selbststabilisierung**: Korrektur von Fehlern **Teil des Algorithmus**

Konsens

Eine gemeinsame Entscheidung treffen.

Ziele:

- Sie verstehen die Herausforderungen der verteiltem Konsensfindung
- Sie können zwei Beispiele für verteilten Konsens nennen

Bedingungen an einen Algorithmus

(Prozesse: P, nicht-schadhafte: P*):

Endet Alle P* müssen irgendwann entscheiden (termination)

Einigkeit Alle P* entscheiden gleich (agreement)

Gültigkeit Wenn alle P* mit dem gleichen Anfangswert v beginnen, muss die Entscheidung v sein (validity)

Endgültigkeit Nachdem die Entscheidung getroffen ist, bleibt sie für immer

Konsens in asynchronen Systemen

Trivial in fehlerfreien Systemen:

- Verteile alle Einzelentscheidungen
- Wende gleiche Entscheidungsfunktion an

Mit Fehlern wird es spannend.

Garantierte Entscheidung mit Crash unmöglich

- Asynchrones verteiltes System → Beliebige Verzögerungen.
- Zustände mit Zünglein an der Wage (Entscheider).
- Was, wenn das Zünglein zögert?

Es gibt immer einen Entscheider oder eine Entscheiderin, auch wenn oft unbekannt.

In absolut asynchronen Systemen ist ein Crash nicht von Verzögerung unterscheidbar.

Die Byzantinischen Generäle

Konsens in einem synchronen verteilten System mit byzantinischen Fehlern.

- Angriff oder Rückzug?
- Es kann Verräter geben.

Lösung ohne Verräter

- Entscheidungen verteilen
- Identische Entscheidungsfunktion anwenden

Anforderungen an einen Algorithmus mit Verrätern

Kommandant und Lieutnant:

1. Jeder loyale Lieutnant erhält den gleichen Befehl
2. Wenn der Kommandant loyal ist, erhält jeder loyale Lieutnant den Befehl des Kommandanten

Lösung mit Verrätern und Wortnachrichten

- Nachrichten werden nicht korrumpiert
- Nachichten können verloren gehen, aber ihr Fehlen kann erkannt werden
- Bei Erhalt ist die Identität des Senders bekannt

Bei 3 Generälen gibt es keine Lösung mit mündlichen Nachrichten

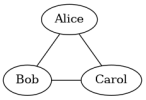

Drei Fälle

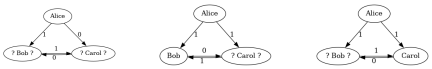

Verallgemeinerung

Für 3 Generäle von denen einer ein Verräter ist gibt es mit verbalen Nachrichten keine Lösung.

Generäle können in gleichgroße Gruppen zusammengefasst werden, mit den Verrätern zusammen in einer Gruppe.

⇒ Bei 3m Generälen und mindestens m Verrätern gibt es keine Lösung.

⇒ $N \geq 3m + 1$

Eine Lösung mit Signaturen

- Ziel der Verräter: Eine Entscheidung verhindern.
- Lösung: Weiterleiten + Mehrheitswahl

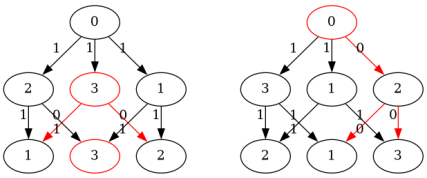

Zusammenfassung Konsens

- Byzantinische Generäle sind ein klassisches Beispiel.
- Mündlichen Nachrichten: Weniger als 1/3tel Verräter.
- Signaturen: Mindestens zwei loyale.
- Störtoleranz über Fehlererkennung prüfbar.

Konkrete Umsetzung: Raft.

Zusammenfassung I

- Koordinator vereinfacht Algorithmen
- Synchronisierer ermöglichen synchrone Algorithmen in asynchronen Systemen
- Fehler: Crash, Auslassung, Byzantinisch
- Toleranz: Maskierend?
- Erkennung: Vollständigkeit, Korrektheit
- Selbststabilisierung
- Konsens: Byzantinische Generäle

Danke!

Verweise I

Ghosh, S. (2015). *Distributed Systems - An Algorithmic Approach*. Computer & Information Science. Chapman & Hall/CRC, 2 edition, ISBN: 978-1466552975.