

Verteilte Systeme – Übung

Replikation: Raft

Sommersemester 2025

Harald Böhm, Christian Berger, Tobias Distler

Friedrich-Alexander-Universität Erlangen-Nürnberg
Lehrstuhl für Informatik 4 (Systemsoftware)

<https://sys.cs.fau.de>



Lehrstuhl für Informatik 4
Systemsoftware



Friedrich-Alexander-Universität
Technische Fakultät

Replikation

- Grundlagen der Replikation

- Raft

Replikation

Grundlagen der Replikation

■ Aktive Replikation

- Alle Replikate bearbeiten alle Anfragen
- Vorteil: Schnelles Tolerieren von Ausfällen möglich
- Nachteil: Vergleichsweise hoher Ressourcenverbrauch

■ Passive Replikation

- Ein Replikat bearbeitet alle Anfragen
- Aktualisierung der anderen Replikate erfolgt über Sicherungspunkte
- Unterscheidung: „Warm passive replication“ vs. „Cold passive replication“
- Vorteil: Minimierung des Aufwands im fehlerfreien Fall
- Nachteil: Im Fehlerfall schlechtere Reaktionszeit als bei aktiver Replikation

■ Replikationstransparenz

- Nutzer auf Client-Seite merkt nicht, dass der Dienst repliziert ist
- Replikatausfälle werden vor dem Nutzer verborgen

■ Zustandslose Dienste

- Keine Koordination zwischen Replikaten notwendig
- Auswahl des ausführenden Replikats z. B. nach Last- oder Ortskriterien

■ Zustandsbehaftete Dienste

- Replikatzustände müssen konsistent gehalten werden
- Beispiel für Inkonsistenzen zweier Replikate R_0 und R_1
 - `incrementAndGet()`-Anfragen A_1 und A_2 von verschiedenen Nutzern
 - Annahme: A_1 erreicht R_0 früher als A_2 , bei R_1 ist es umgekehrt

R_0	Zähler-Speicher
< <i>init</i> >	0
A_1	1
A_2	2


R_1	Zähler-Speicher
< <i>init</i> >	0
A_2	1
A_1	2

→ **Inkonsistente Antworten!**

- Sicherstellung der Replikatkonsistenz
 - Alle Replikate müssen Anfragen in derselben Reihenfolge bearbeiten
 - Protokoll/Dienst zur Erstellung einer Anfragenreihenfolge nötig


■ Weg der Anfrage

- Senden der Anfrage an das Anführer-/Kontaktreplikat
- Verteilen der Anfrage (z. B. durch ein Replikationsprotokoll)



■ Weg der Antwort

- Kontaktreplikat: Rückgabe der Antwort
- Bearbeitung der Anfrage auf allen Replikaten
- Alle anderen Replikate: Speichern/Verwerfen der Antwort, abhängig von der Semantik



Replikation

Raft

- Aktive Replikation einer Anwendung
 - Einigung auf Ausführungsreihenfolge für alle Replikate
 - Zuverlässige, stark konsistente Replikation der entsprechenden Log-Einträge
 - Benötigt $2f + 1$ Replikate, bei bis zu f Ausfällen
- Starker Anführer
 - Im Normalfall
 - Anführer erstellt Log-Einträge anhand von Client-Anfragen
 - Anführer verteilt Log-Einträge per `appendEntries()`-Fernaufruf
 - Anführer gibt replizierte Log-Einträge zur Ausführung frei
 - Anführer beantwortet Anfragen
 - Im Fehlerfall
 - Kandidaten versuchen per `requestVote()` gewählt zu werden
 - Fehlerhafter Anführer muss ersetzt werden, bevor neue Anfragen verarbeitet werden können
- Im Folgenden werden nur ausgewählte Aspekte von Raft betrachtet



D. Ongaro and J. Ousterhout

In Search of an Understandable Consensus Algorithm

Proceedings of the USENIX Annual Technical Conference (USENIX ATC'14), p. 305–319, 2014

- Fragestellung: Wie setzt man einen Anführer ab?
 - Alter Anführer soll nach dem Absetzen keinen Einfluss mehr haben
 - Keine gemeinsame Zeitbasis zwischen Replikaten
 - Replikate können dem alten oder neuen Anführer folgen
 - Anführer könnte noch nicht von eigener Absetzung erfahren haben
- Alle Fernaufrufe und deren Rückgabewerte in Raft enthalten Term
 - Term = „Regentschaft“
 - Neuer Anführer hat höheren Term als alle vorherigen Anführer
 - Hochzählen bei jeder Anführerwahl
- Term nutzen, um alte Fernaufrufe auszusortieren
 - Fernaufruf-Empfänger erhält Aufruf mit **neuem** Term
 - *Empfänger wechselt* in neuen Term und wird zum Follower (Anführer ggf. noch unbekannt)
 - Fernaufruf mit dem neuen Term ausführen
 - Fernaufruf-Empfänger erhält Aufruf mit **altem** Term
 - Empfänger lehnt Fernaufruf ab und gibt neuen Term zurück
 - *Absender wechselt* in den neuen Term und wird zum Follower (Anführer ggf. noch unbekannt)

- Randomisiertes Timeout für Anführerwahl
 - Zufälliger Wert zwischen $t_{wahl}/2$ und t_{wahl} , wobei t_{wahl} = Election Timeout
 - Möglichst nur ein Replikat soll auf einmal ins Timeout laufen
 - **Wichtig:** Timeout muss nach jeder Anführerwahl neu gewürfelt werden
- Anführerwahl-Timeout löst immer wieder aus, solange kein Anführer dies verhindert
 - Timeout zurücksetzen durch `requestVote()` bzw. Heartbeats mittels `appendEntries()`
 - Anführer muss Heartbeats an alle Replikate innerhalb von Timeout senden
 - Abgetrennte Replikate wechseln laufend in höheren Term

→ Bei Wiederbeitritt springen alle anderen Replikate in den höheren Term
- Ein Replikat kann Follower werden, ohne zu wissen wer aktuell der Leader ist
 - Beispiel: Replikat erhält `requestVote()`-Fernaufruf für neueren Term
 - Replikat wechselt als Follower in neuen Term
 - Hier gibt es noch **keinen** Anführer
- `appendEntries()` informiert über aktuellen Anführer

- Relevanter Teil des Replikatzustands

 - `nextIndex[]` Index des nächsten an Replikat zu übertragenden Log-Eintrags

 - `matchIndex[]` Index des höchsten erfolgreich replizierten Log-Eintrags

 - Log des Anführers und Replikat i identisch bis inklusive `matchIndex[i]`

 - `commitIndex` Index des höchsten zur Ausführung freigegebenen Log-Eintrags

 - `lastApplied` Index des höchsten ausgeführten Log-Eintrags

- Replikation von Log-Einträgen entsprechend `nextIndex[]` mittels `appendEntries()`

 - Bei Erfolg: `nextIndex[]` und `matchIndex[]` aktualisieren
 - Anführer muss eigenen Eintrag selbst anpassen
 - Bei Anführerwechsel: `nextIndex[]` auf Log-Ende setzen, `matchIndex[]` auf 0

- Anführer passt `commitIndex` nach Änderungen an `matchIndex[]` an


- Committede Log-Einträge ausführen

 - Bereich zwischen `lastApplied` und `commitIndex`
 - Je nach Implementierung genügt der `commitIndex`

- Problem: Ausgefallenes / Zurückhängendes Replikat aktualisieren
 - Replikat muss fehlende Log-Einträge erhalten und verarbeiten
 - **Hoher Aufwand**: Schlimmstenfalls notwendig alle Log-Einträge seit Systemstart zu übertragen
 - **Hoher Speicherverbrauch**: Log wird beliebig groß

- Sicherungspunkt

- Enthält Kopie des Anwendungszustands nach Ausführen eines Log-Eintrags
- Enthält Log-Index des zuletzt verarbeiteten Log-Eintrags
- Zusammenfassung aller vom Sicherungspunkt abgedeckten Log-Einträge



- Zustand im Sicherungspunkt entspricht exakt dem Zustand nach Ausführen aller Log-Einträge bis zum Sicherungspunkt
 - **Begrenzter Aufwand**: Replikate können mit Sicherungspunkt aktualisiert werden und weite Teile des Logs überspringen
 - **Begrenzter Speicherverbrauch**: Frühere Log-Einträge können gelöscht werden

Snapshot-Erstellung und -Übertragung in Raft

- Analog zu erweiterter Version des Raft-Papiers, siehe </proj/i4vs/pub/aufgabe5>
- Snapshot-Erzeugung
 - Jedes Replikat erstellt Snapshot wenn Log groß genug (z.B. nach jeweils 10 verarbeiteten Anfragen)
 - Snapshot enthält Anwendungszustand, Log-Index und -Term
 - Alle früheren Log-Einträge und Snapshots löschen
- Snapshot-Übertragung
 - Versand an zurückhängendes Replikat per `installSnapshot`-Fernaufruf

```
int installSnapshot(int term, int leaderId,  
                   long lastIncludedIndex, int lastIncludedTerm, Serializable data)
```

`term, leaderId` aktueller Term und Anführer

`lastIncluded{Index, Term}` neuster im Snapshot enthaltener Log-Eintrag

`data` Anwendungszustand im Snapshot

Rückgabewert neuster dem Empfänger bekannter Term

↪ In der Übung: Anders als im Papier soll der Anwendungszustand **auf einmal** übertragen werden

- Ablauf
 - Leader überträgt Snapshot, wenn ein bereits gelöschter Log-Eintrag benötigt würde
 - Empfänger speichert Snapshot und spielt diesen in Anwendung ein
 - Snapshot speichern für den Fall, dass Empfänger zum Anführer wird