Middleware – Cloud Computing – Übung

Aufgabe 6: ZooKeeper

Wintersemester 2022/23

Laura Lawniczak, Tobias Distler, Ines Messadi

Friedrich-Alexander-Universität Erlangen-Nürnberg
Lehrstuhl Informatik 4 (Verteilte Systeme und Betriebssysteme)
https://sys.cs.fau.de

Lehrstuhl für Verteilte Systeme
und Betriebssysteme

FRIEDRICH-ALEXANDER
UNIVERSITÄT
ERLANGEN-NÜRNBERG

TECHNISCHE FAKULTÄT

Überblick

ZooKeeper

Apache ZooKeeper

Apache ZooKeeper

- **Koordinierungsdienst** für verteilte Systeme
  - Anfangs entwickelt bei Yahoo! Research, jetzt Apache-Projekt
  - Im Produktiveinsatz unter anderem für:
    - Anführerwahl: z. B. Apache HDFS
    - Konfigurationsdaten: z. B. Kafka
- Verwaltung von Daten
  - **Hierarchischer Namensraum**: Knoten in einer Baumstruktur
  - Knoten sind eindeutig identifizierbar und können Nutzdaten aufnehmen
  - **Keine expliziten Sperren (Locks)**, aber Gewährleistung bestimmter Ordnungen bei konkurrierenden Zugriffen
- **Fehlertoleranz**
  - Replikation des Diensts auf mehrere Rechner (Replikate)
  - Replikatkonsistenz mittels Leader-Follower-Ansatz
  - Leseoptimierung: Jedes Replikat kann Leseanfragen beantworten
- Literatur

Patrick Hunt, Mahadev Konar, Flavio P. Junqueira, and Benjamin Reed
ZooKeeper: Wait-free coordination for Internet-scale systems
Proc. of the 2010 USENIX Annual Technical Conf. (ATC '10), S. 145–158, 2010.

Schnittstelle

- Zentrale Operationen
  - `create` / `delete` — Erstellen / Löschen eines Knotens
  - `exists` — Prüfen auf Existenz eines Knotens
  - `setData` / `getData` — Setzen und Auslesen der Nutzdaten und Metadaten eines Knotens
  - `getChildren` — Rückgabe der Pfade von Kindknoten eines Knotens
  - `sync` — Warten auf die Bearbeitung aller vorherigen Schreiboperationen
- **Persistente Knoten** (*Regular Nodes*)
  - Erzeugung durch den Client
  - Explizites Löschen durch den Client
- **Flüchtige Knoten** (*Ephemeral Nodes*)
  - Erzeugung durch den Client unter Angabe des `EPHEMERAL`-Flag
  - Keine Kindknoten
  - Löschen
    - Automatisches Löschen durch den Dienst, sobald die Verbindung zum Client, der diesen Knoten erstellt hat, beendet wird oder abbricht

    → Anwendungsbeispiel: Erkennen eines Client-Ausfalls
    - Explizites Löschen durch den Client
- **Sequenzielle Knoten** (*Sequential Nodes*) [Siehe Vorlesung]

Verwaltung von Nutzdaten

- Grundprinzipien [→ Unterschiede zu Dateisystemen]
  - Jeder Knoten kann Nutzdaten aufnehmen
    - Speicherung von Nutzdaten ist nicht auf Blattknoten des Baums beschränkt
    - Kleine Datenmengen, üblicherweise $< 1\,\text{MB}$ pro Knoten
  - Daten werden atomar geschrieben und gelesen
    - {S,Ers}etzen der kompletten Nutzdaten eines Knotens beim Schreiben
    - Kein partielles Lesen der Nutzdaten
- **Versionierung** der Nutzdaten
  - Schreiben neuer Daten → Inkrementierung der Knoten-Versionsnummer
  - Bedingtes Schreiben von Nutzdaten

    ```
    public Stat setData(String path, byte[] data, int version);
    ```

    - Speicherung der Nutzdaten `data` nur, falls die aktuelle Versionsnummer des Knotens dem Wert `version` entspricht
    - Schreiben ohne Randbedingung: `version = -1` setzen
  - Kein Zugriff auf ältere Versionen möglich

Verwaltung von Metadaten

- Verwaltete Metadaten eines Knotens
  - Zeitstempel der Erstellung
  - Zeitstempel der letzten Modifikation
  - Versionsnummer der Nutzdaten
  - Größe der Nutzdaten
  - Anzahl der Kindknoten
  - Bei flüchtigen Knoten: ID der Verbindung des ZooKeeper-Clients, der den Knoten erstellt hat (*Ephemeral Owner*)
  - ...
- Abruf der Metadaten eines Knotens
  - Kapselung in einem Objekt der Klasse `Stat`
  - Nur in Kombination mit dem Lesen der Nutzdaten möglich
- Implementierungsentscheidung
  - Nutz- und Metadaten werden komplett im Hauptspeicher gehalten
  - Keine Strategie für den Fall, dass der Hauptspeicher voll ist

Benachrichtigung über Ereignisse

- Problemstellung
  - Client wartet darauf, dass ein bestimmtes Ereignis eintritt
  - Aktives Nachfragen durch den Client ist im Allgemeinen nicht effizient
- **Beobachter** (*Watcher*)
  - Registrierung bei Leseoperationen (muss ggf. erneuert werden!)
  - Ereignisarten
    - Erstellen / Löschen oder Ändern der Nutzdaten eines Knotens (`exists`)
    - Ändern der Nutzdaten oder Löschen eines Knotens (`getData`)
    - Hinzukommen oder Wegfallen von Kindknoten (`getChildren`)
  - Aufruf durch ZooKeeper-Dienst bei Eintritt bestimmter Ereignisse
- Schnittstelle für Beobachter-Objekte

```
public interface Watcher {
    public void process(WatchedEvent event);
}
```

ZooKeeper

Aufgabe 6

Aufgabe 6

- Umsetzung eines Koordinierungsdienstes
  - ZooKeeper-Implementierung von Apache als Vorbild
  - Funktionen zum Erstellen, Löschen, Schreiben und Lesen von Knoten

  ⇒ Bedingtes und unbedingtes Schreiben anhand von Versionsnummer

- Vereinfachte Schnittstelle

```
public String create(String path, byte[] data, boolean ephemeral);
public void delete(String path, int version);
public MWZooKeeperStat setData(String path, byte[] data, int version);
public byte[] getData(String path, MWZooKeeperStat stat);
```

- Teilaufgaben
  - Implementierung als Client-Server-Anwendung
  - Zustandsverwaltung inklusive **Leseoptimierung** von ZooKeeper

  ↪ Hilfestellung: Tests für Teilfunktionalitäten in `MWZooKeeperImplTest` bereitgestellt
  - **Konsistente, passive Replikation** unter Zuhilfenahme von Zab
  - Unterstützung flüchtiger Knoten (optional für 5,0 ECTS)

Ausgabeparameter in Java

- Problem
  - Methode (z. B. `getData()`) soll mehr als ein Objekt zurückgeben
  - Nur ein „echter“ Rückgabewert möglich
- Lösungsmöglichkeiten
  - Einführung eines Hilfsobjekts, das mehrere Rückgabewerte kapselt
  - Verwendung von **Ausgabeparametern**
- Beispiel für Ausgabeparameter: ZooKeeper-Methode `getData()`
  - Aufruf: Übergabe eines „leeren“ Parameters

```
MWZooKeeper zooKeeper = new MWZooKeeper([...]);
MWZooKeeperStat stat = new MWZooKeeperStat(); // Leeres Objekt
zooKeeper.getData("/example", stat);
System.out.println("Version: " + stat.getVersion());
```

  - Intern: Setzen von Attributen des Ausgabeparameters

```
public byte[] getData(String path, MWZooKeeperStat stat) {
    [...] // Bestimmung der angeforderten Daten
    stat.setVersion(currentVersion);
    [...] // Setzen weiterer Attribute und Daten-Rueckgabe
}
```

Serialisierung & Deserialisierung von Objekten

- Serialisierung & Deserialisierung in Java
  - Objekte müssen das Marker-Interface `Serializable` implementieren
  - {S,Des}erialisierung mittels `Object{Out,In}putStream`-Klassen
- Beispiel: Deserialisierung von Anfragen

```
// Einmaliges Anlegen des Objekt-Stroms
Socket s = [...]; // Socket der Verbindung
ObjectInputStream ois = new ObjectInputStream(s.getInputStream());

while(true) {
    // Empfang und Deserialisierung einer Anfrage
    MWZooKeeperRequest request = (MWZooKeeperRequest) ois.readObject();
    [...] // Bearbeitung der Anfrage
}
```

- **Wichtige Hinweise** zum Einsatz von Object-Streams:
  - Der Konstruktor eines `ObjectInputStream` blockiert, bis auf der anderen Seite ein `ObjectOutputStream` geöffnet wurde $\Rightarrow$ Bei Deadlock Reihenfolge beachten.
  - Object-Streams in Java **puffern Objekte**. Bei Wiederverwendung von Objekten können daher alte Daten übermittelt werden, wenn der Puffer nicht mit `reset()` geelert wird.

Replikation

Konsistenzwahrung

Konsistenzwahrung

- Replikation einer zustandsbehafteten Anwendung
  - Replikatzustände müssen konsistent gehalten werden
  - Beispiel für inkonsistente Zustände zweier Replikate R_1 und R_2
    - Zwei Anfragen A_1 und A_2, die einem Knoten /node neue Daten zuweisen

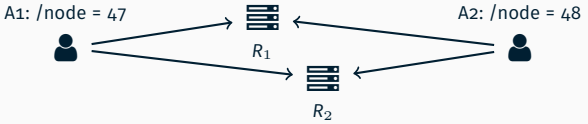

    - Annahme: A_1 erreicht R_1 früher als A_2, bei R_2 ist es umgekehrt

R_1	/node-Daten
$< init >$	$\emptyset$
A_1	47
A_2	48 ↯

R_2	/node-Daten
$< init >$	$\emptyset$
A_2	48
A_1	47 ↯

- Sicherstellung der **Replikatkonsistenz**: Alle Replikate vollziehen Zustandsänderungen in derselben Reihenfolge
- Replikationsvarianten
  - Aktiv: Anfragen an alle Replikate verteilen und dort ausführen
  - **Passiv (Zookeeper)**: Anführer bearbeitet Anfragen und verteilt Zustandsänderungen

Replikation in ZooKeeper

- Gruppe von ZooKeeper-Replikaten
  - $2f + 1$ Replikate zur Tolerierung von höchstens f Fehlern bzw. Ausfällen
  - Jedes Replikat nimmt Verbindungen von Clients an
- Leader-Follower-Ansatz für stark konsistente Schreibanfragen
  - Follower leitet Anfrage an den Leader weiter
  - Leader bearbeitet Anfrage und schreibt **Änderungen** in **Zustandstransaktion**
  - Fehlerfall: Erstellung einer Fehlertransaktion [Bsp.: Zu löschender Knoten existiert nicht.]
  - Total Order Broadcast verteilt Transaktionen in vom Leader vorgegebener Reihenfolge
  - Transaktionsauslieferung erst nach Bestätigung durch Mehrheit der Replikate
  - Konsistente Ausführung ausgelieferter Transaktionen auf allen Replikaten

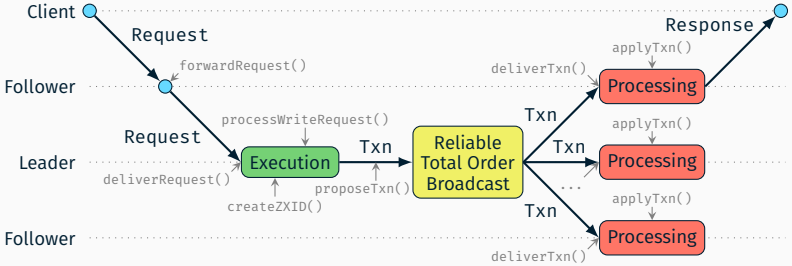

Anfrageverarbeitung

Zustand des Anführers

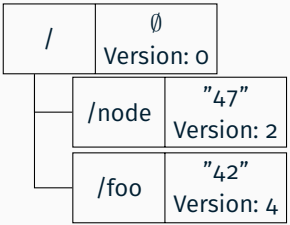

Zustand eines Followers

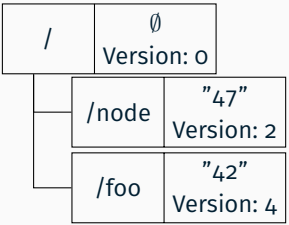

Anfrage	Transaktion	Antwort an Client
Client A: `setData("/node", "47", 1)`	/node, "47", Version: 2	✔
Client B: `setData("/node", "48", 1)`	/node, ϟ	ϟ

⚠ Das Beispiel wird im zugehörigen Video besprochen

Optimierung für lesende Anfragen

- Einsicht: Leseanfragen haben keinen Einfluss auf Replikatkonsistenz
- Optimierte Bearbeitung lesender Anfragen in ZooKeeper
  - Ausschließlich durch direkt mit Client verbundenem Replikat
  - Sofort nach Erhalt, d. h. unabhängig von schreibenden Anfragen
  - Aber: Unter Garantie von FIFO für sämtliche Anfragen eines Clients
- Vorteile
  - Einsparung von Ressourcen
  - Kürzere Antwortzeiten
- Konsequenzen
  - Antworten auf Leseanfragen sind abhängig vom bearbeitenden Replikat
  - Rückgabe von „veralteten“ Daten und Versionsnummern möglich
- `sync()`-Methode
  - Erzwingen eines Synchronisationspunkts
  - Wartet bis alle vor dem `sync()` empfangenen Anfragen bearbeitet wurden

Zustandsverwaltung im Anführer

- Problemstellung
  - Leseanfragen dürfen nur konsistenten, bestätigten Zustand zurückgeben
  - $\Rightarrow$ Unbestätigte Zustandsänderungen könnten im Fehlerfall noch verloren gehen
  - Schreibanfragen müssen aber auf aktuellem, unbestätigtem Zustand arbeiten
  - $\Rightarrow$ Anführer muss beide Zustände gleichzeitig verwalten
- Effizienter Lösungsansatz
  - **Bestätigter Zustand** Z_B
    - Verwaltung des vollständigen Baumes von Datenknoten
    - Aktualisierung durch Einspielen bestätigter, total geordneter Transaktionen
    - Grundlage für die Bearbeitung rein lesender Anfragen
  - **Aktueller Zustand** Z_A
    - Verwaltung in Form einer Sammlung von gegenüber Zustand Z_B geänderten Knoten
    - Modifikation durch Bearbeitung von schreibenden Anfragen
    - Basis für die Erstellung von Zustandstransaktionen
- Mechanismus zur Garbage-Collection
  - Vergabe eindeutiger IDs (`zxids`) an Zustandsänderungen/-transaktionen
  - Einspielen einer Transaktion $\rightarrow$ Löschen der unbestätigten Änderung

Anfrageverarbeitung ohne aktuellen Zustand

Zustand des Anführers

Bestätigt

/	∅ Version: 0
/node	"48" Version: 2
/foo	"42" Version: 4

Aktuell

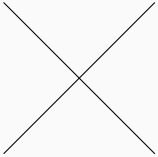

Anfrage	Transaktion	Antwort an Client
Client A: `setData("/node", "47", 1)`	/node: "47", Version: 2	✔
Client B: `setData("/node", "48", 1)`	/node: "48", Version: 2	✔

⚠ Das Beispiel wird im zugehörigen Video besprochen

Anfrageverarbeitung mit aktuellem Zustand

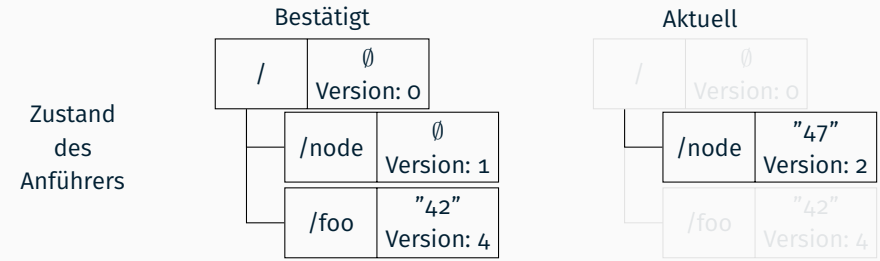

Anfrage	Transaktion	Antwort an Client
Client A: `setData("/node", "47", 1)`	/node, "47" Version: 2	
Client B: `setData("/node", "48", 1)`	/node, ϟ	

⚠ Das Beispiel wird im zugehörigen Video besprochen

Garbage-Collection von Transaktionen

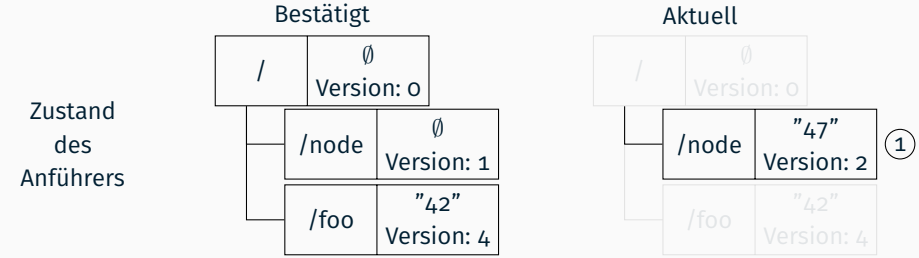

Anfrage	Transaktion	Antwort an Client
Client A: `setData("/node", "47", 1)`	/node ”47” Version: 2	1
Client B: `setData("/node", "48", 1)`	/node ↯	2

⚠ Das Beispiel wird im zugehörigen Video besprochen

Replikation

Zab

- Protokoll für zuverlässigen und geordneten Nachrichtenaustausch
  - Von Apache ZooKeeper verwendet, aber nicht modular integriert
  - Nachträgliche eigenständige Implementierung als *Zab*
  - Modifikation zur Anpassung an die Übungsaufgabe
  - *Übungsfolien sind Dokumentation* der modifizierten Bibliothek
- *Totally Ordered Broadcast Protocol* mit zwei Betriebsmodi
  - **Normalbetrieb** (*Broadcast*)
    - Bereitstellen einer eindeutigen **Sequenznummer** (`zxid`) für jede Transaktion
    - Zuverlässige Verteilung aller Zustandstransaktionen in Reihenfolge der Sequenznummern
  - **Wahl eines neuen Anführers** (*Recovery*)
    - Szenarien: Ausfall des Anführers, Anführer hat keine Mehrheit mehr
    - Sicherstellung der Eindeutigkeit von Sequenznummern
- Literatur

Benjamin Reed and Flavio P. Junqueira

A simple totally ordered broadcast protocol

Proceedings of the 2nd Workshop on Large-Scale Distributed Systems and Middleware, pages 1-6, 2008.

- Repräsentation eines Zab-Knotens in der abstrakten Basisklasse `Zab`
- Varianten von Zab-Teilnehmern
  - `SingleZab` Einzelne (lokale) Instanz, zum Testen
  - `MultiZab` Teil einer verteilten Gruppe aus mindestens 3 Replikaten
- Methoden

```
public void startup();
public void shutdown();
public void forwardRequest(Serializable request);
public long createZXID();
public void proposeTxn(Serializable txn, long zxid);
```

  - `startup()` Starten eines Zab-Knotens
  - `shutdown()` Stoppen eines Zab-Knotens
  - `forwardRequest()` Weiterleiten einer Anfrage an den Anführer
  - `createZXID()` Anfordern der nächsten Sequenznummer (`zxid`)
  - `proposeTxn()` Vorschlagen einer zu ordnenden Transaktion
    → Aufruf muss in Reihenfolge der `zxid`s erfolgen
    → `createZXID()` und `proposeTXN()` immer als Paar aufrufen

[Hinweis: Da Zab in den ersten 4 Bytes einer `zxid` eine Epochennummer codiert, führt eine Neuwahl des Anführers zu einem Sprung in den von `createZXID()` erzeugten `zxid`-Werten.]

- Empfang von Nachrichten über die Schnittstelle `ZabCallback`
- Methoden

```
public void deliverRequest(Serializable request);
public void deliverTxn(Serializable txn, long zxid);
public void status(ZabStatus status, String leader);
```

  - `deliverRequest()` Übergabe einer dem Anführer weitergeleiteten Anfrage
  - `deliverTxn()` Zustellung der nächsten geordneten Transaktion
  - `status()` Benachrichtigung über Änderungen des Status
- Status eines Zab-Knotens (`ZabStatus`)
  - `LOOKING` Temporärer Zustand während der Anführerwahl
  - `FOLLOWING` Lokales Replikat ist Follower
  - `LEADING` Lokales Replikat ist Anführer
- Hinweise
  - Aufrufe von `deliverRequest()` können nebenläufig erfolgen
  - Geordnete Transaktionen werden dagegen durch Zab sequentiell zugestellt
  - Alle von einer Mehrheit ($f + 1$) der $2f + 1$ Replikate bestätigten Transaktionen werden auf allen korrekten Replikaten zugestellt

- Übergabe eines `Properties`-Objekts an den `Zab`-Konstruktor
- Parameter
  - `myid` ID des lokalen Replikats
  - `peer<i>` Zab-Adresse des Replikats *i*
  - ...
- Identische Konfiguration der `peer<i>`-Adressen auf allen Replikaten nötig
- Beispielkonfiguration eines `MultiZab`-Knotens (insgesamt 3 Replikate)
  - Zusammenstellung der Konfiguration für ein Replikat mit der ID 1

```
Properties zabProperties = new Properties();
zabProperties.setProperty("myid", String.valueOf(1));
zabProperties.setProperty("peer1", "localhost:12345");
zabProperties.setProperty("peer2", "localhost:12346");
zabProperties.setProperty("peer3", "localhost:12347");
```

  - Initialisierung eines Zab-Knotens

```
ZabCallback zabListener = [...];
Zab zabNode = new MultiZab(zabProperties, zabListener);
```

- Zab verwendet intern die Logging-API *log4j*
  - Konfiguration z.B. durch eine Datei `log4j2.properties`, die im Classpath abgelegt sein muss
  - Granularitätsstufen: `OFF`, `ERROR`, `WARN`, `INFO`, `DEBUG`, `ALL`, ...
  - Dokumentation unter:
    `https://logging.apache.org/log4j/2.x/manual/configuration.html`
- Beispiele für log4j-Konfigurationen
  - Ausgabe der Log-Meldungen auf der Konsole (Stufe: `DEBUG`)

```
rootLogger = DEBUG, CONSOLE
appender.CONSOLE.name = CONSOLE
appender.CONSOLE.type = Console
appender.CONSOLE.layout.type = PatternLayout
```

  - Ausgabe der Log-Meldungen in der Datei `zab.log` (Stufe: `INFO`)

```
rootLogger=INFO, FILE
appender.FILE.name = FILE
appender.FILE.type = File
appender.FILE.fileName = zab.log
appender.FILE.layout.type = PatternLayout
```