Middleware - Cloud Computing – Übung

Klaus Stengel, Johannes Behl, Tobias Distler,
Tobias Klaus, Christopher Eibel

Friedrich-Alexander-Universität Erlangen-Nürnberg
Lehrstuhl Informatik 4 (Verteilte Systeme und Betriebssysteme)

www4.cs.fau.de

Wintersemester 2013/14

Überblick

ZooKeeper
- Einführung
- Konsistenzwahrung in ZooKeeper
- Aufgabe 5

Apache ZooKeeper

- **Fehlertoleranter Koordinierungsdienst** für verteilte Systeme
  - Anfangs entwickelt bei Yahoo! Research, jetzt Apache-Projekt
  - Im Produktiveinsatz (z. B. bei Yahoo und Facebook (Cassandra))
- Verwaltung von Daten
  - **Hierarchischer Namensraum**: Knoten in einer Baumstruktur
  - Knoten sind eindeutig identifizierbar und können Nutzdaten aufnehmen
  - **Keine expliziten Sperren oder Transaktionen**, aber Gewährleistung bestimmter Ordnungen bei konkurrierenden Zugriffen
- Fehlertoleranz
  - Replikation des Diensts auf mehrere Rechner
  - Replikatkonsistenz mittels Leader-Follower-Ansatz
- Literatur

Patrick Hunt, Mahadev Konar, Flavio P. Junqueira, and Benjamin Reed
ZooKeeper: Wait-free coordination for Internet-scale systems
Proceedings of the 2010 USENIX Annual Technical Conference, 2010.

Schnittstelle

- Zentrale Operationen
  - `create` Erstellen eines Knotens
  - `exists` Überprüfung, ob ein Knoten existiert
  - `delete` Löschen eines Knotens
  - `setData` Setzen der Nutzdaten eines Knotens
  - `getData` Auslesen der Nutz- und Metadaten eines Knotens
  - `getChildren` Rückgabe der Pfade von Kindknoten eines Knotens
  - `sync` Warten auf die Bearbeitung aller vorherigen zustandsmodifizierenden Operationen (siehe später)
- Aufrufvarianten
  - Synchron
  - Asynchron
- ZooKeeper-API (Version 3.4.5)

  `http://hadoop.apache.org/zookeeper/docs/r3.4.5/api/`

Kategorien von Datenknoten

- **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
  - Löschen
    - Explizites Löschen durch den Client
    - Automatisches Löschen durch den Dienst, sobald die Verbindung zum Client, der diesen Knoten erstellt hat, beendet wird oder abbricht
  - Anwendungsbeispiel: Benachrichtigung über Knotenausfall
- **Sequenzielle Knoten** (*Sequential Nodes*)
  - Erzeugung durch den Client unter Angabe des `SEQUENTIAL`-Flag
  - Automatische Erweiterung des Knotennamens um eine vom System vergebene Sequenznummer
  - Anwendungsbeispiel: Herstellung einer Ordnung auf Clients

[Hinweis: Das `EPHEMERAL`- und das `SEQUENTIAL`-Flag sind miteinander kombinierbar]

Verwaltung von Nutzdaten

- Grundprinzipien [→ Unterschiede zu Dateisystemen]
  - Jeder Knoten kann Nutzdaten aufnehmen
    - Kleine Datenmengen, üblicherweise $< 1\,\text{KB}$ pro Knoten
    - „Verzeichnisknoten“ (also Knoten mit Kindknoten) können ebenfalls Nutzdaten direkt aufnehmen
  - 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);
```

    - Nutzdaten `data` werden nur geschrieben, falls die aktuelle Versionsnummer des Knotens `version` entspricht („test and set“)
    - 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*)
  - ...
- Kapselung der Metadaten eines Knotens in einem Objekt der Klasse `org.apache.zookeeper.data.Stat`
- 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
- **Wächter** (*Watches*)
  - Umsetzung von Rückrufen (*Callbacks*) in ZooKeeper
  - Aufruf durch ZooKeeper-Dienst bei Eintritt bestimmter Ereignisse
  - Registrierung bei Leseoperationen (muss ggf. erneuert werden!)
  - Ereignissarten:
    - Erstellen oder Löschen eines Knotens (`exists`)
    - Änderung der Nutzdaten eines Knotens (`getData`)
    - Hinzukommen oder Wegfall von Kindsknoten (`getChildren`)
- Schnittstelle für Wächter-Objekte

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

Anwendungsbeispiel: Wahl eines Anführers

- Problemstellung
  - In einer Gruppe von ZooKeeper-Clients soll ein Anführer gewählt werden
  - Bei Ausfall des Anführers muss ein neuer Anführer bestimmt werden
- Umsetzung
  - Erstellen eines „Verzeichnisknotens“ `/leader` für die Gruppe

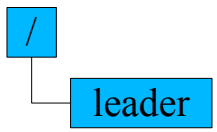

  - Vorgehensweise beim Hinzukommen eines neuen Clients
    - Erstellen eines flüchtigen Kindknotens `/leader/node-<Sequenznummer>`
    - Suche nach Kindknoten mit kleineren Sequenznummern
    - Existiert kein Kindknoten mit kleinerer Sequenznummer → Client ist *Leader*
    - Sonst: Client ist *Follower* → Setzen eines Watch auf den Kindknoten mit der nächstkleineren Sequenznummer
  - Bei Knotenausfall
    - Automatische Löschung des zugehörigen flüchtigen Knotens
    - Genau ein Client wird per Watch über den Ausfall benachrichtigt

Anwendungsbeispiel: Wahl eines Anführers

Beispielablauf

- Client 1 kommt neu zur Gruppe hinzu
  - Erstellen eines flüchtigen Kindknotens `/leader/node-1`
  - Client 1 wird zum Leader, da sein Kindknoten die kleinste Sequenznummer aufweist [bzw. in diesem Fall keine weiteren Kindknoten vorhanden sind]

Anwendungsbeispiel: Wahl eines Anführers

Beispielablauf

- Client 2 kommt neu zur Gruppe hinzu
  - Erstellen eines flüchtigen Kindknotens `/leader/node-2`
  - Client 2 wird zum Follower
  - Client 2 setzt Watch auf Kindknoten mit nächstkleinerer Sequenznummer ($\rightarrow$ `/leader/node-1`)

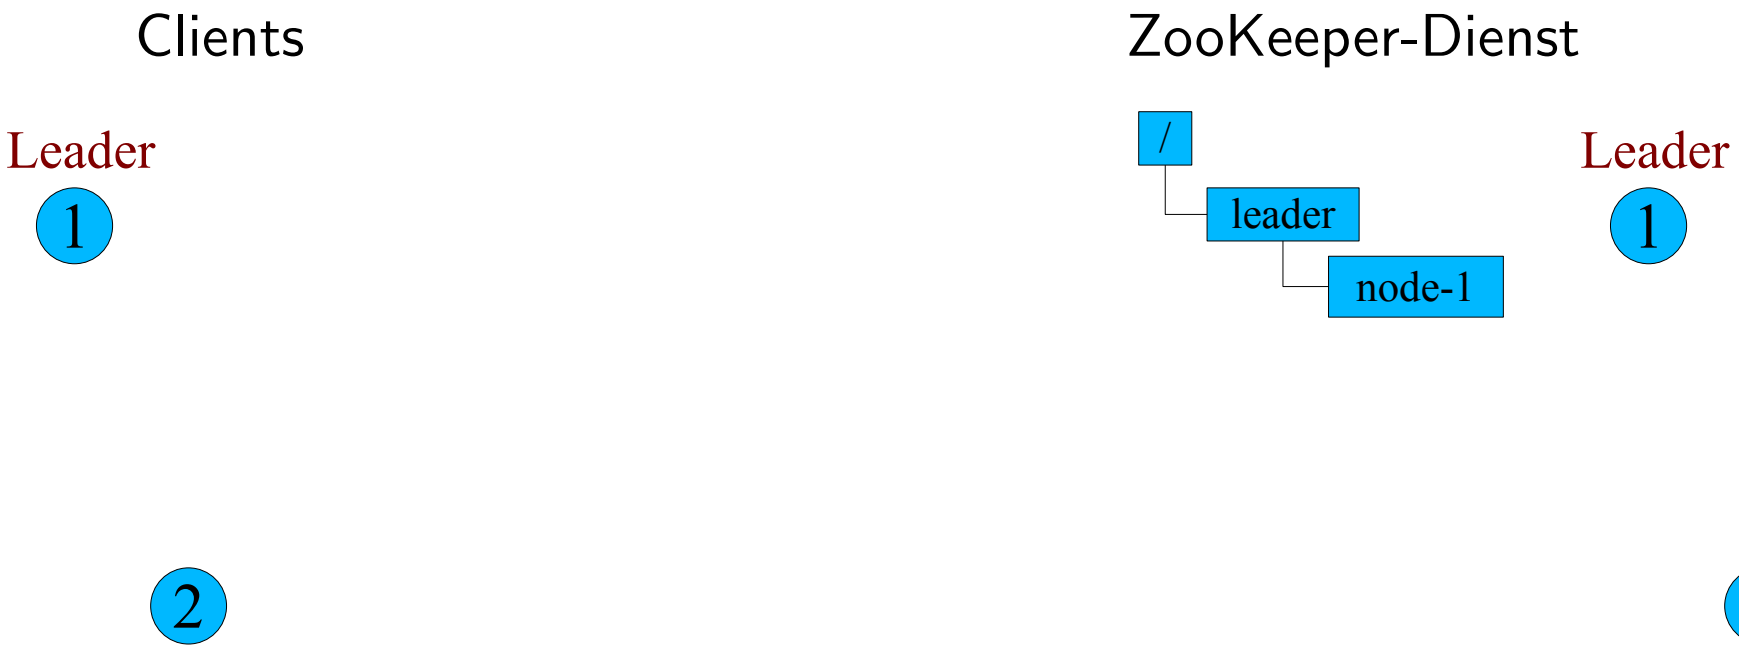

Anwendungsbeispiel: Wahl eines Anführers

Beispielablauf

- Client 3 kommt neu zur Gruppe hinzu
  - Erstellen eines flüchtigen Kindknotens `/leader/node-3`
  - Client 3 wird zum Follower
  - Client 3 setzt Watch auf Kindknoten mit nächstkleinerer Sequenznummer ($\rightarrow$ `/leader/node-2`)

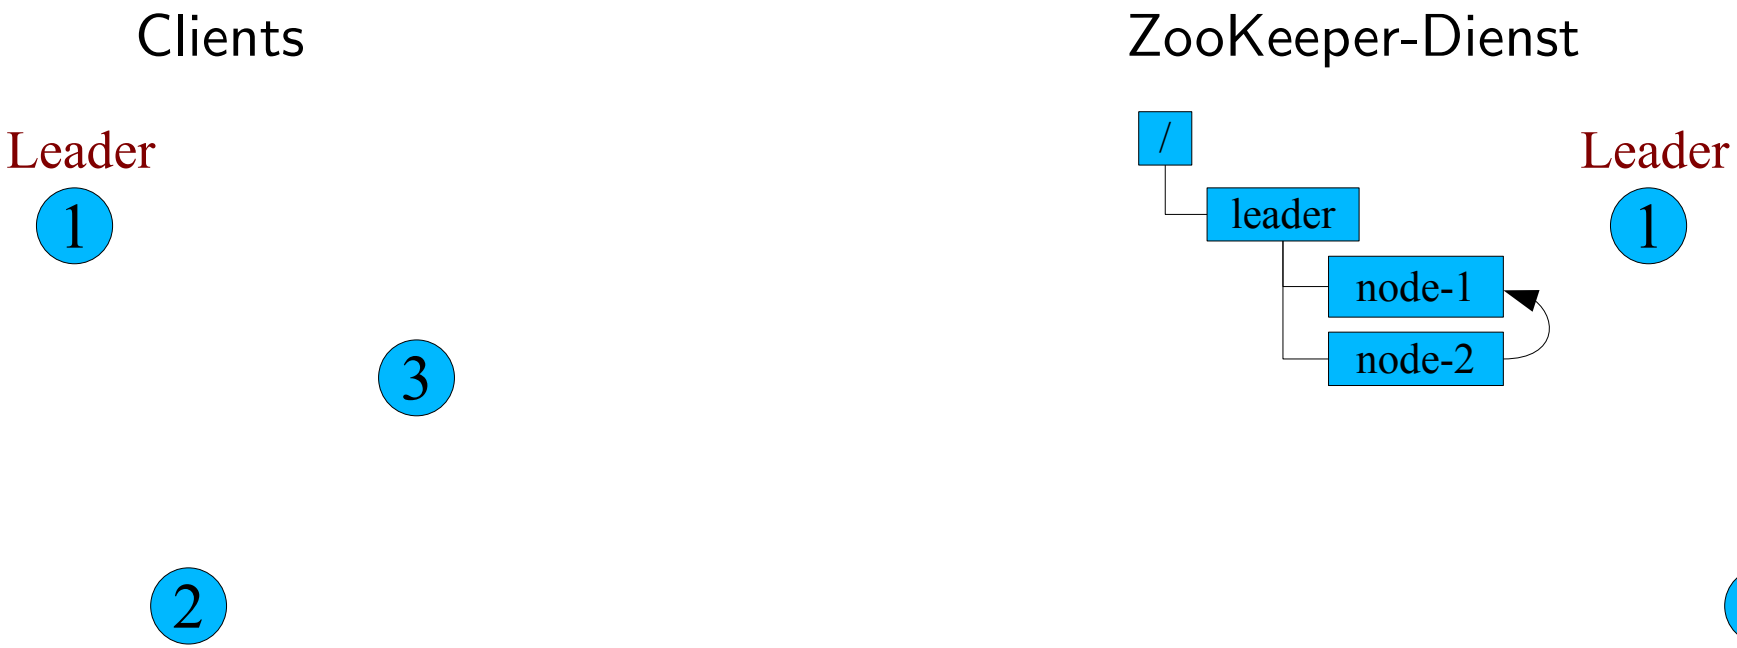

Anwendungsbeispiel: Wahl eines Anführers

Beispielablauf

- Ausfall des Leader-Knotens Client 1
  - Abbruch der Verbindung zum ZooKeeper-Dienst
  - Automatische Löschung des Kindknotens `/leader/node-1`
  - Client 2 wird per Watch über den Ausfall benachrichtigt und steigt damit zum neuen Leader auf

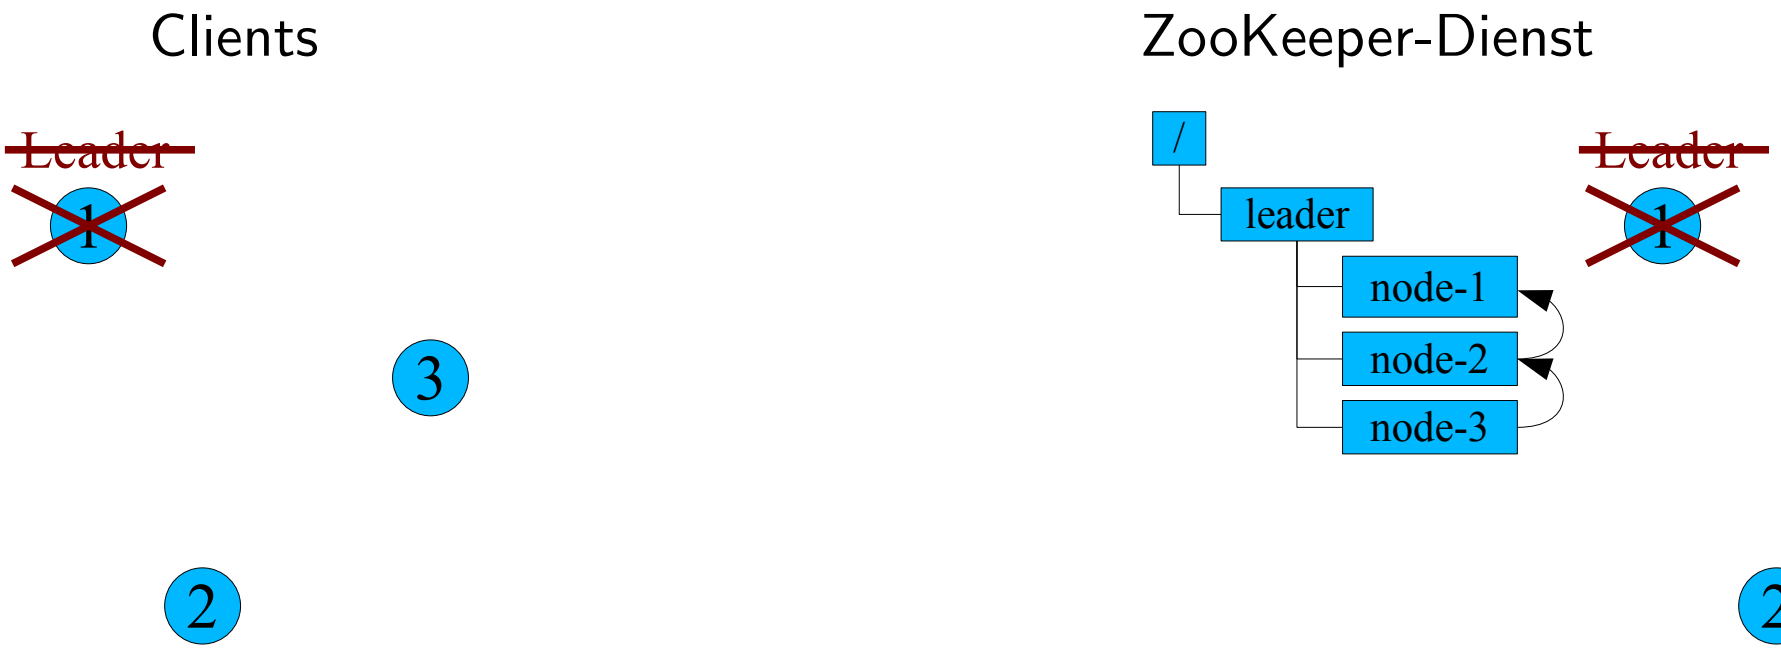

Überblick

ZooKeeper

- Einführung
- Konsistenzwahrung in ZooKeeper
- Aufgabe 5

Konsistenzwahrung in ZooKeeper

- Problemstellung
  - 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

A_1:
```
setData("/node", new byte[] { 47 }, -1);
```

A_2:
```
setData("/node", new byte[] { 48 }, -1);
```

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

R_1	/node-Daten
$< init >$	null
A_1	[47]
A_2	[48]

R_2	/node-Daten
$< init >$	null
A_2	[48]
A_1	[47]

- Sicherstellung der Replikatkonsistenz in ZooKeeper
  - Alle Replikate müssen Anfragen in der selben Reihenfolge bearbeiten
  - Protokoll zur Erstellung einer Anfragenreihenfolge nötig

Replikation in ZooKeeper

- Anzahl der ZooKeeper-Replikate
  - Annahme: Ein ausgefallenes Replikat wird zeitnah durch ein neues ersetzt
  - $2f + 1$ Replikate zur Tolerierung von höchstens f Fehlern bzw. Ausfällen
  - Beispiel für $f = 2$

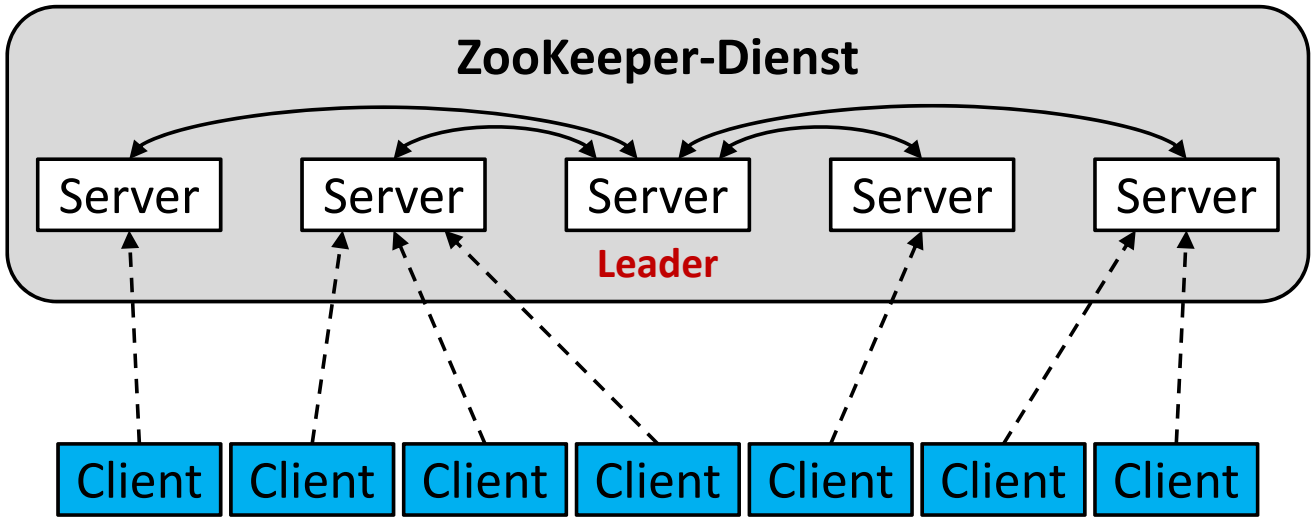

- Leader-Follower-Ansatz
  - Leader gibt Reihenfolge vor
  - Follower bearbeiten Anfragen in der vorgegebenen Reihenfolge

Optimierung für lesende Anfragen

- Einsicht

  Lesende Anfragen haben auf die Replikatkonsistenz keinen Einfluss
- Optimierte Bearbeitung lesender Anfragen:
  - Ausschließlich durch direkt mit Client verbundenes Replikat
  - Sofort, 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 lesende Anfragen sind abhängig vom bearbeitenden Replikat
    - Rückgabe von ‚veralteten' Daten und Versionsnummern möglich
  - Erzwingen eines Synchronisationspunkts mit `sync()`
    - Warten bis alle vor dem `sync()` empfangenen Anfragen bearbeitet wurden

Zab

- Protokoll für zuverlässigen und geordneten Nachrichtenaustausch
  - Von Apache ZooKeeper verwendet, aber nicht modular integriert
  - Nachträgliche eigenständige Implementierung als *Zab*
- *Totally Ordered Broadcast Protocol*
  - Leader-Follower-Ansatz
  - Zwei Protokoll-Modi
    - *Broadcast* Normalbetrieb
    - *Recovery* Wahl eines neuen Leader
- Source-Code

  `https://svn.cs.hmc.edu/svn/linkedin08/zab-multibranch/src/java/main/`
- 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.

Zab: Broadcast-Modus

- Ziel

  Herstellung einer einheitlichen Reihenfolge aller Client-Anfragen
- Vorgehensweise
  - `PROPOSE` Leader schlägt Sequenznummer (`zxid`) für Anfrage vor
  - `ACK` Follower akzeptieren den Vorschlag
  - `COMMIT` Leader bestätigt die Sequenznummer der Anfrage

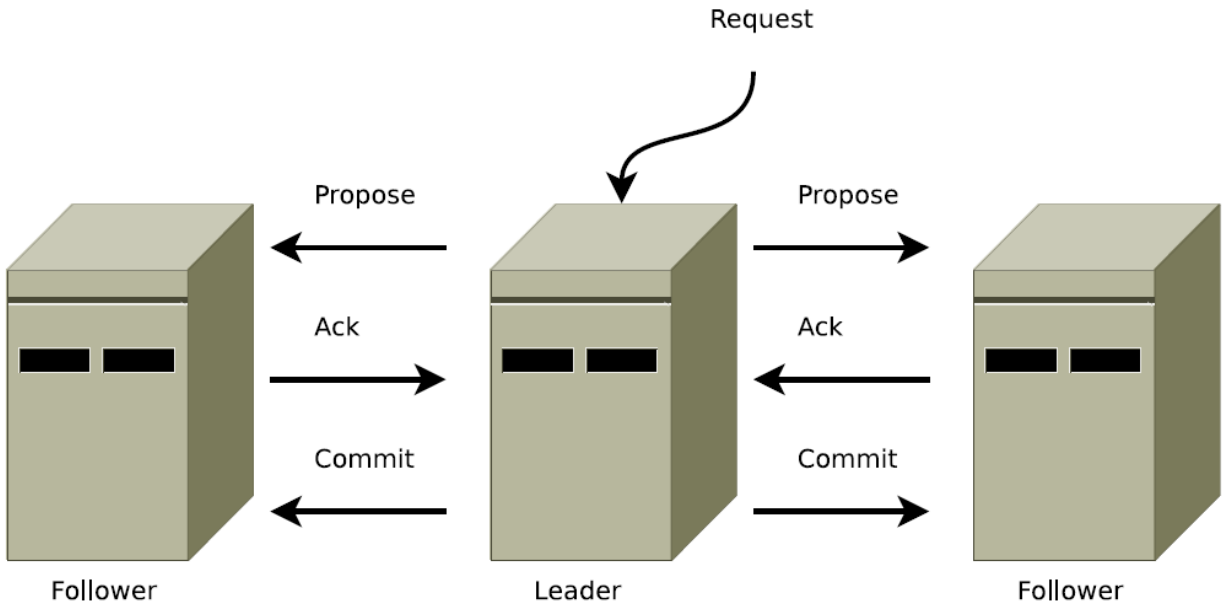

[Abbildung aus Reed et al. „A simple totally ordered broadcast protocol“]

Zab: Recovery-Modus

- Abbruch des Broadcast-Modus
  - Ausfall des Leader
  - Leader hat keine Mehrheit mehr
- Eigenschaften des Recovery-Protokolls
  - Eine Anfrage, die auf einem Knoten bestätigt wurde (`COMMIT`), wird (gegebenenfalls nachträglich) auf allen Knoten bestätigt
  - Nichtbestätigte Vorschläge werden verworfen
- Wahl eines neuen Leader
  - Ziel: Neuer Leader wird der Knoten, dem der Vorschlag mit der höchsten `zxid` bekannt ist; bei Gleichstand entscheidet die höhere Knoten-ID
  - Rundenbasierte Abstimmung, in der jeder Knoten jedem anderen seinen aktuellen Kenntnisstand mitteilt
  - Bei Fehlern während der Wahl: Neustart des Vorgangs nach Timeout
- Nach erfolgreicher Wahl
  - Leader stellt verloren gegangenen Vorschläge und Bestätigungen bereit
  - Wiederaufnahme des Broadcast-Modus

Zab: Implementierung

- Repräsentation eines Zab-Knotens in der abstrakten Basisklasse `Zab`
- Varianten von Zab-Knoten
  - `SingleZab` Einzelner (lokaler) Knoten
  - `MultiZab` Knoten als Teil einer verteilten Gruppe von Knoten
- Methoden

```
public void startup();
public void shutdown();
public ZabTxnCookie propose(byte[] message);
public ZabTxnCookie sync();
```

  - `startup()` Starten eines Zab-Knotens
  - `shutdown()` Stoppen eines Zab-Knotens
  - `propose()` Senden einer zu ordnenden Nachricht
  - `sync()` Senden einer Sync-Anfrage
- Transaktions-Cookie (`ZabTxnCookie`)
  - Interne Verwaltungsinformationen über zu ordnende Nachrichten
  - Sequenznummer, Server-IDs,...

Zab: Nachrichtenempfang & Zustandstransfer

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

```
public void deliver(ZabTxnCookie id, byte message[]);
public void deliverSync(ZabTxnCookie id);
public void status(ZabStatus status, String leader);
public void getState(OutputStream os);
public void setState(InputStream is, ZabTxnCookie lastCommit);
```

  - `deliver()` Zustellung der nächsten geordneten Nachricht
  - `deliverSync()` Benachrichtigung über eine Sync-Anfrage
  - `status()` Benachrichtigung über Änderungen des Knotenstatus
  - `getState()` Auslesen des aktuellen Knotenzustands
  - `setState()` Schreiben des aktuellen Knotenzustands
- Knotenstatus (`ZabStatus`)
  - `LOOKING` Temporärer Zustand während der Anführerwahl
  - `FOLLOWING` Zustand eines Follower-Knotens
  - `LEADING` Zustand des Leader-Knotens

Zab: Konfiguration

- Übergabe eines `Properties`-Objekts an den `Zab`-Konstruktor
- Parameter
  - `myid` ID des lokalen Knotens
  - `peer<i>` Adresse des Knotens *i*
  - `dataLogDir` Verzeichnis, in dem das Transaktions-Log abgelegt wird
  - `dataSnapDir` Verzeichnis, in dem die Snapshots abgelegt werden
  - ...
- Beispielkonfiguration eines `MultiZab`-Knotens (insgesamt 3 Knoten)
  - Zusammenstellung der Konfiguration

```
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(zabListener, zabProperties);
```

Überblick

ZooKeeper

- Einführung
- Konsistenzwahrung in ZooKeeper
- Aufgabe 5

Aufgabe 5

- Umsetzung eines Koordinierungsdienstes
  - ZooKeeper-Implementierung von Apache als Vorbild
- Teilaufgaben
  - Implementierung als Client-Server-Anwendung
  - Replikation unter Zuhilfenahme von Zab
  - Unterstützung flüchtiger Knoten
- Vereinfachte Schnittstelle

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

- Fokus der Übungsaufgabe
  - Konsistente Replikation eines zustandsbehafteten Diensts
  - Unterschiedliche Behandlung von schreibenden und lesenden Anfragen
  - Konsistente Zeitstempel

Konsistente Zeitstempel

- Problemstellung
  - Beim Erstellen eines Knotens bzw. bei jedem Setzen von Nutzdaten soll der `Last-Modified`-Zeitstempel in dessen Metadaten aktualisiert werden
  - Lokale Uhren der Replikate können voneinander abweichen

  $\Rightarrow$ Inkonsistente Zeitstempel bei trivialer Implementierung
- Lösungsansatz
  - Jedes Replikat ordnet jeder Anfrage einen Zeitstempel zu, der seiner lokalen Uhrzeit zum Zeitpunkt des Empfangs der Anfrage entspricht
  - Bei der Ausführung einer Anfrage wird deren Zeitstempel als *aktuelle Zeit* verwendet – unabhängig vom gegenwärtigen Stand der lokalen Uhr
  - Um Sprünge in die Vergangenheit zu vermeiden, wird der `Last-Modified`-Zeitstempel nur dann aktualisiert, wenn der Zeitstempel der Anfrage größer ist

- Weitere (zu weit führende) Fragestellungen
  - Was ist, wenn mehrere Zeitstempel pro Anfrage benötigt werden?
  - Welche anderen Möglichkeiten gäbe es, monoton steigende Zeitstempel zu gewährleisten?
  - ...

Ausgabeparameter in Java

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

  - Intern: Setzen von Attributen des Ausgabeparameters

```
public byte[] getData(String path, MWStat 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 für Serialisierung

```
public byte[] serialize(Serializable obj) throws Exception {
    ByteArrayOutputStream baos = new ByteArrayOutputStream();
    ObjectOutputStream oos = new ObjectOutputStream(baos);
    oos.writeObject(obj);
    oos.close();
    baos.close();
    return baos.toByteArray();
}
```

- Hinweis zum Einsatz von Object-Streams in Verbindung mit Sockets
  - Der Konstruktor des `ObjectInputStream` blockiert solange, bis auf der anderen Seite der Verbindung ein `ObjectOutputStream` geöffnet wird

⇒ Object-Streams auf beiden Seiten in unterschiedlicher Reihenfolge öffnen

Logging mit log4j

- Zab verwendet intern die Logging-API *log4j*
  - Konfiguration mittels einer Datei `log4j.properties`, die im Classpath der Java-Anwendung abgelegt sein muss
  - Granularitätsstufen: `OFF`, `ERROR`, `WARN`, `DEBUG`, `ALL`, ...
- Beispiele für log4j-Konfigurationen
  - Ausgabe der Log-Meldungen auf der Konsole (Stufe: `DEBUG`)

```
log4j.rootLogger=DEBUG, CONSOLE
log4j.appender.CONSOLE=org.apache.log4j.ConsoleAppender
log4j.appender.CONSOLE.layout=org.apache.log4j.PatternLayout
```

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

```
log4j.rootLogger=INFO, FILE
log4j.appender.FILE=org.apache.log4j.FileAppender
log4j.appender.FILE.File=zab.log
log4j.appender.FILE.layout=org.apache.log4j.PatternLayout
```