Middleware – Cloud Computing

Koordinierungsdienste

Wintersemester 2022/23

Tobias Distler

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

Lehrstuhl für Verteilte Systeme
und Betriebssysteme

FRIEDRICH-ALEXANDER
UNIVERSITÄT
ERLANGEN-NÜRNBERG

TECHNISCHE FAKULTÄT

Überblick

Koordinierungsdienste

- Motivation
- Grundkonzept
- Chubby
- ZooKeeper

Koordinierungsaufgaben in der Cloud

- Charakteristika großer verteilter Cloud-Systeme und -Anwendungen
  - Hohe Anzahl von Komponenten bzw. Prozessen
  - Bereitstellung eines **gemeinsamen Diensts durch Kooperation**
- Problem: Kooperation erfordert **Mechanismen zur Koordinierung**
  - Beispiele für Koordinierungsaufgaben
    - Verteilter gegenseitiger Ausschluss
    - Wahl eines Anführers
    - Verteilte (Prioritäts-)Warteschlangen
  - Anforderungen
    - Zuverlässigkeit
    - Verfügbarkeit

  $\rightarrow$ Zur eigentlichen Anwendung orthogonale Problemstellungen
- Herausforderungen
  - Wie lässt sich Koordinierung mittels eines **externen Diensts** bereitstellen?
  - Wie sehen mögliche Kompromisse zwischen Effizienz und Konsistenz aus?

Überblick

Koordinierungsdienste

- **Speicherung kleiner Datenmengen** ($< 1\,\text{MB}$)
  - Verwaltung mittels Knoten in einer Baumstruktur
  - Dateisystemartiger Zugriff auf Nutz- und Metadaten
- Bereitstellung eines **Benachrichtigungsdiensts**
  - Clients spezifizieren *Watches* für Ereignisse, über die sie informiert werden möchten
  - Beispielereignisse: Anlegen/Löschen eines Knotens, Änderung von Daten
- Fehlertoleranz durch **Replikation**

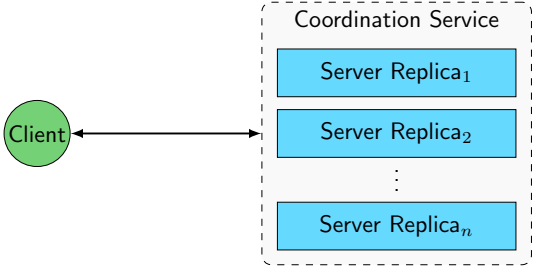

Schnittstelle

- **Standardoperationen**

Operation	Beschreibung
`create()`	Anlegen eines Knotens
`getData()`	Auslesen der Nutz- und Metadaten eines Knotens
`setData()`	Aktualisieren der Nutzdaten eines Knotens
`delete()`	Löschen eines Knotens

- Implementierungsspezifisch: Zusätzliche **Hilfsoperationen** (Beispiele)

`getChildren()`	Ausgabe der Pfadnamen von Kindknoten
`setACL()`	Aktualisierung der Zugriffsrechte für einen Knoten

- **Bedingte Ausführung** von Operationen
  - Problem: Korrektheit vom vorherigen Zustand abhängiger Aktualisierungen
  - Lösungsansatz
    - Verwaltung eines Versionszählers für jeden Knoten
    - Bearbeitung einer Operation nur, falls Versionsnummer weiterhin aktuell ist

Anwendungsbeispiel: Prioritätswarteschlange

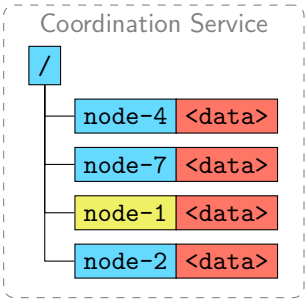


```
CoordinationService cs = create connection;
```

```
void insert(Object o, Priority p) {
  /* Encode priority in node name. */
  String nodeName = "/node-" + p;

  /* Create node and set its data to o. */
  cs.create(nodeName, o);
}
```

```
Object remove() {
  /* Find node with the highest priority. */
  String[] nodes = cs.getChildren("/");
  String head = node from nodes with highest priority
                according to its name;

  /* Get node data and remove node. */
  Object o = cs.getData(head);
  cs.delete(head);
  return o;
}
```

Knoten

- Persistente Knoten
  - Existenz des Knotens unabhängig von Client-Sitzung
  - **Explizites Löschen** durch einen Client erforderlich

- Flüchtige Knoten (Ephemeral Nodes)
  - Existenz des Knotens ist an eine Client-Sitzung gebunden
  - **Automatisches Löschen** des Knotens bei Sitzungsende bzw. -abbruch
  - Anwendungsbeispiel: Ausfallerkennung
    - Client C erstellt flüchtigen Knoten k
    - Andere Clients registrieren sich für Benachrichtigung über Löschung von k
    - Ausfall von Client $C \rightarrow$ Koordinierungsdienst löscht Knoten k
    - Registrierte Clients erhalten Mitteilung über Ausfall von Client C

Überblick

Chubby

- Anforderungen
  - Dienst zur **Wahl eines Anführers**
  - Beispiel: Master-Server im Google File System
  - Typisches Nutzungsprofil eines Lock
    - Lock wird einmal angefordert
    - Wechsel des Lock-Halters üblicherweise nur nach Ausfällen
- Chubby
  - Ausrichtung auf **grobgranulare Locks** [→ Haltezeiten von Stunden oder sogar Tagen]
  - Bereitstellung starker Konsistenzgarantien
  - Unterstützung einer großen Anzahl von Client-Prozessen [z. B. 90.000 [Burrows]]
  - **Zuverlässigkeit wichtiger als Performanz**
- Literatur

Mike Burrows
The Chubby lock service for loosely-coupled distributed systems
Proc. of the 7th Symposium on Operating Systems Design and Implementation (OSDI '06), S. 335–350, 2006.

Architektur

- Client-Bibliothek
  - Senden von Anfragen an Chubby
  - Verwaltung eines **Antwort-Cache für Nutz- und Metadaten**
- Server-Seite: Chubby-Zelle
  - Replikation
    - Typische Zellengröße: 5 Replikate $\rightarrow$ Tolerierung von 2 Ausfällen möglich
    - Konsistenzwahrung mit Hilfe des *Paxos*-Protokolls [Details in der Veranstaltung *Verteilte Systeme*.]
  - Master-Replikat
    - **Ausführung aller (lesenden und schreibenden) Client-Anfragen**
    - Erzeugung und Verteilung von Zustandsaktualisierungen
  - Andere Replikate
    - **Einspielen von Zustandsaktualisierungen**
    - Keine Aktion bei lesenden Anfragen
    - Wahl eines neuen Master-Replikats bei Ausfall des vorherigen

Chubby-spezifische Schnittstellenerweiterungen

- Zugriff auf einen Knoten erfolgt mittels **Handle**
  - Vergleiche: Dateideskriptor in UNIX
  - Operationen
    - `Open()`: Erzeugung eines Handle
      - Festlegung des Zugriffsmodus (z. B. Schreiben, Lesen, Lock-Anforderung)
      - Spezifizierung der abonnierten Ereignisse
    - `Close()`: Schließen eines Handle
- **Locks**
  - Verfügbare Modi
    - Exklusives Schreiber-Lock
    - Geteiltes Leser-Lock
  - Lock-Vergabe unabhängig vom Zugriff auf die Nutz- und Metadaten des korrespondierenden Knotens (*Advisory Locks*)
  - Operationen
    - `Acquire()`: Anfordern eines Lock
    - `Release()`: Rückgabe eines Lock

Verwaltung von Client-Sitzungen

- Grundlegendes Konzept
  - Sitzung: **Temporäre Garantie von Chubby an einen Client**
    - Vom Client erzeugte Knoten-Handles bleiben gültig
    - Vom Client gehaltene Locks werden nicht neu vergeben
  - Festlegung der Dauer einer Sitzung mittels Lease
- Verlängerung einer Sitzung
  - Bei Sitzungsaufbau
    - Client initiiert *KeepAlive*-Fernaufruf zum Master-Replikat
    - Master-Replikat **blockiert** in dem Fernaufruf
  - Vor Ablauf eines Sitzungs-Lease
    - Master-Replikat **deblockiert** KeepAlive-Fernaufruf
    - Antwort des Fernaufrufs enthält Dauer der Lease-Verlängerung [Standardwert: 12 Sekunden]
    - Client startet erneuten KeepAlive-Fernaufruf
- **Vorzeitige Rückkehr** aus einem KeepAlive-Fernaufruf
  - Benachrichtigung eines Clients über abonnierte Ereignisse
  - Vorteil: Ansatz funktioniert auch für durch Firewalls geschützte Clients

Caching auf Client-Seite

- Problem: **Master-Replikat stellt Flaschenhals dar**
  - Bearbeitung schreibender und lesender Anfragen
  - Verwaltung von Sitzungen

  $\rightarrow$ Entlastung des Master-Replikats erforderlich
- Lösungsansatz: **Einsatz von Client-Caches** für Nutz- und Metadaten
- Invalidierung von Cache-Inhalten
  - Master-Replikat verwaltet eine Liste mit Informationen darüber, welche Daten jeder Client in seinem Cache zwischengespeichert haben könnte
  - Bei jeder **modifizierenden Anfrage**
    1. Master-Replikat sendet Invalidierungen an alle betroffenen Clients
    2. Clients löschen die entsprechenden Daten aus ihrem Cache
    3. Clients bestätigen dem Master-Replikat die Invalidierung
    4. Master-Replikat führt Anfrage aus, sobald alle Bestätigungen betroffener Clients vorliegen bzw. deren Sitzungs-Leases ausgelaufen sind
  - Realisierung: Ausnutzung des KeepAlive-Fernaufruf-Mechanismus

Verhalten bei Fehlersituationen

- Korrekter Client schafft es nicht, sein Sitzungs-Lease zu verlängern
  - Möglicher Grund: **Überlastung bzw. Ausfall des Master-Replikats**
  - Vorgehensweise auf Client-Seite
    1. Löschen und Deaktivieren des eigenen Cache
    2. Eintritt in eine Wartephase (**Grace Period**, Dauer: z. B. 45 Sekunden)
    3. Nach Ablauf der Wartephase
       * Abbruch sämtlicher Aufrufe
       * Fehlermeldung an die Anwendung
    4. Bei Wiederherstellung einer Verbindung zu einem Master-Replikat
       * Verlängerung des Sitzungs-Lease
       * Reaktivierung des eigenen Cache
- **Wechsel des Master-Replikats** (z. B. bei Ausfall): Aktionen des neuen Master
  1. Rekonstruktion der Master-Datenstrukturen im Hauptspeicher
  2. Senden einer *Fail-Over*-Benachrichtigung an alle bekannten Clients
  3. **Warten auf Bestätigungen** der kontaktierten Clients
  4. Wechsel in den Normalzustand

Überblick

ZooKeeper

- **ZooKeeper** [Weitere Details in den Übungen.]
  - Apache-Projekt: `http://zookeeper.apache.org/`
  - Produktiveinsatz: Yahoo, Facebook, Twitter,...
  - Verwaltung des Zustands im Hauptspeicher
  - Periodische Sicherungspunkte auf Festplatte
- Hauptunterschiede zu Chubby
  - Keine direkte Unterstützung von Locks
  - Keine vom System verwalteten Client-Caches
  - **Abgeschwächte Konsistenzgarantien**
    - Auf allen Replikaten: Identische Ausführungsreihenfolge für Schreibanfragen
    - Alle Anfragen desselben Clients werden in FIFO-Reihenfolge bearbeitet
- 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 Conference (ATC '10), S. 145–158, 2010.

Architektur

- Server-Seite: **ZooKeeper-Zelle**
  - Typische Größe: 5 Replikate
  - Rollenverteilung
    - *Leader*-Replikat
    - *Follower*-Replikate
- Client: Sitzungsaufbau zu **beliebigem Replikat**
  - Ziel: Verteilung des Kommunikationsaufwands auf alle Replikate
  - Client kommuniziert im Normalfall ausschließlich mit einem Replikat
- Bearbeitung zustandsmodifizierender Anfragen
  1. Client sendet Anfrage an das mit ihm verbundene Replikat R
  2. Replikat R leitet die Anfrage an das Leader-Replikat weiter
  3. **Leader bearbeitet die Anfrage** und erzeugt eine Zustandsaktualisierung
  4. Ausführung der Zustandsaktualisierung auf (letztendlich) allen Replikaten
  5. Nach lokaler Aktualisierung: Replikat R sendet Antwort an den Client

Optimierung für lesende Anfragen

- Bearbeitung **lesender Anfragen**
  1. Client sendet Anfrage an das mit ihm verbundene Replikat R
  2. Replikat R führt Anfrage direkt aus
  3. Replikat R sendet Antwort an den Client
- Mögliche Konsequenz: **Lesen veralteter Zustände**
  - Leseanfragen können Schreibanfragen anderer Clients „überholen“
  - Beispiel: Client C_1 ist mit Replikat R_1 verbunden, Client C_2 mit Replikat R_2
    1. Client C_1 legt erfolgreich einen Knoten k an
    2. Client C_1 sendet eine Nachricht an Client C_2, dass Knoten k angelegt wurde
    3. Client C_2 erhält beim Versuch auf k zuzugreifen eine Fehlermeldung von Replikat R_2, dass der Knoten nicht existiert

    $\rightarrow$ Replikat R_2 hatte die Anfrage von Client C_1 noch nicht ausgeführt
- ZooKeeper-spezifische Schnittstellenerweiterung: `sync`-Operation
  - Bearbeitung aller ausstehenden Schreibanfragen
  - **Langsame Leseanfrage**: Auf `sync`-Aufruf folgende Leseoperation