Middleware – Cloud Computing

Verwaltung großer Datenmengen

Wintersemester 2025/26

Tobias Distler, Christian Berger

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

Lehrstuhl für Informatik 4
Systemsoftware

FRIEDRICH-ALEXANDER
UNIVERSITÄT
ERLANGEN-NÜRNBERG
TECHNISCHE FAKULTÄT

Überblick

Verwaltung großer Datenmengen

- Motivation
- Google File System
- Bigtable
- Colossus

Datenverwaltung in der Cloud

- **CAP-Theorem** nach [Brewer]
  - In einem verteilten System ist es nicht möglich gleichzeitig
    - Konsistenz *(**C**onsistency)*
    - Verfügbarkeit *(**A**vailability)*
    - Partitionstoleranz *(**P**artition Tolerance)*

    zu garantieren
  - **Abschwächung (mindestens) einer der Eigenschaften erforderlich**
- Herausforderungen
  - Welche der Eigenschaften sollen in welchem Umfang garantiert werden?
  - Wie lassen sich **Speichersysteme speziell auf Anwendungen zuschneiden?**
- Literatur

Eric A. Brewer
Towards robust distributed systems
Proc. of the 19th Symp. on Principles of Distributed Computing (PODC'00), S. 7, 2000.

Überblick

Verwaltung großer Datenmengen

- Motivation
- Google File System
- Bigtable
- Colossus

Google File System

- Einsatzszenario
  - Verwendung hunderter bzw. tausender Rechner
  - Verwaltung sehr großer Datenmengen
  - **Hardware-/Software-Ausfälle sind keine Ausnahme**, sondern die Regel
- Google File System
  - Auf eine spezielle Kategorie von Anwendungen zugeschnitten
  - **Fehlertoleranz durch Replikation**
  - Ausgelegt auf Einsatz von Commodity-Hardware
  - **Abgeschwächtes Konsistenzmodell**
  - Vorbild für das quelloffene *Hadoop Distributed File System (HDFS)*
- Literatur

Sanjay Ghemawat, Howard Gobioff, and Shun-Tak Leung
The Google file system
Proc. of the 19th Symposium on Operating Systems Principles (SOSP '03), S. 29–43, 2003.

Anforderungen der Anwendungen an das Dateisystem

- Dateigröße
  - Fokus auf **sehr große Dateien** [→ Mehrere Gigabytes pro Datei.]
  - Kleine Dateien sollen unterstützt werden, sind jedoch nicht vorrangig
- Zugriffsmuster
  - Schreibzugriffe
    - Schreibanfragen hängen in der Regel Daten an eine Datei an
    - **Paralleles Anhängen an dieselbe Datei** durch mehrere Prozesse ist häufig
    - Wahlfreies Schreiben ist die Ausnahme, muss jedoch unterstützt werden
  - Lesezugriffe
    - **Lesen großer, oftmals zusammenhängender Bereiche** einer Datei
    - Lesen kleiner Teilbereiche einer Datei, dazwischen Sprünge
- Weitere Eigenschaften
  - Eine einmal geschriebene Datei wird meistens nicht mehr modifiziert
  - Hoher Durchsatz wichtiger als kurze Antwortzeiten für einzelne Anfragen

Schnittstelle

- **Hierarchische Datenverwaltung**
  - Verzeichnisse
  - Dateien
- An traditionelle Dateisysteme angelehnte **Schnittstelle**

Operation	Beschreibung
`create`	Anlegen einer Datei
`delete`	Löschen einer Datei
`open`	Öffnen einer Datei
`close`	Schließen einer Datei
`read`	Lesen von Daten aus einer Datei
`write`	Schreiben von Daten in eine Datei

- **Zusätzliche Operationen**

append	Atomares Anhängen von Daten an eine Datei
`snapshot`	Erstellen eines Sicherungspunkts

Architektur

- Grundlegender Ansatz
  - Aufteilung großer Dateien in **Datenblöcke fester Größe** (*Chunks*)
    - Typische Größe: 64 MB
    - Eindeutig identifizierbar durch *Chunk-Handles* (jeweils 8 Bytes)
  - Redundantes Speichern eines Datenblocks auf mehreren Rechnern
- Zentrale Komponenten
  - Chunk-Server
    - Verwaltung von Datenblöcken
    - **Persistente Datenspeicherung** auf der lokalen Festplatte
  - Master-Server
    - Verwaltung von Metadaten im Hauptspeicher
      - **Zuordnung von Datenblöcke auf Dateien**
      - Speicherorte von Datenblöcken (= Chunk-Server)
    - Zusätzlich: Sicherung zentraler Metadaten in einer replizierten Log-Datei
    - **Überwachung von Chunk-Servern mittels „*HeartBeat*“-Nachrichten**
    - Koordinierung der Lastverteilung

Schreiboperationen

- Vorbereitungen beim **Anlegen eines Datenblocks**
  - Master wählt drei für den Datenblock zuständige Chunk-Server aus
  - Per Lease: Ernennung eines der Server zum *Primary*
  - Die anderen beiden Server übernehmen die Rolle von *Secondaries*
- Vorgehensweise bei **Schreibanfragen auf Datenblöcken**
  1. Ermittlung der für den Datenblock zuständigen Chunk-Server
     - Anfrage des Clients an den Master
     - Speicherung der Master-Antwort in lokalem Client-Cache
  2. **Verteilung der Nutzdaten** und Warten auf Empfangsbestätigungen
     - Weitergabe zum jeweils „nächstgelegenen“ Chunk-Server
     - Auf IP-Adressen basierende Metrik zur Auswahl des nächsten Empfängers
  - **Durchführung der Schreiboperation**
  3. Senden des eigentlichen Schreibkommandos vom Client an den Primary
  4. Ausführung auf dem Primary und Weiterleitung an Secondaries
  5. Ausführung der Schreiboperation auf den Secondaries
  6. Primary: Sammlung der Bestätigungen aller zuständigen Chunk-Server
  7. Senden einer Erfolgsmeldung vom Primary an den Client

Schreiboperationen

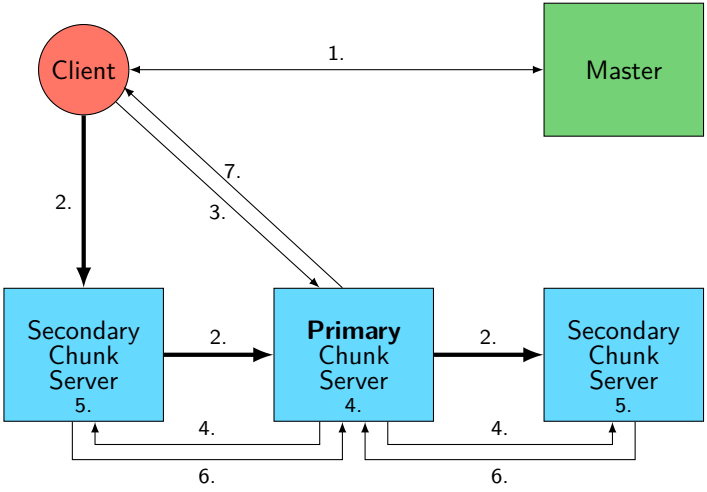

Weitere Operationen

- Schreibaufruf mittels append-Operation
  - **Atomares Anhängen von Daten** an eine Datei
  - Typischer Anwendungsfall
    - Gleichzeitiger Zugriff durch mehrere Clients
    - Paralleles Schreiben in dieselbe Datei
  - Unterschiede zur normalen Schreiboperation
    - **Primary legt Offset im Datenblock fest**
    - Falls die Daten nicht mehr in den aktuellen Datenblock passen
      - Primary weist Secondaries an, den Datenblock mit Padding-Bytes zu füllen
      - Client muss Anhängeoperation auf dem nächsten Datenblock wiederholen
    - Primary teilt dem Client den tatsächlichen Speicher-Offset mit

- Ablauf einer Leseoperation
  1. Client fragt Master nach für den Datenblock zuständigen Chunk-Servern
  2. Client speichert Master-Antwort für spätere Anfragen in lokalem Cache
  3. Client sendet **Leseanfrage zum „nächstgelegenen“ Chunk-Server**

Umgang mit Fehlersituationen

- Mechanismen zur effizienten Behandlung von Master-Ausfällen
  - Replikation des Zustands über mehrere Rechner
  - Relativ kleiner Master-Zustand $\rightarrow$ Schneller Neustart möglich
  - **Einsatz von Shadow-Master-Servern** für nichtmodifizierende Anfragen
- Behandlung von Chunk-Server-(Teil-)Ausfällen
  - Datenkorruption
    - **Fehlerdetektion bei Leseanfragen**
      - Integritätsüberprüfung der gespeicherten Daten durch Chunk-Server
      - Nutzung von Checksummen über 64 KB-Blöcke
    - Meldung an den Master bei der Erkennung von Fehlern
    - Master leitet Erstellung eines neuen Replikats ein
  - Rechnerausfall
    - HeartBeat-Nachrichten an den Master bleiben aus
    - Master leitet Erstellung neuer Replikate ein
    - Master bestimmt **nach Ablauf der Leases neue Primaries** für Datenblöcke

Umgang mit Fehlersituationen

- Fehler bei der Bearbeitung von Anhängeoperationen
  [Vergleichbare Probleme können auch beim wahlfreien Schreiben auftreten.]
  - Die Erfolgsbestätigung von mindestens einem Chunk-Server kommt nicht an
  - Client erhält eine Fehlermeldung
  - → **Client wiederholt die komplette Anhängeoperation**
- Abgeschwächte Konsistenzeigenschaften
  - Erfolgreiche Bestätigung einer Anhängeoperation: Garantie, dass der Datensatz auf den Chunk-Servern **am selben Offset** gespeichert wurde
  - Potentielle Auswirkungen von Fehlern
    - Ein von der Anwendung einmalig angehängter Datensatz kann mehrfach vorliegen
    - Inhalt eines Datenblocks kann zwischen den Replikaten divergieren
- **Auswirkungen auf Anwendungen**
  - Anwendungen müssen mit den schwächeren Garantien umgehen können
  - Beispiele für mögliche Maßnahmen
    - Einsatz von selbstverifizierenden, selbstidentifizierenden Datensätzen
    - Berechnung von Checksummen durch die Anwendung

Überblick

Verwaltung großer Datenmengen

- Motivation
- Google File System
- Bigtable
- Colossus

Bigtable

- Unterstützung auf **strukturierten Daten** basierender Anwendungen (Beispiele)
  - Erstellung und Verwaltung eines Web-Index
  - Datenspeicher für Google Maps/Earth
- Implementierung
  - Architektur
    - Zugriff per Client-Bibliothek
    - Steuerung des Systems durch einen **zentralen Master-Server**
    - Skalierbarkeit durch Bearbeitung von Datenzugriffen auf zusätzlichen Servern
  - **Persistente Speicherung der Daten im Google File System**
  - Vorbild für das quelloffene *HBase*
- Literatur

Fay Chang, Jeffrey Dean, Sanjay Ghemawat, Wilson Hsieh, Deborah A. Wallach et al.
Bigtable: A distributed storage system for structured data
Proc. of the 7th Symposium on Operating Systems Design and Implementation (OSDI '06), S. 205–218, 2006.

Datenmodell

- Verwaltung von **Daten in Tabellenform**
  - Speicherung mehrerer Versionen pro Zelle
    - Identifizierung mittels System- oder Anwendungszeitstempeln
    - Kriterien für automatisierte Garbage-Collection
      - Maximum für die Anzahl der pro Zelle gespeicherten Versionen
      - Obergrenze für das Alter einer Version
  - **Atomare Schreib- und Lesezugriffe** auf Zeilen

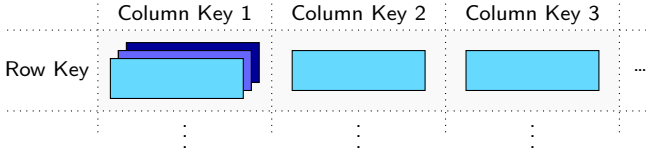

- Skalierbarkeit durch **Partitionierung von Tabellen**
  - *Tablet*: Zusammenhängender Abschnitt benachbarter Zeilen
  - Zuordnung verschiedener Tablets zu unterschiedlichen Servern

  → Oft gemeinsam gelesene Einträge sollten benachbarte Schlüssel haben

Implementierung

- Hierarchie
  - Metadatentabelle: Informationen zu Tablets von Nutzertabellen
  - **Root-Tablet**: Verwaltung der Struktur der Metadatentabelle
  - Koordinierungsdienst: Speicherung eines Zeigers auf das Root-Tablet [→ Separate Vorlesung.]

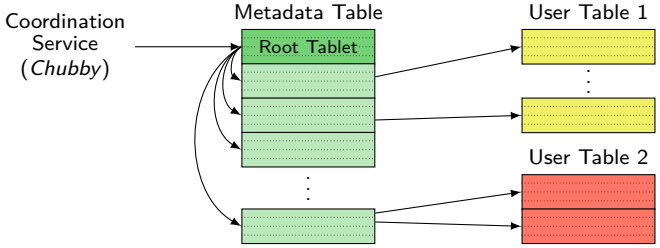

- Einsatz des Google File Systems zur persistenten Speicherung
  - **Sicherungspunkte** von Tablet-Zuständen
  - Log-Dateien mit den **Modifikationen seit dem letzten Sicherungspunkt**

[Hinweis: Der Ansatz ist sehr ähnlich zur Implementierung von Tabellen im Partition Layer von Microsoft Azure Storage.]

Überblick

Verwaltung großer Datenmengen

- Motivation
- Google File System
- Bigtable
- Colossus

Google File System: Zentraler Master – Designentscheidung im Rückblick

- Vorteil: **Vereinfachung des Designs** ermöglichte schnelle Umsetzung
- Probleme
  - Unvorhergesehene Einsatzszenarien (z. B. Gmail)
    - Nicht alle auf dem System betriebenen Anwendungen sind stapelorientiert
    - Chunk-Größe von **64 MB ist für manche Anwendungen zu groß**
  - Symptome
    - Master-Ausfall problematisch für latenzsensitive Anwendungen
    - Metadatenverwaltung für viele kleine Dateien → **Master als Flaschenhals**
- Konsequenzen
  - **Verwendung mehrerer Instanzen** pro Datenzentrum
  - Entwicklung von Systemen mit verteiltem Master (z. B. *Colossus*)
- Literatur

Marshall Kirk McKusick and Sean Quinlan
Evolution on fast-forward
Queue – File Systems, 7(7):10–20, 2009.

Colossus

- Colossus File System (CFS): **Google-interner Nachfolger des Google File Systems**
  - Details über Aufbau und Funktionsweise nicht veröffentlicht
  - Chunk-Größe konfigurierbar (Standardwert: 1 MB)
  - Skalierbarkeit durch Hierarchie von Colossus-Instanzen
  - **Getrennte Speicherung von Meta- und Nutzdaten**
    - *CFS Bigtable*: Verwaltung des Dateisystems
    - *D*: Speicherdienst für Datenblöcke

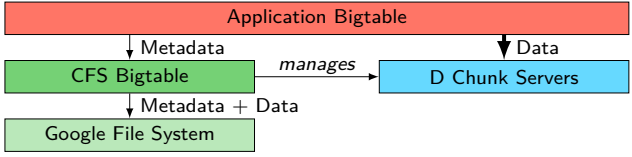

- Literatur

Denis Serenyi
Cluster-level storage @ Google
Keynote at the 2nd Joint International Workshop on Parallel Data Storage & Data Intensive Scalable Intensive Computing Systems, 2017.