

## Verwaltung großer Datenmengen

Motivation

Google File System

Bigtable



- CAP-Theorem nach [Brewer]
  - In einem verteilten System ist es nicht möglich gleichzeitig
    - Konsistenz (**Consistency**)
    - Verfügbarkeit (**Availability**)
    - Partitionstoleranz (**Partition 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**

*Proceedings of the 19th Symposium on Principles of  
Distributed Computing (PODC '00), S. 7, 2000.*

- 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
  - Einsatz von Commodity-Hardware
  - Fehlertoleranz durch Replikation
  - Abgeschwächtes Konsistenzmodell
  - Vorbild für das quelloffene *Hadoop Distributed File System (HDFS)*

## ■ Literatur



Sanjay Ghemawat, Howard Gobioff, and Shun-Tak Leung

### **The Google file system**

*Proceedings of the 19th Symposium on Operating Systems Principles (SOSP '03), S. 29–43, 2003.*

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



- 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



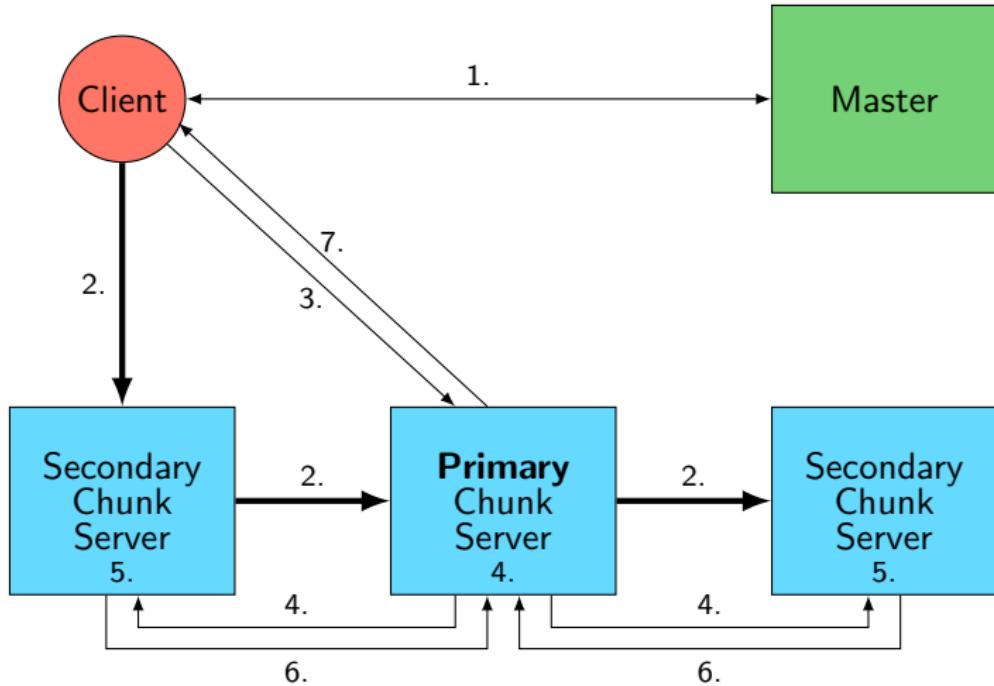
- Grundlegender Ansatz
  - Aufteilung großer Dateien in Datenblöcke fester Größe (*Chunks*)
    - Typische Größe: 64 MB
    - Eindeutig identifizierbar durch *Chunk-Handles* (jeweils 8 Bytes)
  - Redundantes Speichern eines Datenblocks auf mehreren Rechnern
- Zentrale Komponenten
  - Chunk-Server
  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



- Vorbereitungen beim Anlegen eines Datenblocks
  - Master wählt drei für den Datenblock zuständige Chunk-Server aus
  - Per Lease: Ernennung eines der Server zum *Primary*
  - Alle anderen 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



- Schreibauftrag 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 aktuellen Datenblock zu verschließen
      - \* Client muss Anhängoperation 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



- Mechanismen zur effizienten Behandlung von Master-Ausfällen
  - Replikation des Zustands über mehrere Rechner
  - Relativ kleiner Master-Zustand → Schneller Neustart möglich
  - Einsatz von *Shadow-Master-Servers* 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



- Fehler bei der Bearbeitung von Anhängeoperationen
  - [Vergleichbare Probleme können auch beim wahlfreien Schreiben auftreten.]
  - Mindestens ein Chunk-Server sendet keine Erfolgsbestätigung
  - 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
    - Inhalt eines Datenblocks kann zwischen den Replikaten divergieren
    - Ein von der Anwendung einmalig angehängter Datensatz kann mehrfach vorliegen
- 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



- 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
    - Metadatenverwaltung für viele kleine Dateien → Master als Flaschenhals
    - Master-Ausfall problematisch für latenzsensitive Anwendungen
- 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.*

- Unterstützung auf strukturierten Daten basierender Anwendungen
  - 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*

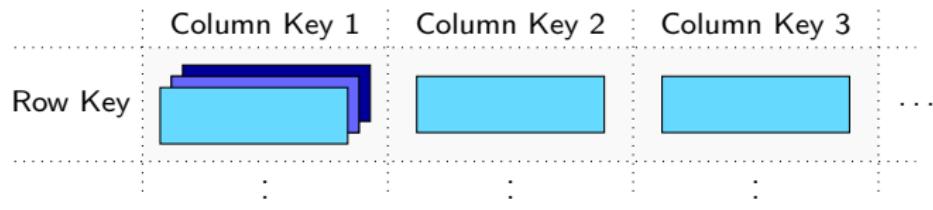
## ■ Literatur



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



- 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

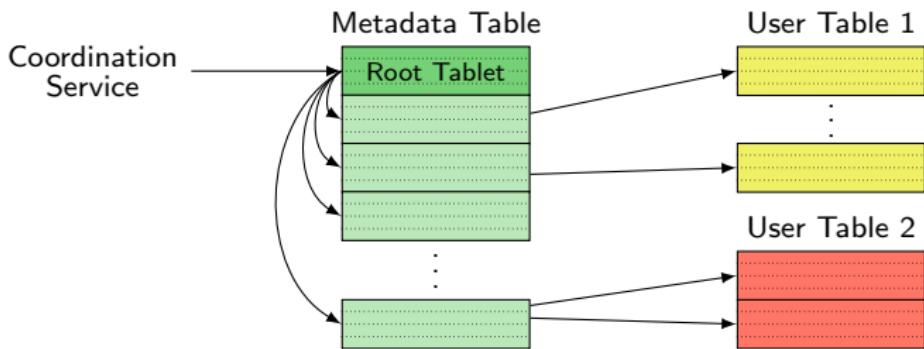


- Skalierbarkeit durch Partitionierung von Tabellen
  - *Tablet*: Zusammenhängender Abschnitt benachbarter Zeilen
  - Zuordnung verschiedener Tablets zu unterschiedlichen Servern
  - Oft gemeinsam gelesene Einträge sollten benachbarte Schlüssel haben



## ■ Hierarchie

- Metadatentabelle: Informationen zu Tablets von Nutzertabellen
- *Root-Tablet*: Verwaltung der Struktur der Metadatentabelle
- Koordinierungsdienst: Speicherung eines Zeigers auf das Root-Tablet



## ■ 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 Windows Azure Storage.]

