Überblick

Datenverwaltung in der Cloud

- Motivation
- Google File System
- Windows Azure Storage: Stream Layer
- Zusammenfassung

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 Symposium on Principles of Distributed Computing (PODC '00), page 7, 2000.

Google File System

- Anforderungen
  - Einsatz 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
- Literatur

Sanjay Ghemawat, Howard Gobioff, and Shun-Tak Leung
The Google file system
Proceedings of the 19th Symposium on Operating Systems Principles (SOSP '03), pages 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
  - Lesezugriffe
    - Lesen großer, oftmals zusammenhängender Bereiche einer Datei
    - Lesen kleiner Teilbereiche einer Datei, dazwischen Sprünge
  - Schreibzugriffe
    - Schreibanfragen hängen in der Regel große Datenmengen an eine Datei an
    - Wahlfreies Schreiben ist die Ausnahme, muss jedoch unterstützt werden
- Weitere Eigenschaften
  - Eine einmal geschriebene Datei wird meistens nicht mehr modifiziert
  - Häufig paralleles Anhängen an die selbe Datei durch mehrere Prozesse
  - Hoher Durchsatz wichtiger als kurze Antwortzeiten für einzelne Anfragen

Schnittstelle

- Hierarchische Datenverwaltung
  - Verzeichnisse
  - Dateien
- An 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 und einer replizierten Log-Datei
      - Zuordnung von Datenblöcken auf Dateien
      - Speicherorte von Datenblöcken ($\rightarrow$ Chunk-Server)
      - Zugriffsberechtigungen von Clients
    - 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
  - Einer der Server wird vom Master per Lease zum *Primary* ernannt, alle anderen Server übernehmen die Rolle von *Secondaries*
- Vorgehensweise bei Schreibanfragen auf Datenblöcken

1. Client fragt Master nach für den Datenblock zuständigen Chunk-Servern, Client speichert Master-Antwort für spätere Anfragen in lokalem Cache
2. Client sendet Nutzdaten zum ,,nähesten" zuständigen Chunk-Server, von wo aus sie an die anderen Chunk-Server verteilt werden
   [Hinweis: Die Identifizierung des ,,nähesten" Server erfolgt mit Hilfe einer auf IP-Adressen basierenden Metrik.]
3. Sobald alle Chunk-Server den Empfang der Daten bestätigt haben, sendet der Client das eigentliche Schreibkommando an den Primary
4. Primary leitet Schreibkommando an Secondaries weiter
5. Chunk-Server führen Schreiboperation aus
6. Primary sammelt Bestätigungen aller zuständigen Chunk-Server
7. Primary sendet Erfolgsmeldung an Client

Schreiboperationen

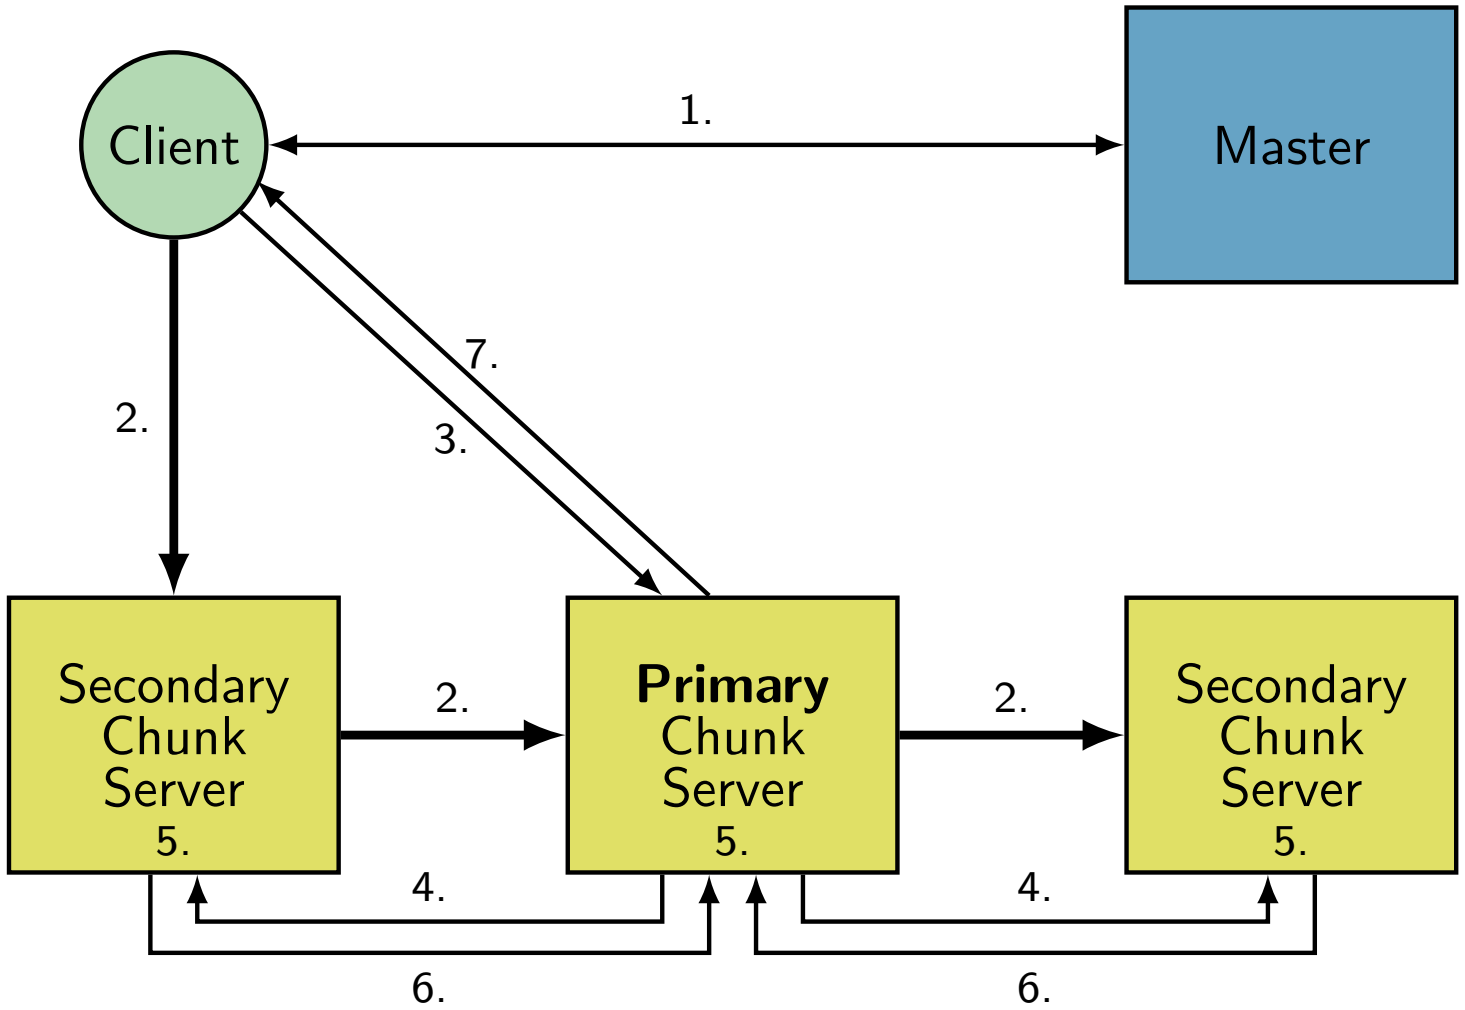

Weitere Operationen

- `append`-Operation
  - Atomares Anhängen von Daten an eine Datei
  - Typischer Anwendungsfall: Paralleles Schreiben in die selbe 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 Anhängeoperation auf dem nächsten Datenblock wiederholen
    - Primary teilt Client 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 „nähesten" zuständigen Chunk-Server

Umgang mit Fehlersituationen

- Mechanismen zur effizienten Behandlung von Master-Ausfällen
  - Replikation des Zustands über mehrere Rechner ($\rightarrow$ Log-Datei)
  - Relativ kleiner Master-Zustand $\rightarrow$ Schneller Neustart möglich
  - Einsatz von *Shadow-Master-Servern* für nicht-modifizierende Anfragen
- Behandlung von Chunk-Server-(Teil-)Ausfällen
  - Datenkorruption
    - Bei Leseanfragen: Chunk-Server überprüfen die Integrität der gespeicherten Daten mittels Checksummen über 64 KB-Blöcke
    - Falls Fehler erkannt werden $\rightarrow$ Meldung an den Master
    - Master leitet Erstellung eines neuen Replikats ein
  - Rechnerausfall
    - HeartBeat-Nachrichten an den Master bleiben aus
    - Master leitet Erstellung eines neuen Replikats ein
    - Master bestimmt nach Ablauf der Leases neue Primaries für Datenblöcke
    - Erkennung veralteter Datenblockversionen durch Einsatz von Lease-Epochen

Umgang mit Fehlersituationen

- 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
    - Der 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
    - Berechnung von Checksummen durch die Anwendung
    - Einsatz von selbstverifizierenden, selbstidentifizierenden Datensätzen

Windows Azure Storage

- Storage Stamp
  - Front-End Layer: Empfang von Client-Anfragen
  - Partition Layer: Verwaltung von Blobs, Tabellen und Warteschlangen
  - **Stream Layer**: Direkter Zugriff auf Festplatten
- Replikation auf zwei Ebenen
  - Innerhalb eines Stamp
    - Aufgabe des Stream Layer
    - Synchrone Replikation während des Schreibvorgangs
  - Zwischen Stamps
    - Aufgabenteilung zwischen Partition Layer und Ortsdienst
    - Asynchrone Replikation im Hintergrund
- Literatur

Brad Calder, Ju Wang, Aaron Ogus, Niranjan Nilakantan et al. **Windows Azure Storage: A highly available cloud storage service with strong consistency.** *Proceedings of the 23rd Symposium on Operating Systems Principles (SOSP '11)*, pages 143–157, 2011.

- *Block*
  - Kleinste Dateneinheit für Lese- und Schreibaufrufe (variable Größe)
  - Periodische Überprüfung der Datenintegrität mittels Checksummen
- *Extent*
  - Datei (NTFS) mit aufeinander folgenden Blöcken
  - Zustände
    - Unversiegelt (*unsealed*): **Anhängen** weiterer Blöcke möglich
    - Versiegelt (*sealed*): Nur noch lesender Zugriff erlaubt
- *Stream*
  - Liste von Referenzen auf Extents
  - Nur der letzte Extent eines Stream ist unversiegelt

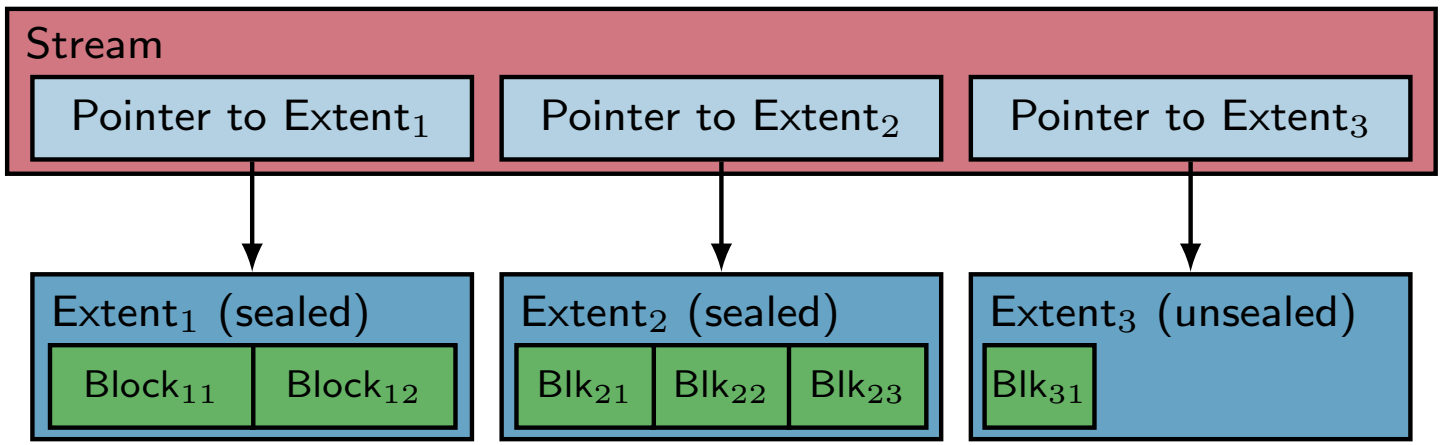

- Extent Nodes
  - Datenspeicherknoten
  - Aufgaben
    - Speicherung von Extents und ihrer Checksummen
    - Abbildung von Extent-Offsets zu Blöcken
  - Mehrere Festplatten pro Rechner
- Stream Manager
  - Verwaltungsknoten
  - Aufgaben
    - Erzeugung von Extents und Zuordnung zu Extent Nodes
    - Überwachung der Extent Nodes
    - Extent-Replikation zur Kompensation nach Hardware-Ausfällen
    - Garbage-Collection für nicht mehr referenzierte Extents
  - Verwaltung von Stream- und Extent-Informationen im Hauptspeicher
  - Stream Manager selbst ist ebenfalls repliziert

Schreiben von Daten – Normalfall

- Anlegen eines neuen Extent
  - Partition Layer weist Stream Manager an, einen neuen Extent zu erstellen
  - Stream Manager wählt drei Extent Nodes (einen *Primary*- und zwei *Secondary*-Knoten) aus verschiedenen Fehlerdomänen aus
- Hinzufügen eines Blocks zu einem Extent
  - Partition Layer sendet Block an Primary Extent Node
  - Primary Extent Node zuständig für Koordinierung des Schreibaufrufs
    - Auswahl des Offset im Extent
    - Weiterleitung der Anfrage an die Secondary Extent Nodes
  - Primary Extent Node sendet Erfolgsbestätigung an Partition Layer

→ Schreiben eines Blocks erfolgt ohne Einbeziehung des Stream Manager

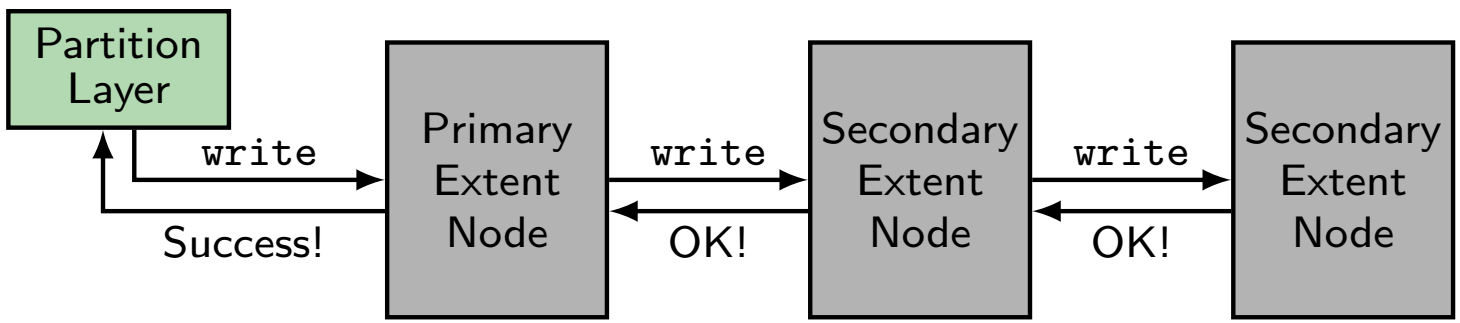

Schreiben von Daten – Fehlerfall

- Fehlersituationen (Beispiele)
  - Fehlermeldung, dass ein Extent Node nicht erreichbar war
  - Fehlende Erfolgsbestätigung innerhalb einer vordefinierten Zeitspanne

  → Partition Layer kontaktiert Stream Manager
- Ausnahmebedingtes Versiegeln des aktuellen Extent
  - Stream Manager befragt Extent Nodes nach aktuellem Extent-Offset
  - Versiegelung des Extent am kleinsten genannten Offset
- Anlegen eines (Ersatz-)Extent
  - Auswahl einer neuen Gruppe von Extent Nodes
  - Wiederholung der Schreiboperation
- Anmerkungen
  - Alle als ,,erfolgreich hinzugefügt" bestätigten Daten bleiben erhalten
  - Ein einmal geschriebener Block wird u. U. mehrmals gespeichert

  → Partition Layer muss damit umgehen können

- Optimierung von Schreibzugriffen
  - Problem
    - Intra-Stamp-Replikation erfolgt synchron → direkter Einfluss auf Antwortzeit
    - Primary Extent Node muss auf Bestätigungen von Secondaries warten
    - Bestätigung kann erst erfolgen, wenn der Block persistent gesichert wurde

    → Instabile Antwortzeiten in Überlastsituationen („hiccups")
  - Lösung
    - Einsatz einer zusätzlichen Festplatte (*Journal Drive*)
    - Doppelte Ausführung jeder Schreiboperationen: Journal Drive + Daten-Disk
    - Senden der Bestätigung sobald einer der beiden Aufrufe erfolgreich war
- Lastbalancierung für Leseanfragen
  - Festlegung einer zeitlichen Schranke für die Bearbeitung einer Anfrage
  - Senden der Anfrage an einen für den Block zuständigen Extent Node
  - Extent Node schätzt ab, ob sich die zeitlichen Schranke einhalten lässt
    - Falls ja: Bearbeitung der Anfrage
    - Falls nein: Sofortige Ablehnung der Anfrage
  - Bei Ablehnung: Neuer Versuch bei anderem Extent Node

Zusammenfassung

- Google File System
  - Ausrichtung auf Anwendungen mit bestimmten Zugriffsmustern
    - Lesen großer, zusammenhängender Bereiche einer Datei
    - Schreiben von Datensätzen durch Anhängen
  - Fehlertoleranz durch Replikation
  - Abgeschwächtes Konsistenzmodell
    - Abweichendes Verhalten bei Fehlern im Vergleich zu gewöhnlichen Dateisystemen möglich (z. B. einmalig geschriebener Datensatz)
    - Spezielle Vorkehrungen auf Anwendungsebene erforderlich
- Windows Azure Storage Stream Layer
  - Beschränkung auf eine Schreiboperation: Anhängen von Daten
  - Replikation auf verschiedene Fehlerdomänen
  - Ähnliche Konsistenzgarantien wie beim Google File System
  - Optimierungen zur Kompensation von Lastschwankungen