Überblick

Aufbau einer Datenspeicher-Cloud
- Motivation
- Windows Azure Storage

Motivation

- Weltumspannendes System zur Speicherung von Daten
  - Heterogenes Nutzungsverhalten
    - Eigene Dienste des Cloud-Betreibers vs. Anwendungen unabhängiger Nutzer
    - Nutzung als Zwischenspeicher vs. Langzeitspeicherung von Daten
    - Verwaltung strukturierter vs. unstrukturierter Daten
  - Ort der Datenspeicherung
    - Global: Latenzüberlegungen, rechtliche Bestimmungen,...
    - Lokal: Art der Anbindung an die Rechen-Cloud desselben Anbieters
  - Großes Spektrum an möglichen Fehlersituationen
    - Defekte einzelner Rechnerkomponenten (z. B. Festplatten)
    - ⋮
    - Ausfall ganzer Datenzentren
- Herausforderungen
  - Welche Datenstrukturen soll die Datenspeicher-Cloud anbieten?
  - Wie feingranular bestimmt ein Nutzer den Speicherort seiner Daten?
  - Wie tiefgreifend sollen die Maßnahmen zum Schutz vor Datenverlust sein?

Windows Azure Storage

- Anforderungen
  - Starke Konsistenz
  - Globaler Namensraum
  - Kein Datenverlust bei Katastrophen
  - Niedrige Kosten
- Windows Azure Storage
  - Einheitliches Speichersystem für unterschiedliche Nutzdaten
  - Trennung des Datenspeichers vom Rest der Cloud
  - Rückgriff auf das Domain Name System (DNS)
  - Georeplikation über mehrere Datenzentren
- 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), S. 143–157, 2011.

Adressierung von Datenobjekten

- Verfügbare Datenobjekte
  - *Blobs* [Binary large objects]
  - Tabellen
  - Warteschlangen
- Typischer Einsatz von Objekten
  - Eingabedaten: Blobs
  - Zwischenergebnisse und Ausgabedaten: Blobs oder Tabellen
  - Koordinierung: Warteschlangen
- Globaler partitionierter Namensraum

`[Protokoll]://[Konto].[Dienst].core.windows.net/[Partition]/[Objekt]`

  - Protokoll: `http` bzw. `https`
  - Kontoname des Nutzers (→ Speicherort) als Teil des DNS-Host-Namens
  - Dienst: `blob`, `table` oder `queue`
  - Identifikation eines Objekts mittels Partitions- und Objektname

Architektur

- *Storage-Stamp*
  - Gruppe aus mehreren Racks
  - Racks besitzen eigene Netzwerk- und Stromanbindungen → *Fehlerdomänen*
  - Stamp von außen über eine eigene IP-Adresse erreichbar
- Ortsdienst
  - Zuordnung von Nutzerkonten zu Stamps
  - Stamp-Auswahl für neue Konten
  - Aktualisierung der Stamp-Adressen im DNS

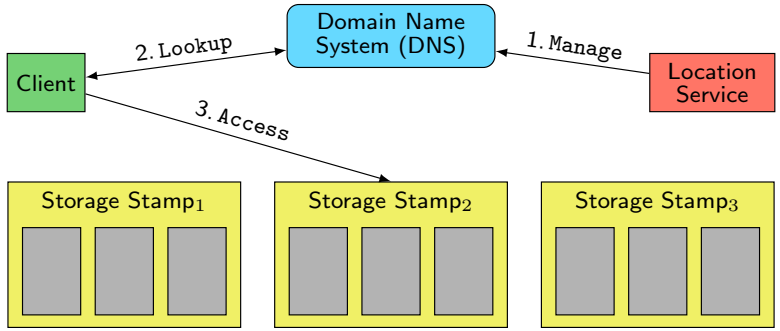

Storage-Stamp

- Front-End-Layer
  - Authentifizierung eintreffender Anfragen
  - Weiterleitung von Anfragen an den Partition-Layer
- Partition-Layer
  - Verwaltung von Blobs, Tabellen und Warteschlangen
    - Zusammenfassung kleiner Objekte
    - Aufteilung großer Objekte in Partitionen
  - Verwaltung von Partitionen
    - Einteilung und Zuordnung zu Servern
    - Lastverteilung zwischen Servern
  - Replikation über mehrere Stamps
- Stream-Layer
  - Direkter Zugriff auf Festplatten
  - Bereitstellung von Datenströmen (*Streams*)
  - Stamp-interne Replikation

Replikation

- Replikation innerhalb eines Stamp (*Intra-Stamp Replication*)
  - Aufgabe des Stream-Layer
  - Synchrone Replikation während des Schreibvorgangs
    - Speicherung der Replikate in unterschiedlichen Fehlerdomänen
    - Replikation auf Binärdaten-Ebene
    - Typischer Replikationsfaktor: 3
  - Im Fehlerfall: Rekonfigurierung der Replikatgruppe
- Replikation zwischen Stamps (*Inter-Stamp Replication*)
  - Aufgabenverteilung
    - Ortsdienst: Nutzerkonto-spezifische Konfiguration
    - Partition-Layer: Durchführung
  - Asynchrone Replikation im Hintergrund [Vergleiche: Einsatzszenario von Google's B4.]
    - Replikation auf Objektebene
    - Durchschnittlich ca. 30s nach dem Schreibvorgang
    - Typischer Replikationsfaktor: 2
  - Im Fehlerfall: Failover durch Anpassung des DNS-Eintrags eines Kontos

Stream-Layer — Interne Datenstrukturen

- Block
  - Kleinste Dateneinheit für Lese- und Schreibaufrufe (variable Größe)
  - Periodische Überprüfung der Datenintegrität mittels Checksummen
- Extent
  - NTFS-Datei 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

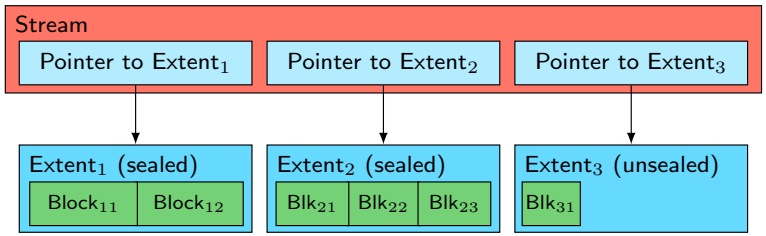

Stream-Layer — Komponenten

- Extent-Nodes
  - Datenspeicherknoten
  - Aufgaben
    - Speicherung von Extents und ihren 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
  - Replikation des Stream-Manager-Zustands

[Vergleiche: Aufgabenverteilung zwischen Komponenten im Google File System]

Stream-Layer — 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 [Vergleiche: Schreiben im Google File System]
  - Partition-Layer sendet Block an Primary
  - Primary zuständig für Koordinierung des Schreibaufrufs
    - Auswahl des Offset im Extent
    - Weiterleitung der Anfrage an die Secondaries
  - Primary sendet Erfolgsbestätigung an Partition-Layer

→ Schreiben eines Blocks erfolgt ohne Einbeziehung des Stream-Managers

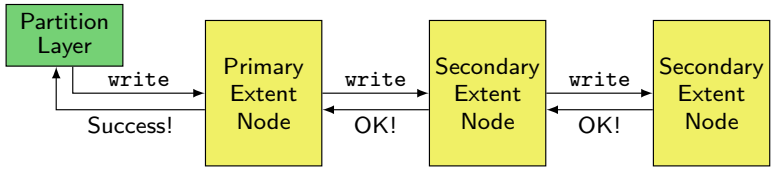

Stream-Layer — Schreiben von Daten – Fehlerfall

- 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 Anhängeoperation
- Anmerkungen
  - Alle als „erfolgreich hinzugefügt“ bestätigten Daten bleiben erhalten
  - Ein einmal geschriebener Block wird u. U. mehrmals gespeichert

→ Partition-Layer muss mit solchen Konsistenzgarantien umgehen können

Stream-Layer — Optimierungen

- Optimierung von Schreibzugriffen
  - Problem
    - Intra-Stamp-Replikation erfolgt synchron → direkter Einfluss auf Antwortzeit
    - Primary 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 zeitliche Schranke einhalten lässt
    - Falls ja: Bearbeitung der Anfrage
    - Falls nein: Sofortige Ablehnung der Anfrage
  - Bei Ablehnung: Neuer Versuch bei anderem Extent-Node

Partition-Layer — Komponenten

- Zentrale Datenstruktur: Objekttabelle [Vergleiche: Google's Bigtable]
  - Speicherung sehr großer Datenmengen [→ Petabytes]
  - Aufteilung in disjunkte *Range-Partitions*
  - Beispiele
    - Account-Table: Verwaltung von Informationen über Nutzerkonten
    - Partition-Map-Table: Zuordnung von Range-Partitions zu Objekttabellen
- Komponenten
  - Lock-Service
    - Vergleiche: Koordinierungsdienste [Siehe spätere Vorlesung.]
    - Vergabe von Leases für Range-Partitions an Partition-Server
  - Partition-Server
    - Verwaltung der ihm zugeteilten Range-Partitions
    - Persistente Speicherung von Daten mittels Stream-Layer
  - Partition-Manager
    - Zuweisung von Range-Partitions zu Partition-Servern
    - Mehrere Instanzen pro Stamp: Auswahl eines Anführers per Lock-Service

Partition-Layer — Partition-Server

- Kombination aus flüchtigen und persistenten Datenstrukturen
  - Memory-Table für effizienten Lesezugriff
  - Commit-Log-Strom zum Schutz vor Datenverlust

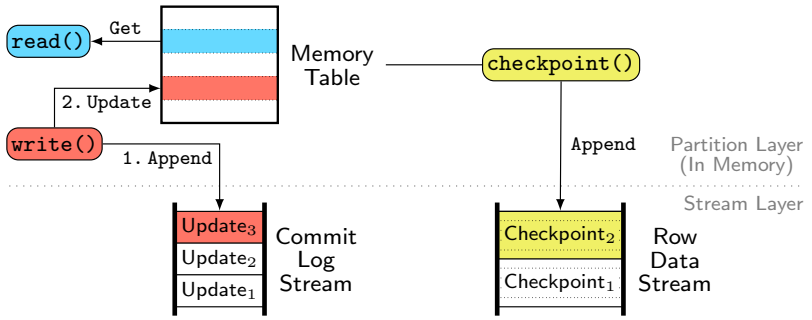

- Erstellen von Sicherungspunkten
  - Auslöser: Commit-Log / Memory-Table erreichen eine bestimmte Größe
  - Erzeugen eines Sicherungspunkts aus dem Inhalt der Memory-Table
  - Aufräumen des Commit-Log

Partition-Layer — Lastbalancierung

- Migration einer Range-Partition von PS_A nach PS_B [PS: **P**artition-**S**erver]
  1. Partition-Manager weist PS_A an, die Partition zu migrieren
  2. PS_A erstellt Sicherungspunkt der Partition
  3. Partition-Manager aktualisiert die Partition-Map-Table
  4. PS_B lädt Range-Partition
- Teilung einer von PS_C verwalteten Range-Partition P
  1. Partition-Manager weist PS_C an, die Partition zu teilen
  2. PS_C erstellt Sicherungspunkt von P
  3. PS_C erzeugt die Datenstrukturen für die Partitionsteile P_1 und P_2 basierend auf den Inhalten der Datenstrukturen von P
  4. PS_C verwaltet sowohl P_1 als auch P_2
  5. Partition-Manager aktualisiert die Partition-Map-Table
  6. P_1 oder P_2 wird auf einen anderen Partition-Server migriert
- Zusammenlegung zweier Range-Partitions: Invers zur Teilung