Middleware – Cloud Computing

Aufbau einer Datenspeicher-Cloud

Wintersemester 2024/25

Tobias Distler

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

Lehrstuhl für Informatik 4
Systemsoftware

Überblick

Aufbau einer Datenspeicher-Cloud

- Motivation
- Microsoft 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
  - Wie feingranular bestimmt ein Nutzer den Speicherort seiner Daten?
  - Wie tiefgreifend sollen die Maßnahmen zum **Schutz vor Datenverlust** sein?

Überblick

Microsoft Azure Storage

- **Anforderungen** [Werden sie erfüllt?]
  - Starke Konsistenz
  - Globaler Namensraum
  - Kein Datenverlust bei Katastrophen

- **Microsoft Azure Storage** (früher: *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, Arild Skjolsvold et al.
Windows Azure Storage: A highly available cloud storage service with strong consistency
Proc. of the 23rd Symp. 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 ($\rightarrow$ 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

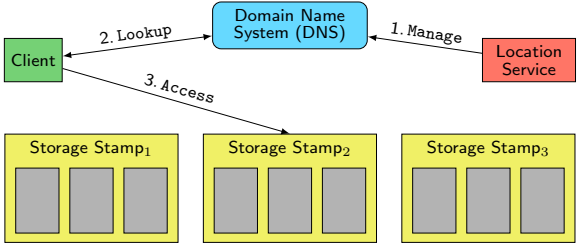

Storage-Stamp

- **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
- **Stream-Layer**
  - Direkter Zugriff auf Festplatten
  - Bereitstellung von Datenströmen (*Streams*)

Replikation

- Replikation zwischen Stamps (*Inter-Stamp Replication*)
  - Aufgabe des Partition-Layer (nach Konfiguration durch den Ortsdienst)
  - **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**

- Replikation innerhalb eines Stamp (*Intra-Stamp Replication*)
  - Aufgabe des Stream-Layer
  - **Synchrone Replikation während des Schreibvorgangs**
    - Replikation auf Binärdaten-Ebene
    - Speicherung der Replikate in unterschiedlichen Fehlerdomänen
    - Typischer Replikationsfaktor: 3
  - Im Fehlerfall: Rekonfigurierung bzw. **Wechsel der Replikatgruppe**

- 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**

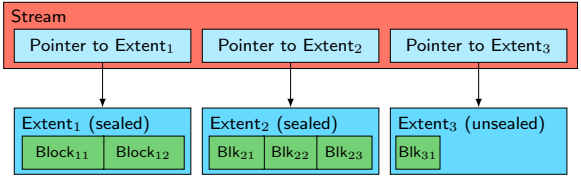

- **Extent-Nodes**
  - Datenspeicherknoten
  - Aufgaben
    - **Speicherung von Extents**
    - Abbildung von Extent-Offsets zu Blöcken
  - Mehrere Festplatten pro Rechner
- **Stream-Manager**
  - Verwaltungsknoten
  - Aufgaben
    - **Erzeugung von Extents und Zuordnung zu Extent-Nodes**
    - Überwachung 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]

- **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**

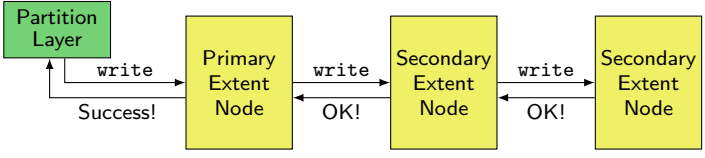

- **Fehlersituationen** (Beispiele)
  - Fehlermeldung, dass ein Extent-Node nicht erreichbar war
  - Fehlende Erfolgsbestätigung innerhalb einer vordefinierten Zeitspanne

  → 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 **eventuell mehrmals gespeichert**

  → Partition-Layer muss mit solchen Konsistenzgarantien umgehen können

- 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 Schreiboperation**: Journal-Drive + Daten-Disk
  - Senden der Bestätigung, sobald einer der beiden Aufrufe erfolgreich war

- Problem
  - Latenzausreißer bei Leseanfragen
  - Ungleichmäßige Lastverteilung zwischen Rechnern
- Lösung
  - 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

- Zentrale Datenstruktur: **Objekttabelle** [Vergleiche: Google's Bigtable]
  - Speicherung sehr großer Datenmengen [→ Petabytes]
  - Aufteilung in **disjunkte *Range-Partitions***
  - Beispiele
    - Blob-Table: Tabelle mit allen Blobs eines Stamp
    - Partition-Map-Table: Zuordnung von Range-Partitions zu Objekttabellen
- Komponenten
  - 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
  - Lock-Service
    - Vergleiche: Koordinierungsdienste [Siehe spätere Vorlesung.]
    - Vergabe von Leases für Range-Partitions an Partition-Server

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

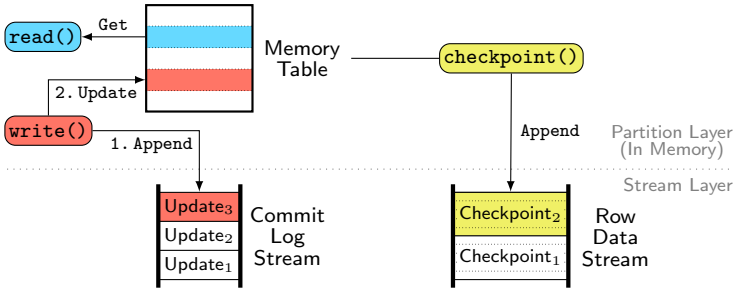

- Erstellen von **Sicherungspunkten**
  - Auslöser: Commit-Log erreicht eine bestimmte Größe
  - Erzeugen eines Sicherungspunkts aus dem Inhalt der Memory-Table
  - Aufräumen des Commit-Logs