


„NoSQL Datenbanken am Beispiel von HBase“

Daniel Georg

NoSQL

~~No to SQL at all~~ sondern **Not only SQL**

Open-Source Community

Erst im Jahr 2009 gestartet

Community bietet verschiede Lösungen:
Casandra, CouchDD, HBase, Hypertable…


Anforderungen

- Performance bei high-load Projekten
- Skalierbarkeit
- Erweiterbarkeit
- Verfügbarkeit
- Antwortzeit

BigTable von Google

- **Datenmodell**
  - Eine dünn besetzte, verteilte, sortierte und mehrdimensionale Abbildung.
  - Jeder Eintrag in der Abbildung wird als row key, column key, und timestamp : **(row:string, column:string, time:int64) ➔ string** indiziert.

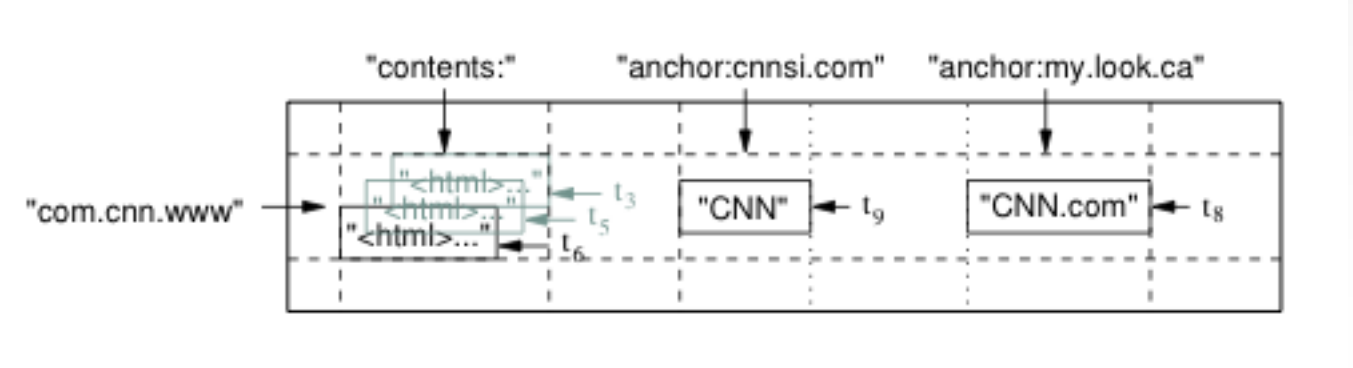

BigTable von Google

- **Datenmodell**
  - **Zeilen** in den Tabellen sind nach dem Schlüssel in der lexikographischen Ordnung sortiert.
  - Lese- Sreibzugriffe sind atomar.

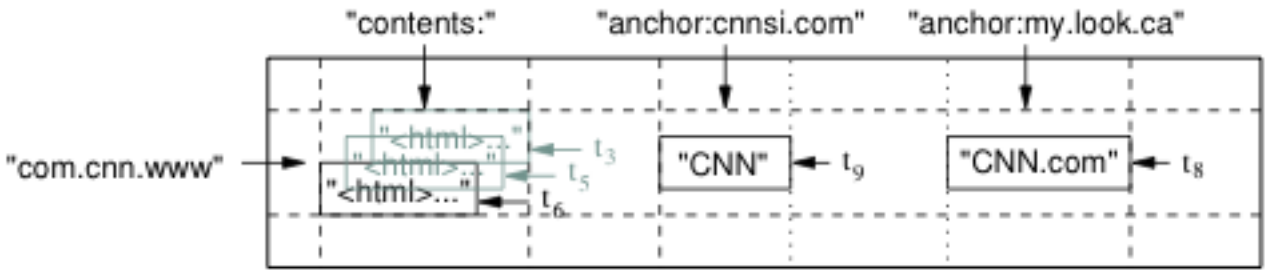

BigTable von Google

- **Datenmodell**
  - **Spalten-Schlüssel** sind in Gruppen organisiert und werden Spaltenfamilien (colum-family) genannt.
  - Der Schlüssel wird aus **family:qualifier** gebildet

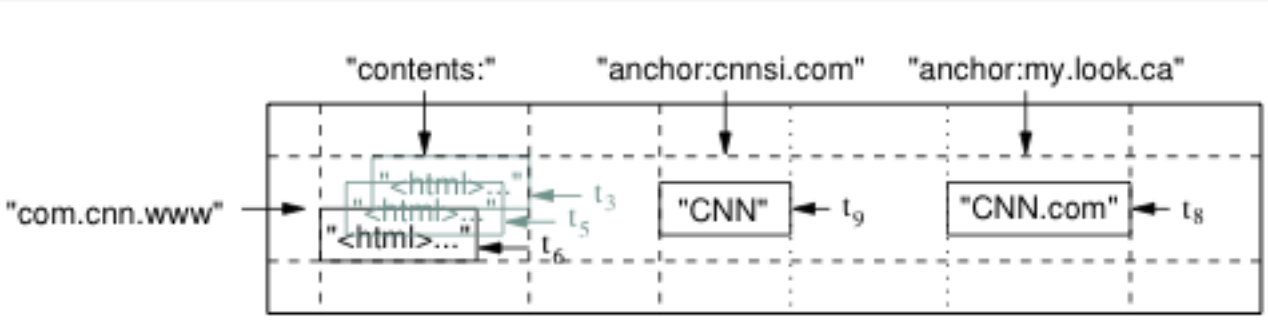

BigTable von Google

- **Datenmodell**
  - Mehrere Versionen pro Zeile
  - Jede Version hat einen eigenen **Zeitstempel**
  - Ermöglicht Automatische Entfernung von veralteten Daten.

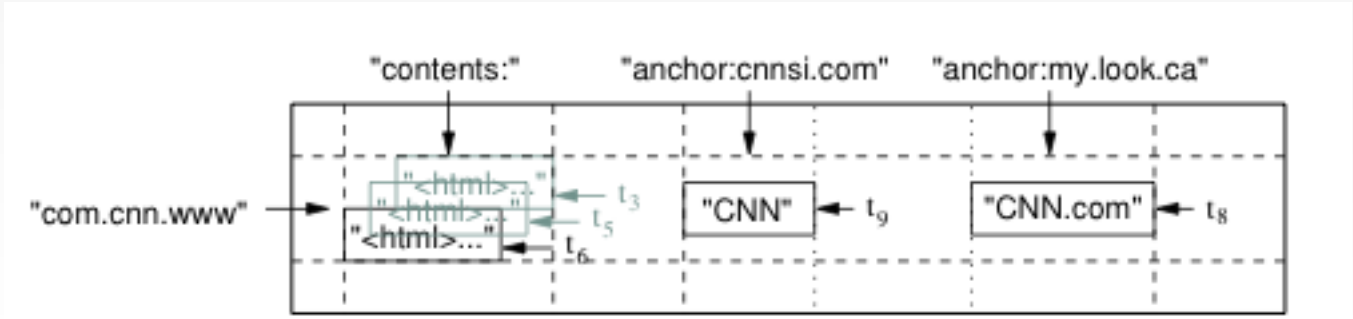


Architektur von BigTable

- BigTable-Cluster bestehen aus dem Master-Server und einer Menge von Tablet- Servern.
- Jeder Tablet-Server ermöglicht den Zugriff auf bestimmte Tablets.
- Zur Speicherung des Standortes der Tablets wird eine dreistufige Hierarchie verwendet.


Architektur von BigTable

- **Aufgaben von Master-Server:**
  - Verteilungen von Tablets auf die Tablet- Server.
  - Überwachung von Tablet-Servern, Load-Balancing zwischen Servern.
  - Entfernung von veralteten Daten.
  - Steuert die Erzeugung und Änderungen von Tabellen sowie der Family-Columns.


Architektur von BigTable

- **Aufgaben von Tablet-Server:**
  - Verarbeiteten die Lese-Schreibanfragen an die betreuten Tablets.
  - Teilung von Tablets.
  - Dynamisches Hinzufügen oder Entrnen im Cluster.

Architektur von BigTable

- **Dreistufige Hierarchie**
  - Root tablet
    - Verweise auf Metadaten Tablet
    - Im Chubby geschpeichert
    - Wird Nie aufgetielt
  - Metadaten Tablet
    - Verweise auf User Tablets
  - User Tablets

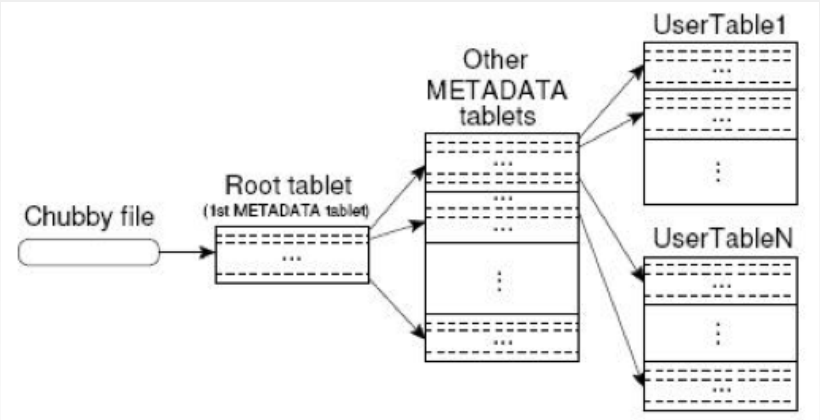


Architektur von BigTable

- **Tablets**
  - Im Form einer Datei auf GFS abgelegt.
  - Alle Änderungen werden im Log-File gespeichert.
    - Neue Änderungen im Puffer gescpeichert (memtable)
    - Älteren Änderungen in dem SSTables gespeichert.
  - Verdiechtung:
    - Aus Memtables wird eine SSTable erzeugt.
    - Aus Mehreren SSTables wird eine SSTable erzeug.
    - Alle Memtables und SSTables werden in eine SSTable vermischt.


- Eine OpenSource Alternative zum BigTable-System
- Änliche Datenmodell und Realisation
- HBase verwendet eine etwas andere Terminologie als BigTable
- Existieren kleine spezifische Unterschiede


- **Unterschiede**:
  - Tablet als Region bezeichnet
  - Server die Regionen betreuen sind RegionServer
  - Die Daten werden auf Familien von Spalten aufgeteilt
  - Jede Familie wird in Store geschpeichert
  - Store ist Analog zu SSTable
  - Die Daten werden auf dem HDFS abgelegt und heißen StoreFiles
  - Hbase verwendet kein Chubby Service
  - Ist in Java realisiert


Yahoo PNUTS

- Daten können als geordnete oder gehashte Datenstruktur gespeichert
- Speziell für Webapplikationen etwikelt
- Arbeitet mit Duplikaten
- Hinzufügen von neuen Attributen wärend der Laufzeit möglich
- Geografisch orientiertes Datenbanksystem


Yahoo PNUTS

- **Anfragemodell**
  - Selektionen und Projektionen auf die einfachen Tabellen
  - Beim Update oder Delete muss erstmal der Primärschlüssel deklariert werden
  - Unterstützt keine Join- oder Gruppierungs Anfragen

Yahoo PNUTS

- **per-record- time-consistency**
  - Die Repliken bewegen sich immer vorwärts auf dem Zeitstrahl.
  - Jeder Datensatz hat eine Nummer
  - Nummer besteht aus der Generation und der Versionsnummer
  - Jedes Insert ist eine neue Generation
  - Bei jeden Update wird eine neue Version erzeugt.

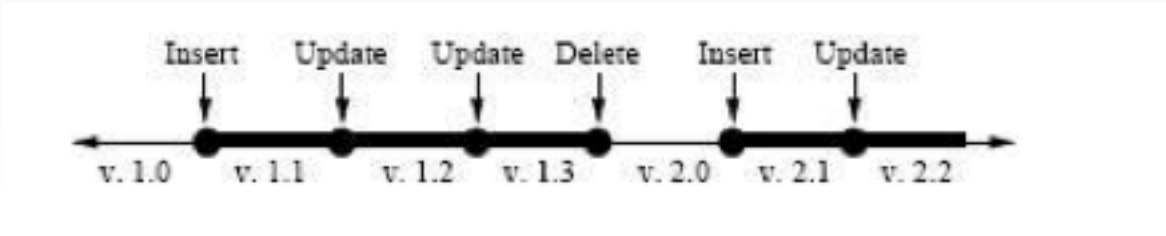


Yahoo PNUTS

- **per-record- time-consistency bietet eine Reihe von API Funktionen:**
  - Read-any
  - Read-critical (requered_version)
  - Read-lastes
  - Test- and-set-write(required)

Architektur von Yahoo PNUTS

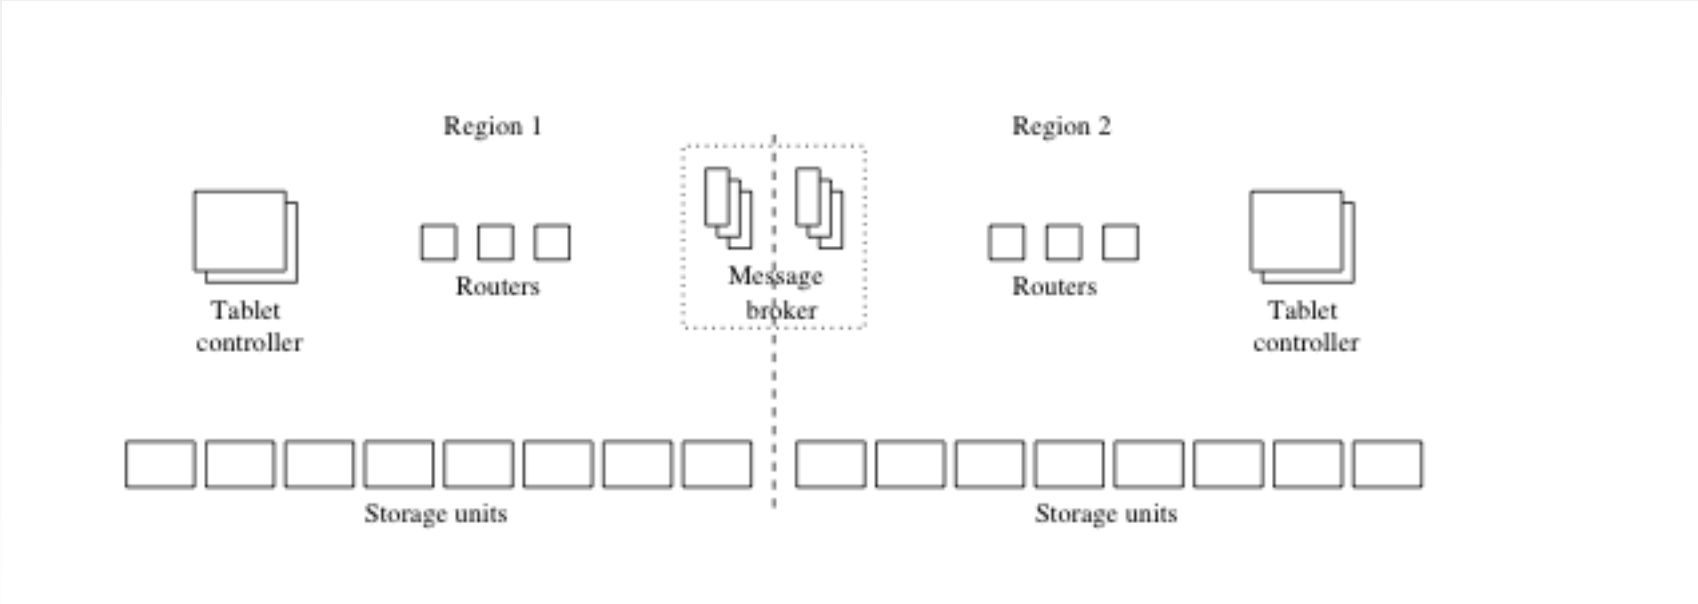


Architektur von Yahoo PNUTS

- Das System wird in Regionen geteilt.
- Jedes Region hat alle benötige Systemkomponenten und eine Kopie von allen Tabellen.
- Verwendung von Archiven oder Backups unnötig.
- Tabellen sind in Tablets unterteilt.
- Jedes Tablet ist innerhalb einer Region nur auf einen Server gespeichert.


Architektur von Yahoo PNUTS

- **Storage-Units**
  - Hier werden die Tablets gespeichert
  - Beantworten die get(), set() und scan() anfragen
  - Bei Hash-Tabellen wird ein Unix Dateisystem verwenden
  - Für die geordnete Tabelle wird mySQL mit InnoDB verwendet


Architektur von Yahoo PNUTS

- **Router**
  - Bestimmt welche Storage-Unit für einen zu lesenden oder zu schreibenden Datensatz zuständig ist.
  - Der Router speichert eine Liste mit den Intervallen und den dazugehörigen Storage-Units.
- **Tablet-Controller**
  - Führt mappen
  - Teilt die Tablets


Architektur von Yahoo PNUTS

- **Yahoo Message-Broker**
  - Ersatz zum Redo-log
  - Für das Replizieren und Protokollieren zuständig
  - Änderungen werden erstmal dem YMB übergeben, danach verteilt YMB asynchron die Änderungen auf verschiedene Regionen und sie werden danach auf ihre eigenen Repliken angewandt.
  - Die Nachrichten gehen nicht verloren bevor sie auf die Datenbank angewendet wurden.