



Wegweiser


Scaling:

wie kriegen wir die
Cloud groß genug?





Scaling Dimensionen





Wegweiser

DB Scaling





Umgang mit Relationalen DBMSs

- Siehe Einführung
 - Scale-Up
 - Scale-Out
- Normalisierung + De-Normalisierung!
- Sharding
- Dimensionen:
 - Storage
 - Zugriffe/Performance
 - technische DB-Optimierung (z.B. Indizes, Caching)
- ...



Zoo an Alternativen aka NoSQL

- In Memory DBs: SAP HANA; memcached, eXtremeDB
- Caches: memcached, redis
- Key-Value Stores: redis, Amazon Dynamo, Apache Cassandra
- Dokumenten DBs: CouchDB, MongoDB
- Graph DBs: InfoGrid, Neo4j
- Object DBs: ZopeDB, Gemstone
- ...



NoSQL: Häufige Eigenschaften

- Nomen est Omen – keine SQL basierte Abfrage => aber bewegt sich in die Richtung
- Verzicht auf striktes ACID
- Eventual Consistent
- Einfache Skalierbarkeit durch Daten Verteilung / Sharding => siehe Consistent Hashing.
- Spezialisierter Use-Case
- Keine oder weniger „strikte“ Schemata



Beispiel:

Apache



Cassandra

- Open Source, ursprünglich entwickelt von Facebook
- Konzepte übernommen von
 - Amazons Dynamo DB (der Core Entwickler von Cassandra hat vorher an Dynamo mitentwickelt)
 - Google BigTable
- Kommerzieller Support von DataStax
 - (inkl. AWS Deployment, falls gewünscht)



Cassandra Konzepte (1)

- Peer-to-Peer Modell - kein Master => Gossip Protokoll
- Automatische Replikation / Verteilung => Consistent Hashing
- Multi-Datacenter Support
- Tuneable Consistency Modell (per Operation) – read repair
Konflikt Auflösung
- Hohe Performance => r/w skaliert weitestgehend linear mit
Anzahl der Knoten
- Hohe Verfügbarkeit => definierbarer Replikationsfaktor,
Hinted Handoff



Cassandra Konzepte (2)

- Key-Value++ / Column based
- Cassandra Query Language (CQL)
- Lightweight Transactions => PAXOS
- Map/Reduce support => Integration in Hadoop



Cassandra Tuneable Consistency

- Replikationsfaktor wird festgelegt
- $\text{Quorum} = \text{GanzZahligAbgerundet}(\text{Replikationsfaktor} / 2 + 1)$
- Verschiedene Konsistenzlevel (pro Operation wählbar)
- Konflikt Auflösung via Timestamp – neuster gewinnt
- Lesend (Auswahl):
 - ONE: Antwort des nächsten Knotens
 - Quorum: Antwort mit aktuellstem Zeitstempel aus Quorum Knoten
 - Local Quorum: wie Quorum aber nur aus einem Rechenzentrum
 - ALL: Antwort mit aktuellstem Zeitstempel nach Abfrage aller Replika-Knoten



Cassandra Tuneable Consistency

- Schreibend (Auswahl):
 - Any: Der Schreibzugriff muss persistiert sein (eventuell Lesen nicht möglich wenn die zuständigen Knoten nicht verfügbar => Hinted Handoff)
 - ONE: Der Schreibzugriff muss einem zuständigen Knoten persistiert sein (ist danach lesbar)
 - Quorum: der Schreibzugriff muss bei Quorum Knoten erfolgreich sein
 - Local Quorum: wie Quorum nur 1 RZ
 - All: der Schreibzugriff muss bei allen Replika-Knoten erfolgreich sein

Publikumsfrage –
Beispiele für verschiedene
Lese-/ Schreibszenarien



Cassandra Datenmodell

Keyspace (=> *Datenbank*)

Column Family (=> *Tabelle*)

Row

Column

Row Key:

Name:Value

Name:Value

Name:Value

Row Key:

...

...

Row

...

...

Bestimmt den zuständigen Knoten => Consistent Hashing

Der Inhalt der Row liegt „linear“ auf der Platte



Cassandra Datenmodell Beispiele

Keyspace: StudiDB

Column Family: Student

123:

Vorname:Paul

Nachname:
Muster

Note:1plus

124:

Vorname:Lisa

Email:l@d.de

```
create keyspace StudiDB;  
use StudiDB;  
create column family Student;  
set Student [,123'][,Vorname'] = ,paul'  
set Student [,123'][,Nachname'] = ,Muster'  
set Student [,123'][,Note'] = ,1plus'  
set Student [,124'][,Vorname'] = ,Lisa'  
...
```

```
...  
get Student[,123']  
=>(column-Vorname, value=Paul, timestamp=34324)  
=>(column-Nachname=Muster, timestamp=132423)  
=>(column...
```

```
get Student where note=,1plus'
```

Secondary
Index muss
gesetzt sein



Cassandra Randbedingungen

- Columns können hinten oder vorne hinzugefügt werden => implizite zeitliche Sortierreihenfolge möglich
- Löschen von Columns erzeugen „Tombstones“
 - => z.B: Queues sind ein Anti-Pattern
- Schreibzugriffe schneller als Lesen (disk commit log => Memtable => DataFile (Sorted Strings Table) & SSTableIndex & Bloomfilter)
- Vorsicht bei secondary Indexen auf Columns
 - Die Rows sind verteilt gespeichert
 - Niedrige Kardinalität (viele Duplikate) von Vorteil
 - Bei Hoher Kardinalität (und sehr kleine ausgeprägte Selektivität) zu hoher overhead => unnötige Anfragen an alle Knoten im Cluster

Level:ANY

Level:ONE