

# Google Spanner

Proseminar Ein-/Ausgabe Stand der Wissenschaft

Hanno Harte

Betreuer: Julian Kunkel

24.6.13

# Gliederung

- Überblick
- Funktionsweise
  - True Time
  - Konsistenzsemantik
- Benchmarks
- Zusammenfassung

# Überblick


- Projekt der GoogleInc. seit 2009
- Dezentralisiert
- Globale Datenbank
  - 13 Rechenzentren / 1 Million Server
  - Bald bis zu 10 Millionen Server ?
- Hohe Verfügbarkeit von Daten
  - Datenredundanzen
  - Verschiebung von Daten
- Geringe Latenz

# Überblick

## Exkurs SQL:

- Sprache in Datenbanken zur Bearbeitung und Abfrage von Datenbeständen
- Definition von Datenstrukturen
- Für relationale Datenbanken
- Angelehnt an englische Umgangssprache

# Überblick



## Beispiel Sql Datenbank

Student

<u>MatrNr</u>	Name
26120	Fichte
25403	Jonas
27103	Fauler

Hört

<u>MatrNr</u>	<u>VorlNr</u>
25403	5001
26120	5001
26120	5045

Vorlesung

<u>VorlNr</u>	Titel	<u>PersNr</u>
5001	ET	15
5022	IT	12
5045	DB	12

Professor

<u>PersNr</u>	Name
12	Wirth
15	Tesla
20	Urlauber

# Überblick

- Multi-versionale Datenbank mit Zeitstempel
- SQL ähnliches relationales Datenbanksystem
  - nicht vollständig relational




# Funktionsweise

- Zugriff auf eine Information in einer Google Datenbank
- Information in einer Tabelle
- SQL ähnliche relationale Datenbank
- Tabellen auf einem „Spannserver“
  - B-Trees auf „Colossus“

# Funktionsweise

- Background-Anwendung „Movedir“
  - erzeugt und löscht Replikationen
  - nicht blockierend
- 100-1000 Datenstrukturen auf einem Spannserver
  - genannt Tablet
- So genannter Paxos über dem Tablet

# Funktionsweise



# Exkurs Paxos:

- Protokolle zur Vereinfachung der Interaktion zwischen Prozessoren
- Anfrage an mehrere Prozessoren
- Eine Replikation pro Prozessor

# Exkurs Paxos:

Aufgaben der Prozessoren:

- Client
- Acceptor
- Proposer
- Leader
- Learner

# Exkurs Paxos:

- Long lived leader
- `tt.after(smax) = true`; `smax` = maximaler Zeitstempel
- Gleiche Zustände übermittelt
- Vereinfachung der Verschiebung zwischen Servern
- Viele Anfragen gleichzeitig möglich
- Korrekte Reihenfolge garantiert

# Funktionsweise

- Schreibt in 2 logs
- Paxos Group
- Schreibende Zugriffe müssen Paxos Protokoll initiieren
- Lesende Zugriffe vom Tablet verwaltet


# Funktionsweise

- Lock table für:
- 2 Phase locking
  - Expanding, Shrinking Phase
- Transaction Manager für Koordination

# Funktionsweise

Universe Master

Placement Driver



# Funktionsweise

- Location Proxies für Position des Spannservers
- Zonen
  - 1 Zonenmaster, bis zu einigen tausend Spannservers
- ZonenMaster als Verwaltungseinheit
- Zonen nicht lokal gebunden


# Funktionsweise

- Universe Master für interaktives Debugging
- Placement Driver
  - Verschieben von Daten bei Überfüllung
  - Abgleichen der Replikationen
- Gesamter Einsatzbereich als Universum bezeichnet

# True Time

- NTP (Network Time Protocol)
- TrueTime Googles eigene API
  - Eigene Atomuhren und GPS Receiver
- „Timeslave daemon“
  - Abgleich mit Master Server
- Abweichungen einberechnet

# True Time



# True time

Method	Returns
TT.now()	TTinterval [earliest, latest]
TT.after(t)	True if t has definitely passed
TT.before(t)	True if t has definitely not arrived

[1]

- TT.now() erzeugt den Zeitstempel
- TTinterval absolute Zeit in der TT.now() benutzt wurde

# Konsistenzsemantik

- Read Only:
- Vorteile von Snapshot isolation
- Muss vordeklariert sein als read only
- Blockiert nicht
- Read only als snapshot reads implementiert

s-read = tt.now().latest

# Konsistenzsemantik

- Snapshot reads
- Scope Ausdruck
- Zeitstempel in monoton steigender Reihenfolge übergeben

# Konsistenzsemantik

Read / Write:

- Writes buffern auf dem Client
- Wound/wait bei den reads innerhalb von read/write
- Read locks

# Konsistenzsemantik

## 2 Phase Commit:

- Protokoll zur Sicherung der Transaktionen bei Fehlern
- 2 Phasen:
  - 1. Phase
    - Nachricht des Koordinators an Ausführende Stellen
    - Führt Transaktion aus und schreibt in 2 logs undo/redo
  - 2. Phase:
    - Antwort : Ja
      - Transaktion wird fertiggestellt und locks freigegeben
    - Antwort : Nein
      - Zurücksetzen der Transaktion mit undo log

# Konsistenzsemantik

- Write locks
- Prepare Zeitstempel
- Einen Zeitstempel für die gesamte Transaktion
- Wartet nun auf TT.after(s)
  - Garantie das der Zeitstempel in der Vergangenheit liegt
- Locks werden gelöst

# Konsistenzsemantik

- read  $t \leq t\text{-safe}$
- $t\text{-safe} = \min(t\text{-paxos-safe}, t\text{-TM-safe})$
- $t\text{-paxos-safe}$
- $t\text{-TM-safe}$

# Konsistenzsemantik

- Schema Change Transaktion
  - Als „normale“ Transaktion
  - Nicht blockierend
  - Zeitstempel in der Zukunft

# Benchmarks

- 4GB Ram, AMD Barcelona 2200MHz
- Netzwerkdistanz  $\leq 1$  MS
- 50 Paxos Groups
- Reads and Writes mit 4 KB grÖÙe
- Paxos Latenz bei ca 9 ms und Wartezeit ca 5 ms

# Benchmarks

participants	Latenz (ms)	
	mean	99 <sup>th</sup> percentile
1	17.0 + - 1.4	75.0 + - 34.9
2	24.5 + - 2.5	87.6 + - 35.9
5	31.5 + - 6.2	104.5 + - 52.2
10	30.0 + - 3.7	95.6 + - 25.4
25	35.5 + - 5.6	100.4 + - 42.7
50	42.7 + - 4.1	93.7 + - 22.9
100	71.4+ - 7.6	131.2 + - 17.6
200	150.5 + - 11	320.3 + - 35.1

- 2 phase commit getestet an 3 Zonen á 25 Spannserversn

# Zusammenfassung

- Globale Vernetzung aller Rechenzentren
- Minimierung von Latenzen
- Hohe Fehlertoleranz
- Eindeutiger Zeitstempel möglich
- Nicht blockierende Reads

# Quellen

[1] [http://static.googleusercontent.com/external\\_content/untrusted\\_dlcp/research.google.com/en//archive/spanner-osdi2012.pdf](http://static.googleusercontent.com/external_content/untrusted_dlcp/research.google.com/en//archive/spanner-osdi2012.pdf)

[2] [http://business.chip.de/news/Google-Spanner-Redundanz-fuer-10-Millionen-Server\\_42369620.html](http://business.chip.de/news/Google-Spanner-Redundanz-fuer-10-Millionen-Server_42369620.html)

[3] <http://www.wired.com/wiredenterprise/2012/11/google-spanner-time/>

[4] Vorlage:

[http://www.neogrid.de/Bilder-Lexikon.php?Bild\\_Nr=8&Feld=Google-Spanner&Serie=no](http://www.neogrid.de/Bilder-Lexikon.php?Bild_Nr=8&Feld=Google-Spanner&Serie=no)

[5] <http://de.wikipedia.org/wiki/SQL>