Überblick

Latenzminimierung in Datenzentren

- Motivation
- Ansätze und Techniken

Tail Latency

- Typische Antwortzeitverteilung in der Praxis
  - Mehrheit der Anfragen wird in relativ kurzer Zeit beantwortet
  - **Ausreißer mit höherer Antwortzeit**
    - Zahlenmäßig geringer Anteil an der Gesamtmenge aller Anfragen
    - Antwortzeiten übersteigen Mittelwert um ein Vielfaches

  → „**Tail Latency**“
- Beispiel: ZooKeeper-Implementierung aus Übungsaufgabe 6

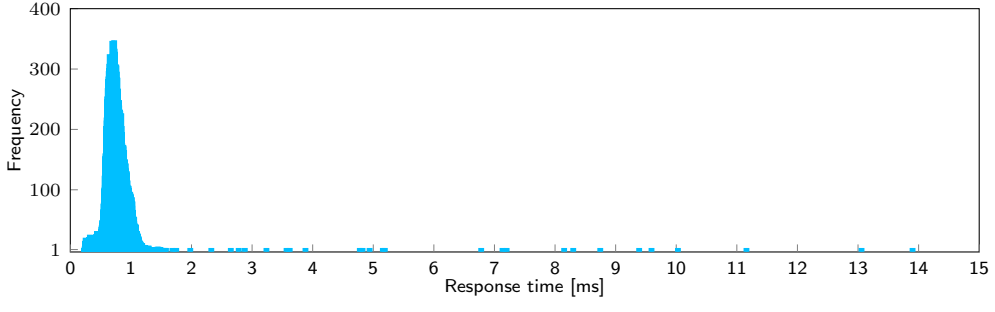

Gründe für Antwortzeitschwankungen

- Warten beim **Zugriff auf geteilte Ressourcen**
  - Lokal: CPU, Caches, Speicher, Netzwerk etc.
  - Global: Koordinierungsdienste, verteilte Dateisysteme etc.
- Verzögerungen durch **Warteschlangen auf verschiedenen Ebenen**
- Zusatzbelastung durch die Aktivierung periodischer Tasks (Beispiele)
  - Garbage-Collection
  - Datenrekonstruktion in Dateisystemen
  - Komprimierung von Log-Dateien
- Variabilität durch **Einflüsse unterschiedlicher Energiesparmodi**
- ...
- Literatur

Jeffrey Dean and Luiz André Barroso
The tail at scale
Communications of the ACM, 56(2):74–80, 2013.

Verteilte Bearbeitung von Anfragen

- Bearbeitung von Anfragen durch mehrere Server
  - **Aufspaltung in kleine Teilaufgaben**
  - Eventuell weitere Aufgliederung der Teilaufgaben
  - Bestimmung der **Gesamtantwort auf Basis der Teilergebnisse**
- Beispiel: Teilaufgaben bei Ausführung einer Suchmaschinenanfrage
  - Bereitstellung von statischen Elementen der Web-Seite
  - Ermittlung des Suchergebnisses
  - Zusammenstellung von Vorschlägen für verwandte Suchanfragen
  - Aufbereitung von Kontextinformationen
  - Auswahl der eingeblendeten Werbung
  - ...
- Problem
  - Gesamtantwortzeit einer Anfrage hängt von vielen Faktoren ab
  - **Schwankungen in einzelnen Servern** wirken sich unmittelbar aus

Auswirkungen langsamer Server

- Vereinfachtes Systemmodell
  - An der Bearbeitung einer Anfrage sind **parallel** s **Server beteiligt**
  - Bei der Erfüllung seiner Teilaufgabe ist jeder Server
    - mit Wahrscheinlichkeit p: *schnell*
    - mit Wahrscheinlichkeit $1 - p$: *langsam*
  - Antwort erfolgt, sobald alle Server mit ihren Teilaufgaben fertig sind
- **Wahrscheinlichkeit für die schnelle Ausführung** einer Anfrage: $P = p^s$

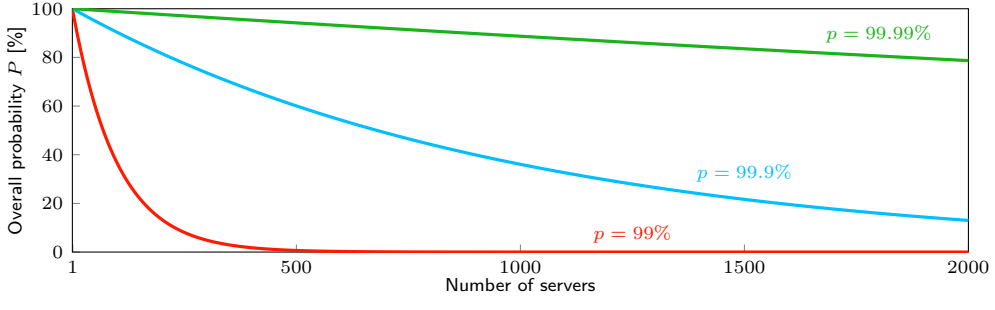

Minimierung von Latenzen

- Beobachtung

> „**Systems that respond** to user actions quickly (**within 100ms**) **feel more fluid and natural to users** than those that take longer.“ [Dean et al.]

- **Kombinierter Ansatz** zur Minimierung von Gesamtantwortzeiten
  - Techniken zur Vermeidung von Ausreißern
  - Konzipierung von *tail-toleranten* Systemen
  - Vergleiche: Vorgehensweise beim Umgang mit Fehlern
- Wahl der Metrik
  - Arithmetisches Mittel: Ungeeignet, da kaum Aussage über Ausreißer
  - n %-**Quantil** (n^{th}-*percentile*)
    - Bedeutung: Antwortzeit für n % aller Anfragen ist $\leq$ n %-Quantil
    - Typische Werte: $n = 95$ oder $n = 99$
- Herausforderungen
  - Wie lässt sich die Anzahl bzw. das Ausmaß von Ausreißern reduzieren?
  - Wie geht man mit Verzögerungen bei der Bearbeitung von Teilaufgaben um?

Vermeidung von Ausreißern mittels Lastbalancierung

- Probleme
  - Zugriffshäufigkeit variiert zwischen Objekten des Anwendungszustands
  - Erhöhte Antwortzeiten als Konsequenz **überlasteter Partitionen**
  - Zugriffsmuster können sich ändern $\rightarrow$ statische Partitionierung unwirksam
- Einsatz von **Mikropartitionen**
  - Anzahl der Partitionen $\gg$ Anzahl der Server
  - Vorteile
    - Feingranulare Lastverteilung möglich
    - Effizientes Verschieben von Partitionen zwischen Servern
  - Beispiele
    - Verwaltung von Range-Partitions im Microsoft Azure Storage Partition Layer
    - Aufteilung eines MapReduce-Jobs in Tasks
- **Selektive Replikation**
  - Replikationsgrad eines Objekts ist abhängig von seiner „Popularität“
  - Beispiel: Dateispezifischer Replikationsfaktor in HDFS

Reduzierung der Anzahl problematischer Ausreißer

- **Priorisierung zeitsensitiver Anfragen**
  - Einteilung von Anfragen in Dienstklassen
  - Beispiel: BEEMR
    - Interaktive Jobs
    - Batch-Jobs
  - Vorteil: Verzögerungen betreffen vor allem nicht-zeitsensitive Operationen
- **Aufspaltung nicht-zeitsensitiver Aufgaben** mit langer Bearbeitungszeit
  - Ausführung als Sequenz mehrerer kurzer Operationen
  - Bessere Verzahnung mit zeitsensitiven Anfragen möglich
  - Vorteil: Steigerung der Effektivität des Priorisierungsansatzes
- Optimierte **Einplanung von Hintergrundaktivitäten**
  - Ausführung in Zeiten mit geringer Systemlast
  - Abstimmung zwischen unterschiedlichen Servern
  - Vorteil: Störender Einfluss ist auf wenige zeitsensitive Anfragen begrenzt

Tolerierung von Ausreißern bei Leseanfragen

- **Abgesicherte Anfragen** (*Hedged Requests*)
  - Aktionen des Clients
    - Senden derselben Anfrage an mehrere Replikate
    - Verwendung der schnellsten Antwort
    - Abbruch der noch ausstehenden Ausführungen
  - Effiziente Implementierung
    - Senden der Anfrage an das vermutlich schnellste Replikat
    - Kontaktierung weiterer Replikate erst nach Timeout
- **Verknüpfte Anfragen** (*Tied Requests*)
  - Anwendungsfall
    - Größere Schwankungen in den Wartezeiten vor der eigentlichen Ausführung
    - Relativ konstante Bearbeitungszeiten
  - Vorgehensweise
    - Client verschickt dieselbe Anfrage an zwei Replikate
    - Anfrage enthält Replikatadressen
    - Bei Ausführungsbeginn: Replikat sendet Abbruchnachricht an das andere

Umgang mit Ausreißern auf Systemebene

- **Prüfung mittels Stichproben** (*Canary Requests*)
  - Problem
    - Ungewöhnliche Anfrage resultiert in Ausführung ungetesteter Code-Pfade
    - Parallele Verzögerungen oder Fehler auf mehreren Servern
  - Lösung
    - Senden von ein oder zwei Teilaufgaben an die entsprechenden Server
    - Verteilung der restlichen Teilaufgaben an die anderen Server erst bei Erfolg
- **Einschränkung der Funktionalität** (*Graceful Degradation*)
  - Ausklammern von Teilaufgaben, deren Bearbeitung zu lange dauert
  - Ausliefern der Gesamtantwort, sobald ihre Qualität „gut genug“ ist
  - Beispiele
    - Weglassen der Werbung
    - Ausblenden der Kommentarfunktion
  - Vorteile
    - Reduzierung des Einflusses einzelner Ausreißer auf die Gesamtantwortzeit
    - Im Allgemeinen bemerken die meisten Nutzer den Unterschied nicht