Middleware – Cloud Computing

Verarbeitung großer Datenmengen

Wintersemester 2020/21

Tobias Distler

Friedrich-Alexander-Universität Erlangen-Nürnberg
Lehrstuhl Informatik 4 (Verteilte Systeme und Betriebssysteme)

Lehrstuhl für Verteilte Systeme und Betriebssysteme

FRIEDRICH-ALEXANDER UNIVERSITÄT ERLANGEN-NÜRNBERG
TECHNISCHE FAKULTÄT

Überblick

Verarbeitung großer Datenmengen
- Motivation
- MapReduce

Verarbeitung großer Datenmengen

- **Problemstellungen** (Beispiele)
  - Indexierung des World Wide Web
  - Erstellung von Log-Statistiken
- **Ziele**
  - Ausnutzung der im Datenzentrum zur Verfügung stehenden Kapazitäten
  - Einfache Realisierung von Anwendungen
- Herausforderungen
  - Wie lässt sich ein System aufbauen, das es ermöglicht, mit **relativ wenigen Code-Zeilen** große Datenmengen zu verarbeiten?
  - Wie entspart man einem Anwendungsprogrammierer sich um Aspekte wie **Verteilung, Parallelisierung und Fehlertoleranz** kümmern zu müssen?
  - Wie lässt sich Wissen über das zugrundelegende Datenspeichersystem zur **Entlastung von Netzwerkverbindungen** nutzen?

Überblick

Verarbeitung großer Datenmengen
- Motivation
- MapReduce

MapReduce

- Programmiermodell: **Implementierung von zwei Methoden**
  - Map: Abbildung der Eingabedaten auf Schlüssel-Wert-Paare
  - Reduce: Zusammenführung der von Map erzeugten Schlüssel-Wert-Paare
- **Framework**
  - Aufgaben
    - Partitionierung der Eingabedaten
    - Parallelisierung und Einplanung von Verarbeitungsschritten
    - Fehlerbehandlung bei Ausfällen
  - Merkmale
    - **Automatische Verteilung** auf Hunderte bzw. Tausende von Rechnern
    - Verarbeitetes Datenvolumen mitunter viel größer als Hauptspeicherkapazität
- Literatur

  Jeffrey Dean and Sanjay Ghemawat
  MapReduce: Simplified data processing on large clusters
  Proc. of the 6th Symposium on Operating Systems Design and Implementation (OSDI '04), S. 137–150, 2004.

Architektur

- MapReduce-*Job*
  - Vom Nutzer an das Framework übermittelte Aufgabe
  - **Aufspaltung in Teilaufgaben** (*Tasks*)
    - *Map-Task*: Aufgabe, einen Teil der Eingabedaten zu verarbeiten
    - *Reduce-Task*: Aufgabe, einen Teil der Zwischenergebnisse zusammenzufassen
- Framework-Prozesse auf Worker-Rechnern
  - *Master*-Prozess
    - Dedizierter Prozess zur **Verwaltung des Frameworks**
    - Aufgabe: Zuweisung von Map- und Reduce-Tasks zu Worker-Prozessen
  - *Worker*-Prozesse
    - Restliche Prozesse
    - Aufgabe: **Ausführung von Map- und Reduce-Tasks**
    - Benennung je nach übernommener Aufgabe: *Map-* bzw. *Reduce-Worker*

Verarbeitungsablauf — Vorbereitung

1. Nutzer übermittelt Job an einen Job-Scheduler
2. Scheduler: **Auswahl von Worker-Rechnern** zur Bearbeitung des Jobs
3. MapReduce-Bibliothek
   - Annahme: *M* Map-Tasks, *R* Reduce-Tasks
   - **Partitionierung der Eingabedaten** in *M* etwa gleichgroße Teile (16-64 MB)
   - Verteilung des Programms auf Worker-Rechner
   - Start des Master-Prozesses bzw. der Worker-Prozesse
4. Master: **Zuteilung von Map- und Reduce-Tasks** zu Worker-Prozessen

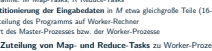

Verarbeitungsablauf — Map-Phase

5. Map-Worker
   - **Einlesen der Eingabedatenpartition** aus dem Google File System
   - Konvertierung der Eingabedaten in Schlüssel-Wert-Paare
   - **Aufruf der Map-Funktion** für jedes der Schlüssel-Wert-Paare

     `map(Key$_M$, Value$_M$) → List<(Key$_I$, Value$_I$)>`
   - Puffern der Zwischenergebnisse im Hauptspeicher
   - Bündelweises Schreiben der **Zwischenergebnisse auf die lokale Festplatte**
     - Aufteilung in *R* Partitionen mittels *Partitionierungsfunktion* (z.B. hash(key) % R)
     - Meldung der Partitionsadressen an den Master
6. Master: Weiterleitung der Partitionsadressen an die Reduce-Worker

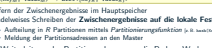

7. Reduce-Worker
   - **Holen der Zwischenergebnisse** per Fernaufruf
   - Sobald alle benötigten Zwischenergebnisse lokal vorhanden sind
     - Gruppierung aller zum selben Schlüssel gehörigen Werte
     - Sortierung der Zwischenergebnisse nach Schlüsseln
   - **Aufruf der `Reduce`-Funktion** für jede Schlüssel-Werte-Gruppe

     `reduce(Key, List<Value>) → List<Value>`
   - Sichering der **Ausgabedaten im Google File System**
   - Eine Ausgabedatei pro Reduce-Task (→ keine Zusammenführung)
8. Master: Meldung an Nutzer, sobald alle Tasks beendet wurden

- **Anwendungsbeispiele**
  - Wörter zählen (→ siehe Übung)
  - Verteiltes grep
  - Verteiltes Sortieren
  - Invertierter Index
- Beispiel: **Zeilenindex des ersten Auftretens eines Wortes** [Lane Immordino]

Map-Phase (2 Tasks)

Gruppierung und Sortierung

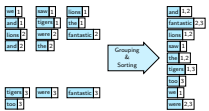

Reduce-Phase (1 Task)

Implementierung

- Anpassung des Frameworks durch den Nutzer
  - Verwendung **nutzerdefinierter Datentypen**
    - Abbildung der Eingabedaten auf Schlüssel-Wert-Paare
    - Einfluss auf Format der Ausgabedaten möglich
  - **Nutzerdefinierte Partitionierung** der Zwischenergebnisse
    - Standard: Aufteilung anhand eines Hash-Werts über den Schlüssel
    - Bereitstellung einer eigenen Abbildungsvorschrift

    → Einfluss auf Zuordnung der Ergebnisse zu Ausgabedateien möglich
  - Einführung **nutzerdefinierter Zähler**
    - Einsatz bei statistischen Auswertungen
    - Zugriff auf Zähler in der Map- und/oder Reduce-Funktion
    - Zusammenfassung der Zähler einzelner Tasks im Master
- Bereitstellung von Statusinformationen
  - Master-Prozess verfügt über eigenen HTTP-Server
  - Übersicht über aktuellen Job-Fortschritt (z. B. Anzahl beendeter Tasks)

Fehlertoleranz

- Master: Maßnahmen zur **Tolerierung von Worker-Ausfällen**
  - Periodische Ping-Anfragen an Worker-Prozesse
  - Falls Worker *w* nicht antwortet → *w* wird als „ausgefallen" definiert
    - Alle *w* zugetelten Map-Tasks werden an andere Worker-Prozesse vergeben
    - Alle *w* zugetelten Reduce-Tasks, die dem Master noch nicht als beendet gemeldet wurden, werden an andere Worker-Prozesse vergeben
    - Reduce-Worker werden über die Neuzuteilung benachrichtigt
  - Prinzip: **Einfachheit vor Effizienz**
    - Kein Versuch eventuell bereits vorhandene Zwischenergebnisse zu retten
    - Redundante Bearbeitung von Tasks wird nicht verhindert
- **Ausfall des Master-Prozesses**
  - Keine Fehlertoleranzmechanismen
    - Ausfall wird in Kauf genommen
    - Annahme: Nutzer startet seinen MapReduce-Job neu
  - Mögliches Vorgehen: Periodische Sicherungspunkte des Master-Zustands

Optimierungen

- Datenlokalität
  - Ziel: Einsparung der übers Netzwerk zu sendenden Daten
  - Ansatz: **MapReduce-Master berücksichtigt Speicherort der Eingabedaten** bei der Zuteilung von Tasks zu Worker-Prozessen
  - Beispiel: Ausführung eines Map-Task auf einem Worker-Rechner, auf dem das Google File System ein Replikat der Eingabepartition verwaltet
- Task-Granularität
  - Ziele: Verbesserte Lastbalancierung, beschleunigte Fehlerbehandlung
  - Ansatz: **Aufspaltung eines Jobs in viele Tasks**
  - Vorteile
    - Feingranulare, dynamische Task-Platzierung nach Lastkriterien möglich
    - Bei Ausfall: **Verteilung der Tasks auf viele Worker-Prozesse**
  - Nachteile
    - Zusätzliche Scheduling-Entscheidungen für den Master-Prozess
    - Ungünstiger Ansatz für Reduce-Tasks → große Anzahl an Ausgabedateien
  - Beispiel [Dean et al.]: 200.000 Map-, 5.000 Reduce-Tasks (2.000 Rechner)

Optimierungen

- Redundante Task-Ausführung
  - Problem
    - In der Praxis benötigen **einige wenige Worker-Prozesse deutlich länger** als alle anderen für die Bearbeitung ihrer Tasks → *„Nachzügler" (Stragglers)*
    - Mögliche Gründe: Überlast auf dem Rechner, Hardware-Fehler,...

    → Verzögerungen bei der Bearbeitung des MapReduce-Jobs
  - Lösung
    - Sobald ein Großteil aller Tasks beendet ist, vergibt der Master die sich noch in Ausführung befindenden Tasks an weitere Worker-Prozesse → **Backup-Tasks**
    - Verwendung der Ergebnisse des (Original-/Backup-)Task, der zuerst fertig ist
- Zusammenfassen von Zwischenergebnissen
  - Ziel: Reduktion der Zwischenergebnisse → **Entlastung des Netzwerks**
  - Ansatz: Spezifizierung einer `Combiner`-Funktion
    - **Vorverarbeitung der Zwischenergebnisse** während der Map-Phase
    - Meist identisch mit der `Reduce`-Funktion

MapReduce vs. Datenbanksysteme

- Verwaltung von Daten
  - MapReduce
    - **Semi-strukturierte Daten** (Schlüssel-Wert-Paare)
    - Effizientes Einlesen von Eingabedaten
  - Datenbanksysteme
    - Speicherung von Daten mittels **vordefiniertem Schema**
    - Vergleichsweise hoher Aufwand für das Parsen und Verifizieren beim Einlesen
- Fazit auf Basis von Experimenten [Stonebraker et al.]
  - MapReduce mit Vorteilen bei
    - Einrichtung des Systems
    - **Einlesen der Daten**
    - Szenarien, in denen Daten nur einmalig gelesen und verarbeitet werden
  - Datenbanken schneller, **sobald Daten geladen** sind und öfter genutzt werden
- Literatur

Michael Stonebraker, Daniel J. Abadi, David J. DeWitt, Madden, Erik Paulson et al.
MapReduce and parallel DBMSs: Friends or foes?
Communications of the ACM, 53(1):64–71, 2010.