Überblick

Verarbeitung großer Datenmengen

- Motivation
- MapReduce
- Pig
- Zusammenfassung

Verarbeitung großer Datenmengen

- Problemstellungen (Beispiele)
  - Indexierung des World Wide Web
  - PageRank-Berechnungen für Web-Seiten
  - Erstellung von Log-Statistiken
  - ...
- Alternative Herangehensweisen
  - Trennung zwischen Speicherung von Daten und ihrer Verarbeitung
    - Vergleiche: Windows Azure Storage und Windows Azure
    - Separate Skalierbarkeit der Subsysteme möglich
    - Erhöhter Aufwand für Datenübertragung erforderlich
  - Speicherung und Verarbeitung von Daten erfolgt auf denselben Rechnern
    - Vergleiche: Google File System und MapReduce
    - Ausnutzen von Datenlokalität
    - Anwendung muss Einblick in Interna des Datenspeichersystems besitzen

Herausforderungen

- Ausgangssituation
  - Sehr große Datenmengen
  - Hohe Anzahl an Rechenknoten
- Ziele
  - Ausnutzung der zur Verfügung stehenden Kapazitäten
  - Einfache Realisierung von Anwendungen
- Herausforderungen
  - Wie lässt sich ein System aufbauen, das es ermöglicht, mit vergleichsweise wenigen Code-Zeilen große Datenmengen zu verarbeiten?
  - Wie erspart man einem Anwendungsprogrammierer sich um Aspekte wie Verteilung, Parallelisierung und Fehlertoleranz kümmern zu müssen?
  - Wie lässt sich Wissen über das zugrundeliegende Datenspeichersystem zur Entlastung von Netzwerkverbindungen nutzen?

MapReduce

- Konzept
  - Kombination aus Programmiermodell und Framework
  - Grundidee
    - Framework übernimmt Verteilung der Anwendung
    - Programmierer implementiert zwei Methoden
      - `Map`: Abbildung der Eingabedaten auf Schlüssel-Wert-Paare
      - `Reduce`: Zusammenführung der von `Map` erzeugten Schlüssel-Wert-Paare
- Implementierungen
  - Google MapReduce (nicht öffentlich verfügbar)
  - Apache Hadoop MapReduce ($\rightarrow$ siehe Übung)
  - Phoenix (Stanford University)
  - ...
- Literatur

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

Framework

- Rahmenbedingungen bei Google
  - Cluster aus Hunderten bzw. Tausenden von Commodity-Rechnern
  - Datenvolumen übersteigt den Platz im Hauptspeicher bei weitem
  - Datenverwaltung mittels Google File System
- Aufgaben des MapReduce-Framework
  - Partitionierung der Eingabedaten
  - Scheduling von Anwendungsprozessen
  - Fehlerbehandlung bei Ausfällen
  - Kommunikation zwischen Rechnern
- Bereitstellung als Bibliothek
- Literatur

Luiz André Barroso, Jeffrey Dean, and Urs Hölzle
Web search for a planet: The Google cluster architecture
IEEE Micro, 23(2):22–28, 2003.

Begrifflichkeiten nach [Dean et al.]

- Rechner im Cluster: Worker-Rechner (*Worker Machine*)
- 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 Framework
    - 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*

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

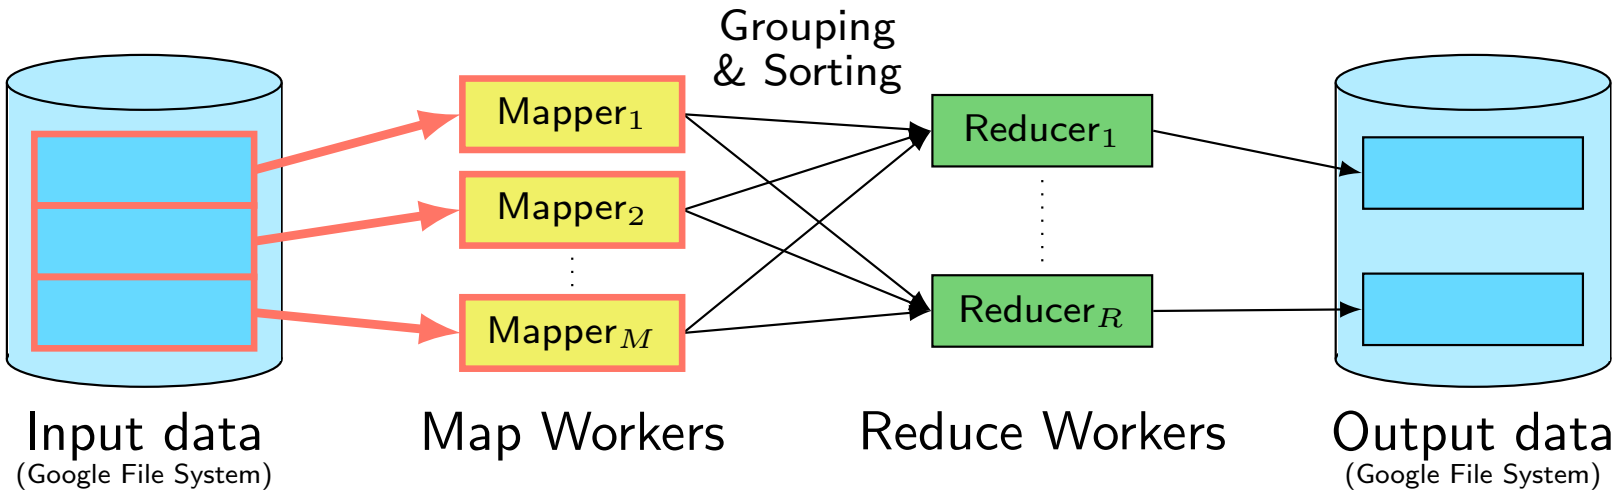

5. Map-Worker
   - Einlesen der Eingabedatenpartition aus dem Google File System
   - Konvertierung der Eingabedaten in Schlüssel-Wert-Paare
   - Aufruf der `Map`-Funktion für jedes der Schlüssel-Wert-Paare

     $\texttt{map(Key}_M\texttt{, Value}_M\texttt{)} \rightarrow \texttt{List<\{Key}_R\texttt{, Value}_R\texttt{\}>}$
   - Puffern der Zwischenergebnisse im Hauptspeicher
   - Periodisches Schreiben der Zwischenergebnisse auf die lokale Festplatte
     - Aufteilung in R Partitionen mittels *Partitionierungsfunktion* [z. B. $\texttt{hash(Key}_R\texttt{) \% R}$]
     - Meldung der Partitionsadressen an den Master
6. Master: Weiterleitung der Partitionsadressen an die Reducer-Worker

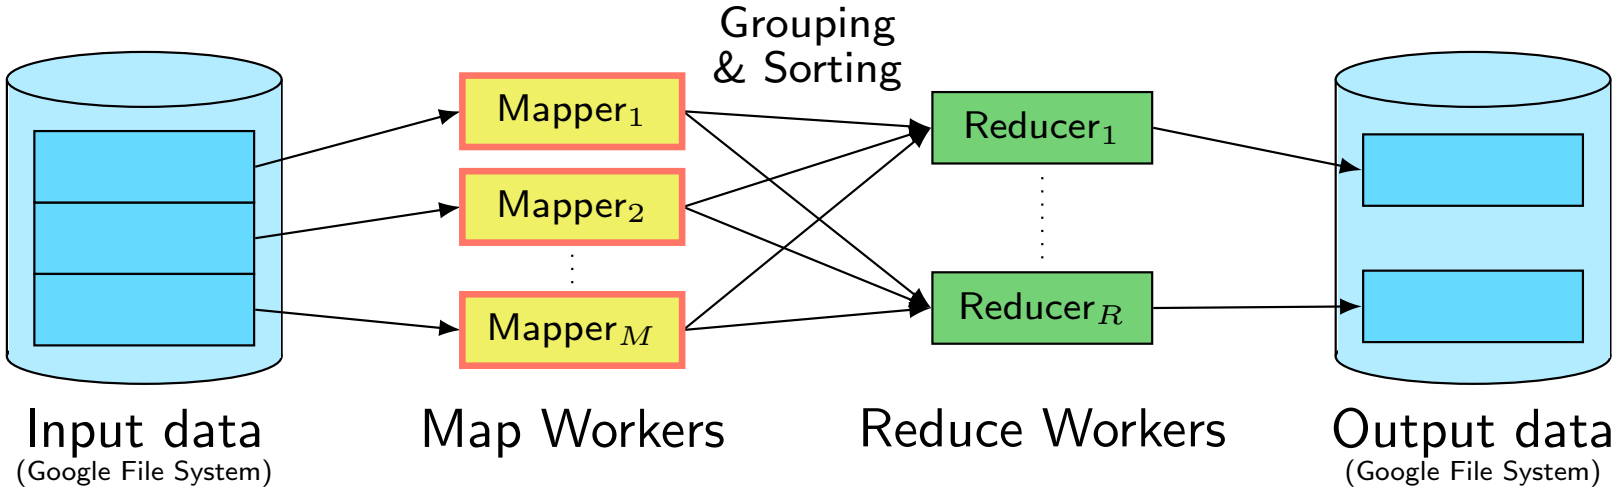

7. Reduce-Worker
   - Holen der Zwischenergebnisse per Fernaufruf
   - Sobald alle benötigten Zwischenergebnisse lokal vorhanden sind
     - Sortierung der Zwischenergebnisse nach Schlüsseln
     - Gruppierung aller zum selben Schlüssel gehörigen Werte
   - Aufruf der `Reduce`-Funktion für jede Schlüssel-Werte-Gruppe

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

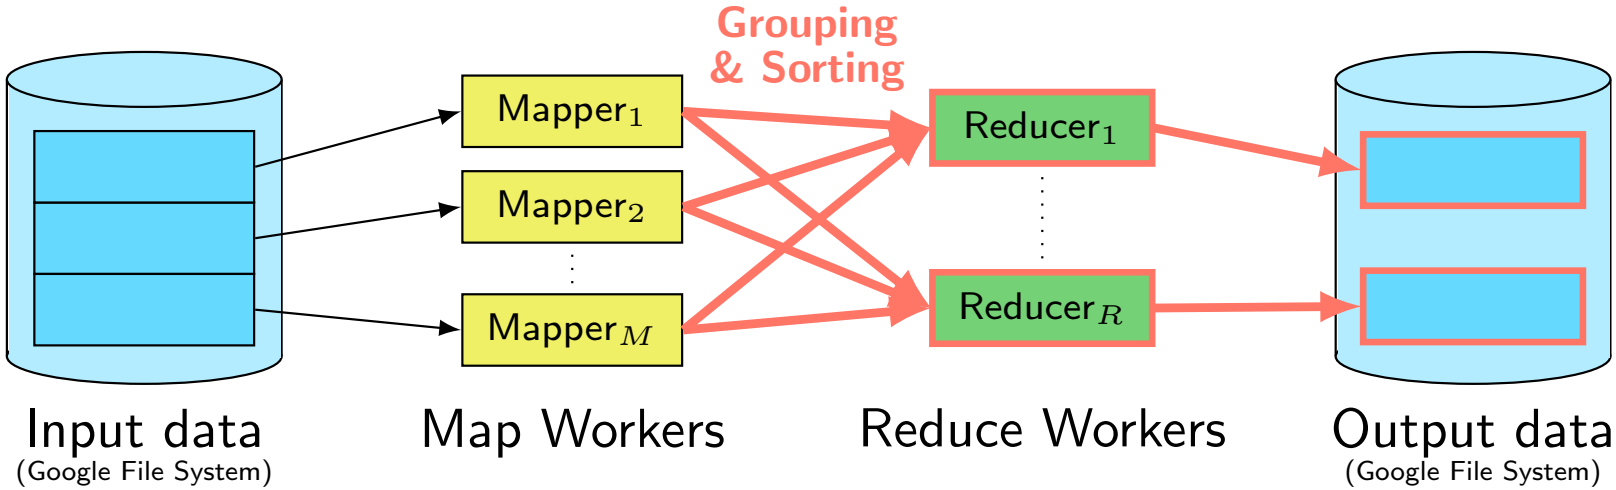

Anwendungen

- Anwendungsbeispiele
  - Wörter zählen ($\rightarrow$ siehe Übung)
  - Verteiltes `grep`
  - Verteiltes Sortieren
  - Invertierter Index
- Beispiel: Zeilenindex des ersten Auftretens eines Wortes [case-insensitive]

Map-Phase (2 Map-Worker, jeweils 1 Map-Task)

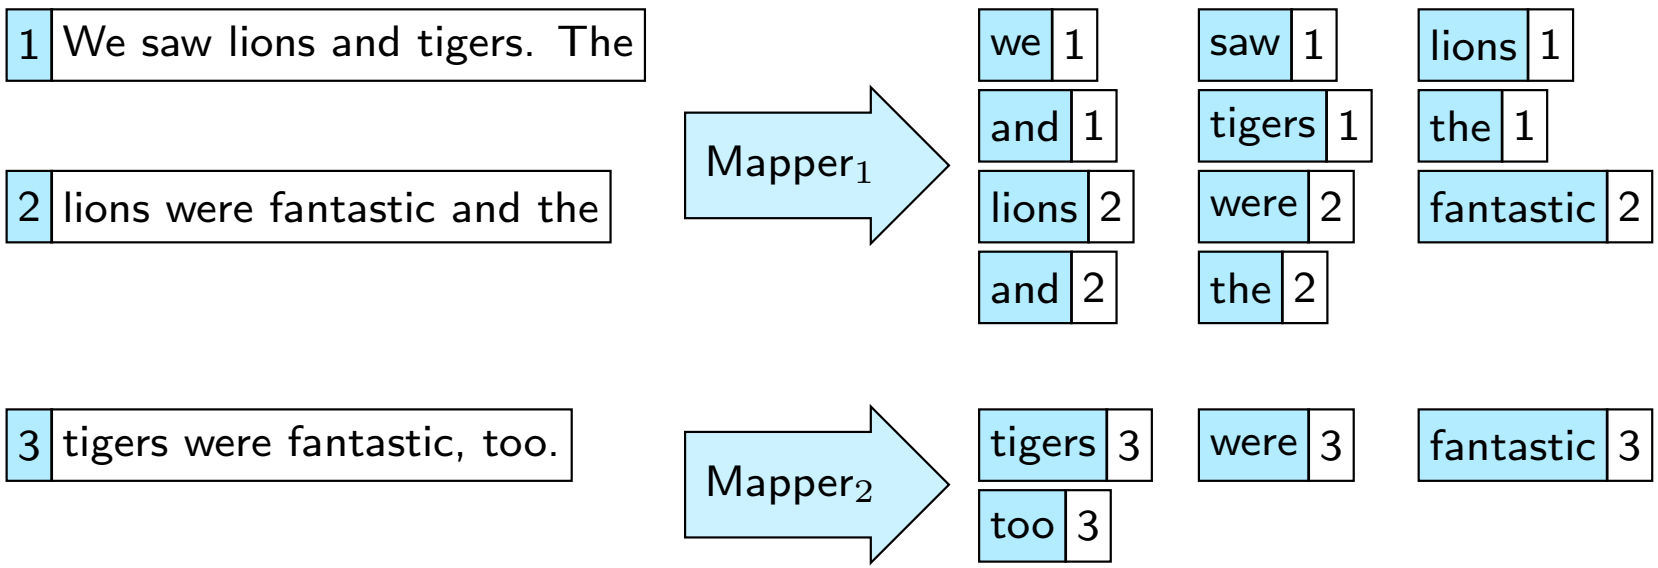

Zeilenindex des ersten Auftretens eines Wortes

Gruppierung und Sortierung

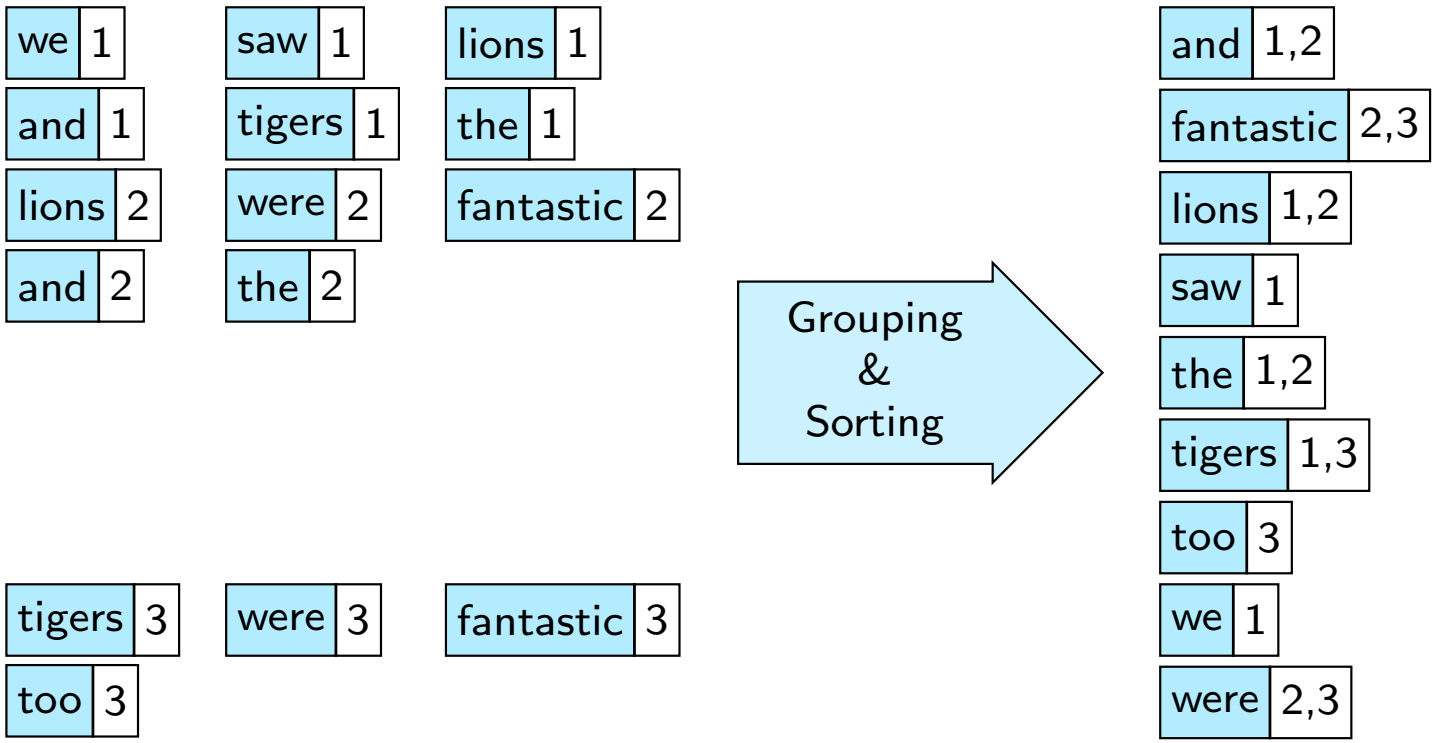

Zeilenindex des ersten Auftretens eines Wortes

Reduce-Phase (1 Reduce-Worker, 1 Reduce-Task)

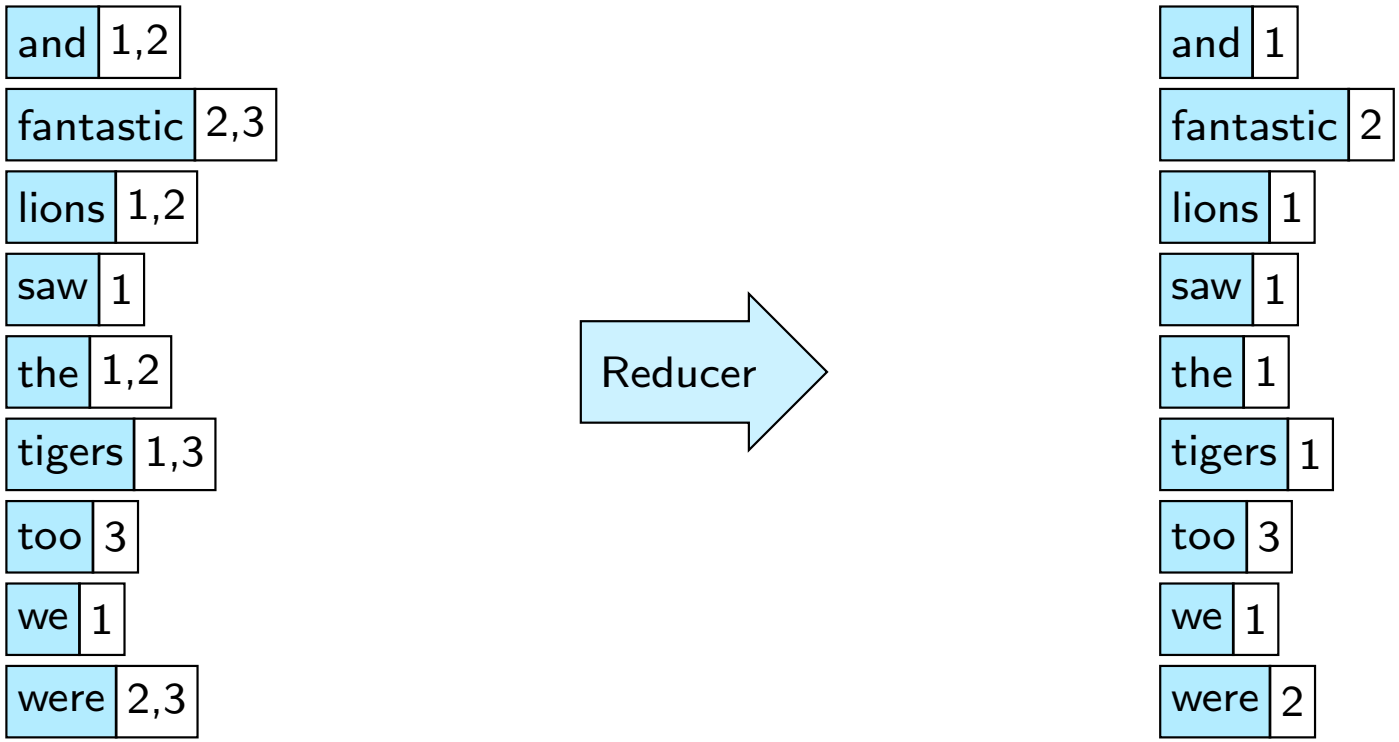

Implementierung

- Anpassung des Framework 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

    $\rightarrow$ 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 $\rightarrow$ w wird als „ausgefallen“ definiert
    - Alle w zugeteilten Map-Tasks werden an andere Worker-Prozesse vergeben
    - Alle w zugeteilten 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
    - Keine Differenzierung zwischen Prozess- und Rechnerausfall
    - Kein Versuch eventuell bereits vorhandene Zwischenergebnisse zu retten
    - Redundante Bearbeitung von Tasks wird in Kauf genommen
- 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
  - Ziel: 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 $\rightarrow$ 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

Pig

- Ad-hoc-Analyse großer Datenmengen
  - MapReduce für manche Aufgaben zu unflexibel
  - Viele Programmierer empfinden SQL-Anfragen als „unnatürlich“ [Olston et al.]
- *Apache Pig* (`http://pig.apache.org/`)
  - *Pig Latin*
    - Sprache zur Beschreibung von Datenflüssen
    - Kompromiss zwischen imperativen und deklarativen Sprachen
  - Auf Hadoop basierende Ausführungsumgebung für Pig Latin
  - Übersetzung von Pig-Latin-Programmen in MapReduce-Jobs
- Literatur

Christopher Olston, Benjamin Reed, Utkarsh Srivastava, Ravi Kumar et al.
Pig Latin: A not-so-foreign language for data processing
Proc. of the 28th Intl. Conference on Management of Data (SIGMOD '08), S. 1099–1110, 2008.

Alan F. Gates, Olga Natkovich, Shubham Chopra, Pradeep Kamath et al.
Building a high-level dataflow system on top of Map-Reduce: The Pig experience
Proceedings of the VLDB Endowment, 2(2):1414–1425, 2009.

- Datenmodell
  - Basistypen

Typ	Beschreibung	Beispiel
`Atom`	Einfacher Wert	`47` oder `'MWCC'`
`Tuple`	Sequenz von *Feldern* beliebigen Typs	`(47,'MWCC',7)`
`Bag`	Kollektion von Tupeln	$\{$ `(47,'MWCC',100)` `('MWCC','WS14/15')` $\}$
`Map`	Datenstruktur zur Verwaltung von Schlüssel-Wert-Paaren: `Atoms` als Schlüssel, Werte beliebig	$\{$ `'WS'`$\rightarrow$`'MWCC'` `'SS'`$\rightarrow$`'VS'` $\}$

  - Schachtelung von Datentypen möglich
- Benutzerdefinierte Funktionen
  - Kapselung komplexer Operationen
  - Anpassung an anwendungsspezifische Anforderungen
  - Implementierung in Java

- LOAD
  - Einlesen und Deserialisieren der Eingaben
  - Rückgabewert: Referenz auf Bag mit Eingabedaten
  - Beispiel [Beispiele aus [Olston et al.].]

```
queries = LOAD 'query_log.txt'                    Eingabedatei
          USING myLoad()                  Deserialisierungsfunktion
          AS (userId, queryString, timestamp);        Tupelformat
```

- ORDER: Sortieren eines Bag nach einem Feld

```
sorted_queries = ORDER queries BY timestamp;
```

- FOREACH
  - Tupelweise Bearbeitung von Datensätzen
  - Annahme: Keine Abhängigkeiten zwischen Tupeln [→ Ausführung parallelisierbar]
  - Beispiel

```
exp_queries = FOREACH queries                              Eingabe
              GENERATE userId,                Ergebnisberechnung mittels
                       expand(queryString);  benutzerdefinierter Funktion
```

- FILTER
  - Filtern von Datensätzen mit bestimmten Eigenschaften
  - Beispiel

```
real_queries = FILTER queries BY userId neq 'bot';
```

- GROUP
  - Gruppierung von Tupeln
  - Beispiel

```
grouped = GROUP queries BY userId;
```

- STORE
  - Ausgabe von Ergebnissen in eine Datei
  - Beispiel

```
STORE grouped INTO 'output.txt'
      USING myStore();
```

Ausgabedatei

Serialisierungsfunktion

Pig

- Ausführungsumgebung für Pig Latin
  - Open-Source-Projekt: *Apache Pig*
  - Ausgelegt auf verschiedene Ausführungsplattformen
  - Unterstützung von Apache Hadoop
  - Hadoop-Compiler für Pig-Latin-Programme
- Schrittweises Kompilieren
  - Erstellung eines logischen Ablaufplans *(Logical Plan)*
    - Unabhängig von der Ausführungsplattform
    - Übersetzung in eine interne Darstellung
    - Zusammenführung der logischen Ablaufpläne aller Teilausdrücke
  - Erstellung eines physischen Ablaufplans *(Physical Plan)*
    - Abhängig von der Ausführungsplattform
    - Für Hadoop: Übersetzung des logischen Plans in MapReduce-Job(s)
    - Ausnutzung in MapReduce bereits vorhandener Funktionalität
      - Gruppierung
      - Sortierung

Pig Latin → MapReduce

- Aufteilung des logischen Ablaufplans
  - Orientierung an `GROUP`-Kommandos
  - Ein MapReduce-Job pro `GROUP`-Kommando
  - Map-Phase: Setzen des Gruppierungsfelds als Schlüssel
  - Reduce-Phase: Identische Abbildung
- Kommandos (z. B. `FOREACH`, `FILTER`) zwischen Gruppierungsaktionen
  - Einbettung in `reduce()`-Methode eines Jobs oder
  - Einbettung in `map()`-Methode des nächsten Jobs
- Abbildung des `ORDER`-Kommandos auf zwei MapReduce-Jobs

1. Vorbereitung zur Optimierung des Sortiervorgangs
   - Analyse der Werteverteilung des Sortierschlüssels basierend auf Samples
   - Definition einer Partitionierungsfunktion zur gleichmäßigen Auslastung der Reduce-Worker während des Sortierens in Schritt 2
2. Durchführung der eigentlichen Sortierung

- Vorteile
  - Effizienzsteigerungen durch hohe Parallelisierbarkeit
    - `LOAD`: Paralleles Einlesen von Eingabedaten aus dem Google File System
    - `FOREACH`: Parallele Bearbeitung in mehreren Worker-Prozessen
    - `GROUP`: Parallele Gruppierung durch das MapReduce-Framework
  - Rückgriff auf bestehende Lastverteilungs- und Fehlertoleranzmechanismen
- Nachteile
  - Aufteilung auf mehrere MapReduce-Jobs beeinträchtigt die Performanz
    - Keine direkt Weitergabe der Daten zwischen zwei Jobs
    - Ineffiziente Indirektion über das verteilt replizierte Google File System
  - Verwaltungsaufwand für Zuordnung von Tupeln zu Eingabedatensätzen

Zusammenfassung

- MapReduce
  - Programmiermodell
    - `Map`: Abbildung der Eingabedaten auf Schlüssel-Wert-Paare
    - `Reduce`: Zusammenführung der Zwischenergebnisse
  - Framework
    - Enge Verzahnung mit dem Datenspeichersystem (z. B. Google File System)
    - Scheduling und Verteilung von Worker-Prozessen
    - Fehlerbehandlung bei Worker-Ausfällen
- Pig
  - Pig Latin: Sprache zur Beschreibung von Datenflüssen
  - Übersetzung von Pig-Latin-Programmen in MapReduce-Jobs
- Kritik an MapReduce

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