

## MapReduce Framework

### MapReduce

Einführung und Grundlagen

Ablauf eines MapReduce-Jobs

Aufgaben des Frameworks

### Aufgabe 4

Abstract Factory Entwurfsmuster

Vergleichen und Sortieren mit Java

Zusammenführung vorsortierter Listen

Futures

Daten finden und extrahieren



## MapReduce: Einführung

- MapReduce: Programmiermodell zur Strukturierung von Programmen für **parallele, verteilte** Ausführung
- Map und Reduce ursprünglich Bausteine aus funktionalen Programmiersprachen (z. B. LISP)
  - **Map**: Abbildung eines Eingabeelements auf ein Ausgabeelement
  - **Reduce**: Zusammenfassung mehrerer gleichartiger Eingaben zu einer einzelnen Ausgabe
- Formulierung zu lösender Aufgabe in MapReduce
  - Aufteilen in (potentiell mehrere) Map- und Reduce-Schritte
  - Implementierung der Map- und Reduce-Methoden (Entwickler)
  - Parallelisierung und Verteilung (MapReduce-**Framework**)



## MapReduce: Einführung

- „MapReduce: Simplified data processing on large clusters“ (OSDI'04)

- Implementierung von Google nicht öffentlich

- Zahlreiche Open-Source-Implementierungen (z. B. Disco, **Apache Hadoop**, Phoenix)

→ Ermöglicht Verarbeitung riesiger Datenmengen

→ Vereinfachung der Anwendungsentwicklung

- Literatur

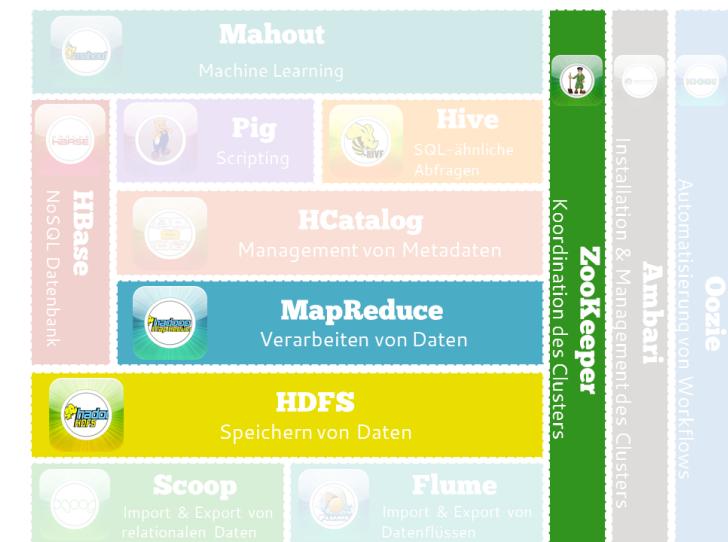
Jeffrey Dean and Sanjay Ghemawat

**MapReduce: Simplified data processing on large clusters**

*Proceedings of the 6th Conference on Operating Systems Design and Implementation (OSDI '04)*, pages 137–150, 2004.

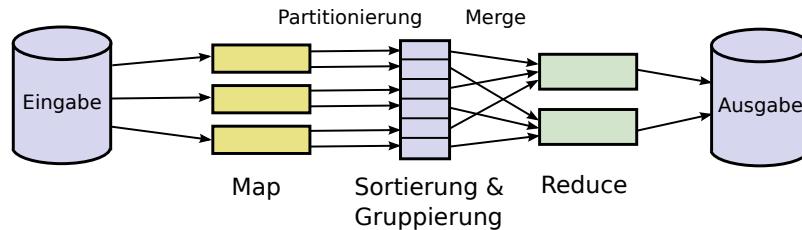


## Hadoop-Framework (Komponenten)



## Ablauf von MapReduce

- Übersicht: Ablauf eines MapReduce-Durchlaufs.



- Darstellung der Daten in Form von **Schlüssel-Wert-Paaren**



## Mapper-Schnittstelle

- Schnittstelle **Mapper** in Apache Hadoop

```
public class Mapper<KEYIN, VALUEIN, KEYOUT, VALUEOUT> {  
    void map(KEYIN key, VALUEIN value, Context context) {  
        context.write((KEYOUT) key, (VALUEOUT) value);  
    }  
}
```

- Festlegen von Datentypen mittels „Generics“

- key**: Schlüssel, z. B. Zeilennummer

- value**: Wert, z. B. Inhalt der Zeile

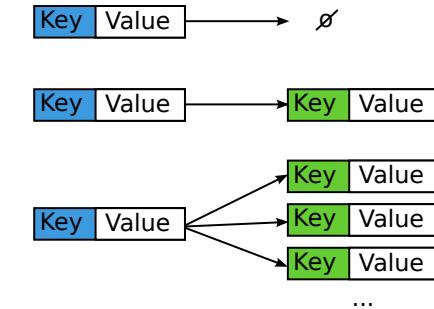
- context**: Ausführungskontext, enthält `write()`-Methode zur Ausgabe von Schlüssel-Wert-Paaren



## Map-Phase

- Abbildung in der Map-Phase

- parallele Verarbeitung verschiedener Teilbereiche der Eingabedaten
- Eingabedaten in Form von Schlüssel-Wert-Paaren
- Abbildung auf **variable Anzahl** von **neuen** Schlüssel-Wert-Paaren



## Mapper-Beispiel

- Beispiel: Zählen von Wörtern

- Mapper-Eingabe

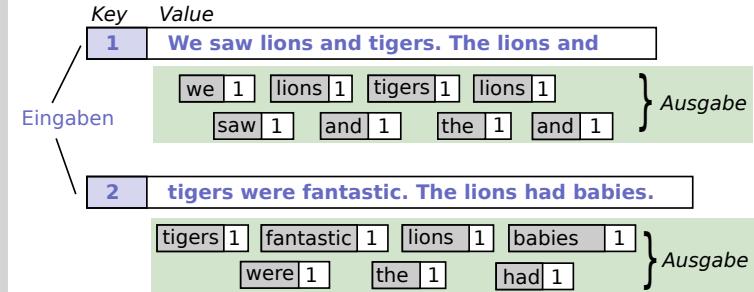
**Schlüssel**: Zeilennummer

**Wert**: Textzeile

- Mapper-Ausgabe

**Schlüssel**: Wort

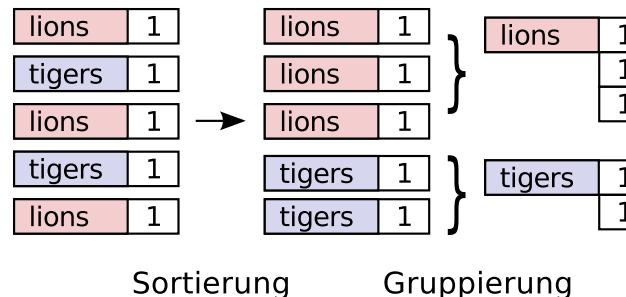
**Wert**: Anzahl (hier: 1 für jedes Wort)



# Sortierung und Gruppierung

## Sortierung und Gruppierung nach **Schlüssel**

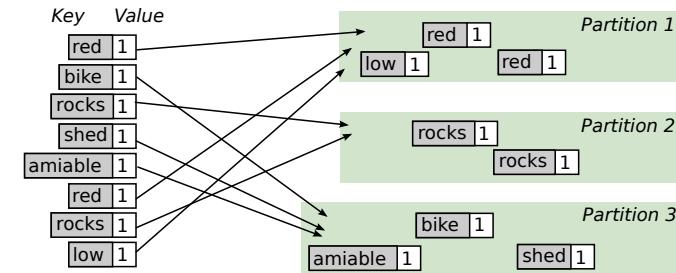
- Lokale Vorsortierung nach Verarbeitung der Daten durch Mapper
- Zusammenfassen aller Werte unter identischem Schlüssel
- Statt Schlüssel-Wert-Paar nun Schlüssel und **Liste von Werten**



# Partitionierer

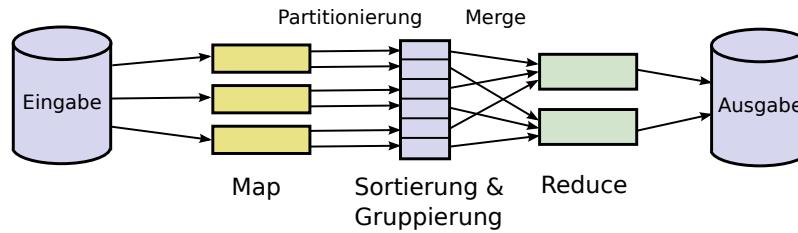
- Zuordnung zu späterem Reducer bei Mapper-Ausgabe
  - Reducer-Eingaben unabhängig → parallelisierbar
  - Gleiche Schlüssel müssen zu gleichem Reducer
- Schnittstelle in Apache Hadoop

```
public class Partitioner<KEY, VALUE> {  
    int getPartition(KEY key, VALUE value, int numPartitions) {  
        return Math.abs(key.hashCode()) % numPartitions;  
    }  
}
```



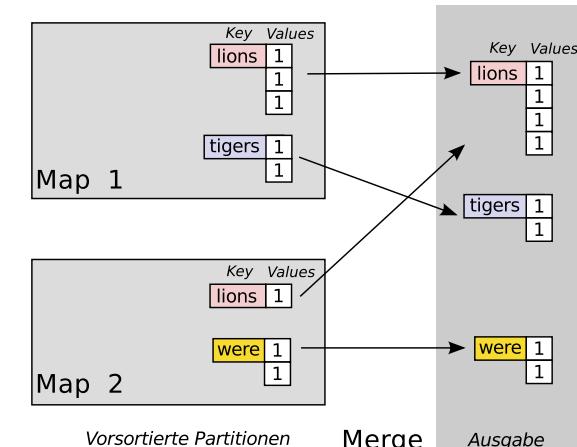
# Ablauf von MapReduce

- Übersicht: Ablauf eines MapReduce-Durchlaufs.



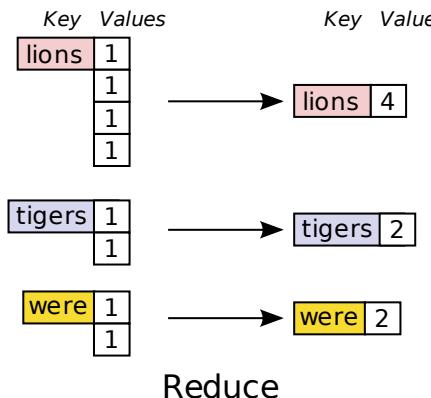
# Merge

- Eingaben für Reducer befinden sich in (mehreren) Mapper-Ausgaben
- Zusammenfassung der vorsortierten Partitionen zu einer vollständig sortierten und gruppierten Gesamtliste (Merge)



## ■ **Zusammenführen** von Daten in der Reduce-Phase

- Eingabe in Form von Schlüssel und alle zugehörigen Werte aus Mapper
  - Parallel Verarbeitung verschiedener Teilbereiche von Schlüsseln
  - Abbildung auf **variable Anzahl** von **neuen Schlüssel-Wert-Paaren**



## Reducer-Schnittstelle

## ■ Schnittstelle **Reducer** in Apache Hadoop:

```
public class Reducer<KEYIN, VALUEIN, KEYOUT, VALUEOUT> {  
    void reduce(KEYIN key, Iterable<VALUEIN> values, Context context) {  
        for(VALUEIN value : values) {  
            context.write((KEYOUT) key, (VALUEOUT) value);  
        }  
    }  
}
```

- **key**: Schlüssel aus Sortierungsphase
  - **values**: Liste von Werten, welche zu dem Schlüssel gruppiert wurden
  - **context**: Ausführungskontext, enthält `write()`-Methode zur Ausgabe von Schlüssel-Wert-Paaren

## Aufgaben des Frameworks

- Generelle **Steuerung** der MapReduce-Abläufe
    - Scheduling einzelner (Teil-)Aufgaben
    - Einhaltung der Reihenfolge bei Abhängigkeiten
    - Zwischenspeicherung der Daten
  - Implementiert grundsätzliche **Algorithmen** (z. B. Sortierung)
  - Bereitstellen von **Schnittstellen** zur Anpassung von
    - Partitionierung
    - Dateneingabe (Deserialisierung)
    - Mapper
    - Sortierung/Gruppierung
    - Reducer
    - Datenausgabe (Serialisierung)

## Framework-Entwicklung

- Framework stellt **Rahmen** für Anwendungen auf
    - Lediglich **grundsätzlicher Ablauf** vorgegeben
    - Details der Anwendung nicht vorab bekannt
      - Hohe Flexibilität und Konfigurierbarkeit notwendig
  - Im Fall des MapReduce-Frameworks aus Aufgabe 4:
    - Mapper
    - Reducer
    - Sortierung
  - Auswählbare Implementierung für einzelne Schritte
    - Framework muss notwendige Objekte selbst instanziieren
    - Lösung mittels „Factory Pattern“

- Problemstellung: Es sollen Objekte instanziert werden, welche eine bestimmte Schnittstelle zur Verfügung stellen, ohne dass der genaue Typ vorab bekannt ist.  
→ **Kapselung der Instanziierung** in eigener Klasse
- Beispiel:

```
public class WordCountMapper implements Mapper {  
    ...  
}  
  
public class WordCountFactory {  
    public Mapper createMapper() {  
        return new WordCountMapper();  
    }  
}
```

- **Allerdings:** Klasse WordCountFactory muss Framework bekannt sein



## Sortieren mittels Comparator-Objekten

- Standardisierte Schnittstellen zum Vergleich von Objekten:

### Comparable

- Vergleicht Objekt mit **anderem gegebenen Objekt**

```
public interface Comparable<T> {  
    public int compareTo(T o);  
}
```

### Comparator

- Vergleicht **zwei gegebene Objekte miteinander**
- equals() vergleicht Äquivalenz verschiedener Comparator-Typen

```
public abstract class Comparator<T> {  
    public int compare(T o1, T o2);  
    public boolean equals(Object obj);  
}
```



- Lösung durch weitere Abstraktionsschicht: Schnittstelle zur Instanziierung

```
public class WordCountMapper implements Mapper { ... }  
  
public interface MapperFactory {  
    public Mapper createMapper();  
}  
  
public class WordCountFactory implements MapperFactory {  
    public Mapper createMapper() {  
        return new WordCountMapper();  
    }  
}
```

- Verwendung:

```
void myMethod(MapperFactory mfact) {  
    Mapper m = mfact.createMapper();  
    ...  
}
```

## Sortieren mittels Comparator-Objekten

- Verwendung:

```
int x = links.compareTo(rechts);  
int y = comparator.compare(links, rechts);
```

- Methoden compareTo() und compare() liefern Integer zurück

- **negativ**: Linker Wert **kleiner** als rechter Wert (kommt **vor...**)
- **0**: Beide Werte sind **gleich** (**äquivalent**)
- **positiv**: Linker Wert **größer** als rechter Wert (kommt **nach...**)

- Beispiel: Strings rückwärts sortieren

```
class RevStringComparator implements Comparator<String> {  
    public int compare(String o1, String o2) {  
        return -o1.compareTo(o2);  
    }  
}
```

- Comparator ermöglicht Änderung der Sortierreihenfolge **ohne Ableiten** der zu sortierenden Objekte
- Einstellung bei sortierenden Standard-Containern in Java  
Beispiel: TreeMap (implementiert SortedMap)

```
RevStringComparator revcmp = new RevStringComparator();
TreeMap<String,X> treemap = new TreeMap<String,X>(revcmp);
```

→ Iterieren über Map liefert Schlüssel in umgekehrter Reihenfolge



## Zusammenführung mittels Priority-Queues

- Algorithmus:
  1. Priority-Queue mit vorsortierten Listen befüllen
  2. Entnahme des Elements höchster Priorität liefert Liste, welche das nächste auszugebende Listenelement an erster Stelle enthält
  3. Ausgeben und Entfernen des obersten Listenelements aus der entnommenen Liste
  4. Liste wieder in Priority-Queue einfügen
  5. Wiederholen ab (2), bis alle Listen leer sind



- Aufgabe: Zusammenführen bereits vorsortierter Listen
  - Vergleich des obersten Elements über alle Listen
  - Kleinstes Element bestimmt nächstes Ausgabeelement
- Datenstruktur **Priority-Queue**
  - Einfügen von Elementen mit zugeordneter Priorität
  - Entfernen entnimmt immer Element mit **höchster** Priorität
  - Üblicherweise als Heap-Datenstruktur implementiert
- Nutzung als Merge-Algorithmus:
  - Priorität entspricht Wertigkeit des **obersten Elements** jeder **Liste**
  - Entnahme aus Priority-Queue liefert Liste mit nächstem Element



## Zusammenführung mittels Priority-Queues

- Priority-Queues in Java: `java.util.PriorityQueue`
  - **Höchste Priorität** entspricht **erster Stelle** nach Sortierung
  - Festlegen der Sortierung mittels Comparator:

```
public PriorityQueue(int capacity, Comparator c);
```
  - Einfügen eines Elements vom Typ E:

```
public boolean add(E item);
```
  - Abfrage des obersten Elements:

```
public E peek();
```
  - Entnahme des obersten Elements:

```
public E poll();
```



- Oftmals synonym verwendet: *Promise*

- Schnittstelle

```
boolean poll();  
<beliebiger Datentyp> get();
```

- Funktionsweise

1. Beim asynchronen Aufruf wird (statt dem eigentlichen Ergebnis) sofort ein Future-Objekt zurückgegeben
2. Das Future-Objekt lässt sich befragen, ob der tatsächliche Rückgabewert der Operation bereits vorliegt bzw. ob die Operation beendet ist  
→ `poll()`
3. Ein Aufruf von `get()`
  - liefert das Ergebnis der Operation sofort zurück, sofern es zu diesem Zeitpunkt bereits vorliegt **oder**
  - blockiert solange, bis das Ergebnis eingetroffen ist



## Anwendungsbeispiel Executor-Service

- Interface ExecutorService

- Erlaubt asynchrone Ausführung von Tasks
- Task bei Executor-Service „abgeben“, Ergebnis per Future
- Zentrale Methode

```
<T> Future<T> submit(Callable<T> task)
```

- Interface Callable

- Schnittstelle

```
public interface Callable<V> {  
    V call() throws Exception;  
}
```

- Unterschiede zu Runnable

- Rückgabewert
- Exception



## Schnittstelle Future

- Umfang

- Methoden der allgemeinen Future-Schnittstelle
- Zusätzliche Methoden zum Abbrechen von Tasks

- Schnittstelle

```
public interface Future<V> {  
    public V get();  
    public V get(long timeout, TimeUnit unit);  
  
    public boolean isDone(); // --> poll()  
  
    public boolean cancel(boolean mayInterruptIfRunning);  
    public boolean isCancelled();  
}
```



## Klasse java.util.concurrent.Executors

- Überblick

- Hilfsmethoden zur Erzeugung von Callable-Objekten
- Bereitstellung von ExecutorService-Implementierungen

- Wichtige Factory-Methoden für ExecutorServices

- Ausführung in einem einzigen Thread

```
public static ExecutorService newSingleThreadExecutor();
```

- Konstante Thread-Anzahl

```
public static ExecutorService newFixedThreadPool(int nThreads);
```

- ...

- ExecutorService nach Verwendung wieder beenden:

```
public void shutdown();
```



## Beispielklasse

```
public class FutureExample implements Callable<Integer> {
    private int a, b;

    public FutureExample(int a, int b) {
        this.a = a;
        this.b = b;
    }

    public Integer call() throws Exception {
        return a * b;
    }
}
```

## Aufruf

```
ExecutorService es = Executors.newSingleThreadExecutor();
FutureExample task = new FutureExample(4, 7);
Future<Integer> f = es.submit(task);
[...]
System.out.println("result: " + f.get());
```



- Extrahieren von Daten typische MapReduce-Anwendung
  - Statistiken, Data Mining
  - Mustererkennung, Machine Learning
  - Graph-Algorithmen

- Eingabedaten häufig in Form von Textzeilen

- Partitionierung von Eingabedaten problematisch:

**Zusammengehörige** Daten können in **unterschiedlichen** Worker-Threads verarbeitet werden

- Lösungsmöglichkeiten:

- Beeinflussung der Partitionierung durch Eingabedaten
- Verwerfen unvollständiger Datensätze, z. B. bei statistischen Auswertungen großer Datenmengen



# Auffinden von Zeichenketten

## Einfache Methoden in Java.lang.String

### Finden konstanter Zeichenketten

- Vorwärts suchen ab bestimmter Position:

```
public int indexOf(String str, int start);
```

- Rückwärts suchen ab bestimmter Position:

```
public int lastIndexOf(String str, int start);
```

### Operationen mit regulären Ausdrücken:

- Test, ob regulärer Ausdruck anwendbar:

```
public boolean matches(String regex);
```

- Aufteilen in Array anhand von regulärem Ausdruck:

```
public String[] split(String regex, int limit);
```



# Reguläre Ausdrücke in Java

## Reguläre Ausdrücke mit java.util.regex.Pattern

### Nützliche Teilausdrücke

- Beliebiges Zeichen: .
- Anfang des Strings: ^
- String-Ende: \$
- Wiederholung: \* → beliebig oft, + → mindestens einmal
- Zeichenauswahl: [abc] → a, b oder c
- Zeichenklassen: \s Leerzeichen, \d Ziffern

### Beispiele:

```
^Hallo // Hallo am Anfang des Strings
welt.$ // welt gefolgt von beliebigem Zeichen am Stringende
te[sx]t // te, mindestens einmal s oder x, t
```



- Vorkompilieren häufig benötigter Ausdrücke:

```
Pattern p = Pattern.compile(regex);
Matcher m = p.matcher(str);
```

- Test, ob Ausdruck passt:

```
public boolean matches();
```

- Position abfragen, wo ein Treffer gefunden wurde:

```
public int start();
```

- Beispiel:

```
if (m.matches()) {
    int pos = m.start();
    ...
}
```

## Weitere Informationen

- J. Dean, S. Ghemawat, MapReduce: Simplified Data Processing on Large Clusters, OSDI 2004 Proceedings, S. 137-150,  
<http://www.usenix.org/events/osdi04/tech/dean.html>
- Apache Hadoop  
<http://hadoop.apache.org/>
- Hadoop SVN repository  
<http://svn.apache.org/viewvc/hadoop/common/>

- Bei bekanntem Start- und End-Index:

```
public String substring(int start, int end);
```

- Ausgabe des Strings ab start bis end, **ohne** end selbst.

- Tipp: Zum Test ein Zeichen vor und nach dem gesuchten Teilbereich ausgeben lassen

- Aufteilen nach regulärem Ausdruck:

```
String[] parts = input.split(regex, 2);

if (parts.length() < 2)
    System.err.println("Not found");

String left = parts[0], right = parts[1];
```