

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: 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.

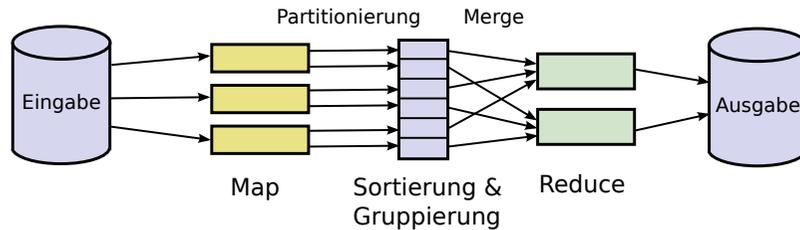


Hadoop-Framework (Komponenten)



Ablauf von MapReduce

- Übersicht: Ablauf eines MapReduce-Durchlaufs.



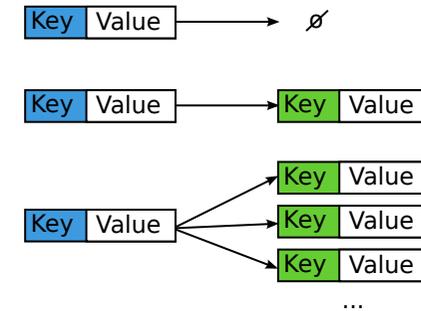
- Darstellung der Daten in Form von **Schlüssel-Wert-Paaren**



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-Schnittstelle

- Schnittstelle **Mapper** in Apache Hadoop

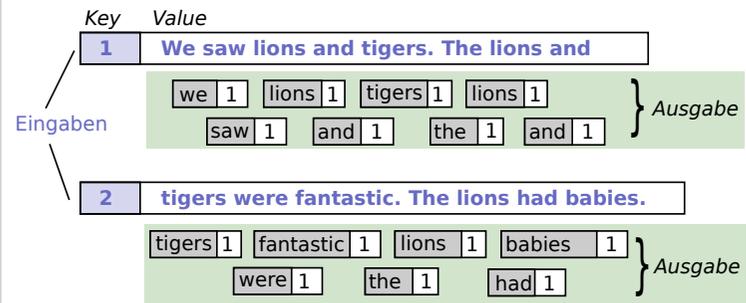
```
public class Mapper<KEYIN, VALUEIN, KEYOUT, VALUEOUT> {  
    void map(KEYIN key, VALUEIN value, Context context) {  
        context.write((KEYOUT) key, (VALUEOUT) value);  
    }  
}
```

- 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



Mapper-Beispiel

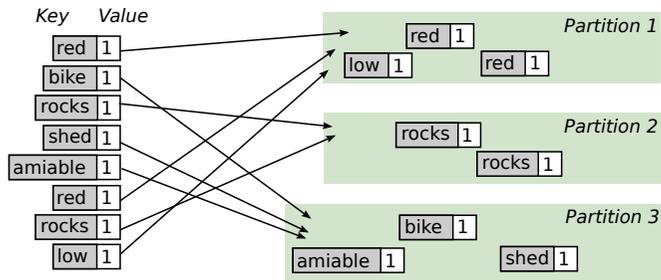
- Beispiel: Zählen von Wörtern
- Mapper-Eingabe
Schlüssel: Zeilennummer
Wert: Textzeile
- Mapper-Ausgabe
Schlüssel: Wort
Wert: Anzahl (hier: 1 für jedes Wort)



Partitionierer

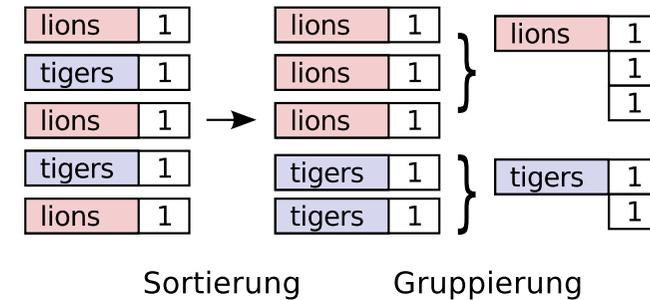
- Zuordnung der Mapper-Ausgabe zu späterem Reducer
 - Gleiche Schlüssel müssen zu gleichem Reducer
 - Eingaben der einzelnen Reducer sind unabhängig → parallelisierbar
- Schnittstelle in Apache Hadoop

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



Sortierung und Gruppierung

- Sortierung und Gruppierung jeder Partition 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**

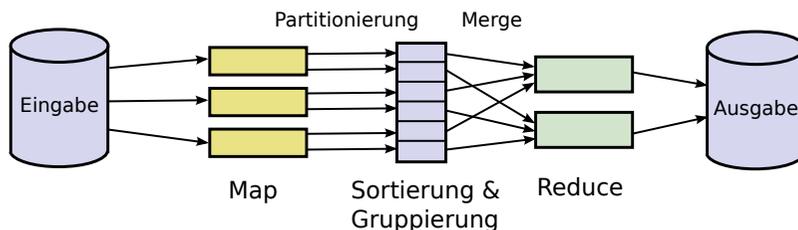


Sortierung Gruppierung



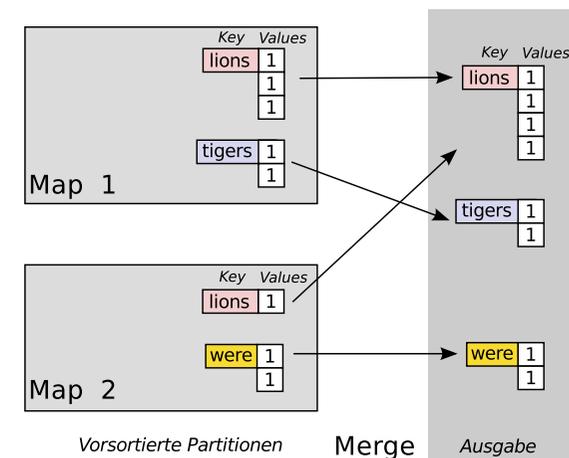
Ablauf von MapReduce

- Übersicht: Ablauf eines MapReduce-Durchlaufs.



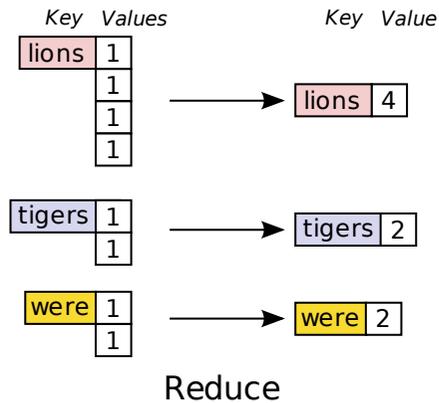
Merge

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



Reduce-Phase

- **Zusammenführen** von Daten in der Reduce-Phase
 - Eingabe in Form von Schlüssel und allen zugehörigen Werten aus Mapper
 - Parallele Verarbeitung verschiedener Teilbereiche von Schlüssel
 - 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)



Überblick

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



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 instanziiieren
 - Lösung mittels „Factory Pattern“



Factory Pattern

- Problemstellung: Es sollen Objekte instanziiert 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



Abstract Factory Pattern

- 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

- 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);  
}
```



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);  
    }  
}
```



Sortieren mittels Comparator-Objekten

■ 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

■ Aufgabe: Zusammenführen bereits vorsortierter Listen

- Vergleich des obersten Elements über alle Listen
- Kleinstes Element bestimmt nächstes Ausgabelement

■ 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

■ 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



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();
```



Futures

- Allgemeine Schnittstelle

```
boolean isDone();  
<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
→ `isDone()`
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



Futures in Java

`java.util.concurrent.Future`

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();  
  
    public boolean cancel(boolean mayInterruptIfRunning);  
    public boolean isCancelled();  
}
```



Futures in Java

`java.util.concurrent.ExecutorService`

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



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: Extrahieren von Daten

- 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
```



Teilstrings extrahieren

- 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 Testen 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];
```



Reguläre Ausdrücke in Java

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/>

