



Information  
Systems  
Group

Hasso Plattner Institut | Universität Potsdam

# MapReduce on Hadoop

## Übung – DBS2

Felix Naumann  
Alexander Albrecht

# Motivation

- Problem: Verarbeiten großer Datenmengen (z.B. Wikipedia Corpus)
  - Häufigkeiten zählen, Invertierten Index berechnen, ...
- Alternative Szenarien
  - Log-File Analyse
  - Google Page Rank
  - Wetterdaten ...

# Verteiltes Rechnen

- **Bekannte Beispiele**

- Search for Extraterrestrial Intelligence



- IBM Deep Blue



- Google (PageRank)



- Rendering

- Wettervorhersage

- ...



# Motivation

## Beispiel: Worthäufigkeit

```
01: String[] input={"this is the foo text",
                     "this is the bar text","even more foo text"};
02: HashMap<String, Integer> wordcount = new HashMap<String,
                                         Integer>();
03: for (int i = 0; i < input.length; i++) {
04:     String[] words = input[i].split(" ");
05:     for (int j = 0; j < words.length; j++) {
06:         if (wordcount.containsKey(words[j])) {
07:             wordcount.put(words[j], wordcount.get(words[j]) + 1);
08:         } else {
09:             wordcount.put(words[j], 1);
10:         }
11:     }
12: }
13: for (String s : wordcount.keySet())
14:     System.out.println(s + ":" + wordcount.get(s));
```

# Motivation

## Beispiel: Worthäufigkeit

```
01: String[] input={"this is the foo text",
                     "this is the bar text","even more foo text"};
02: HashMap<String, Integer> wordcount = new HashMap<String,
03: for (int i = 0; i < input.length; i++) {
04:     String[] words = input[i].split(" ");
05:     for (int j = 0; j < words.length; j++) {
06:         if (wordcount.containsKey(words[j])) {
07:             wordcount.put(words[j], wordcount.get(wor
08:         } else {
09:             wordcount.put(words[j], 1);
10:     }
11: }
12: }
13: for (String s : wordcount.keySet())
14:     System.out.println(s + ":" + wordcount.get(s));
```

|        |
|--------|
| text:3 |
| is:2   |
| more:1 |
| even:1 |
| foo:2  |
| the:2  |
| bar:1  |
| this:2 |

# Motivation

---

- Verteiltes Rechnen
  - Programmiermodell erforderlich
  - Infrastruktur erforderlich (Load balancing, data distribution, messaging, hardware failures)
- Google Strategie: Berechnung auf mehrere Rechner verteilen
  - Billige Standard-Hardware
  - **Shared Nothing**
  - Geographisch verteilt
  - Repliziert

# Motivation

- Beispiel: Worthäufigkeit
- Phase 1
  - **Input:**

```
(1, "this is the foo text")
(2, "this is the bar text")
(3, "even more foo text")
```
  - **Output:**

```
("this", 1),("is", 1),("the", 1), ("foo", 1), ("text", 1)
("this", 1),("is", 1),("the", 1), ("bar", 1), ("text", 1)
("even", 1),("more", 1),("foo", 1), ("text", 1)
```

# Motivation

---

- Beispiel: Worthäufigkeit
- Phase 2 / Task 1
  - **Input:**  
`("this", 1), ("this", 1)`
  - **Output:**  
`("this", 2)`
- ...
- Phase 2 / Task 8
  - **Input:**  
`("text", 1), ("text", 1), ("text", 1)`
  - **Output:**  
`("text", 3)`

# Motivation

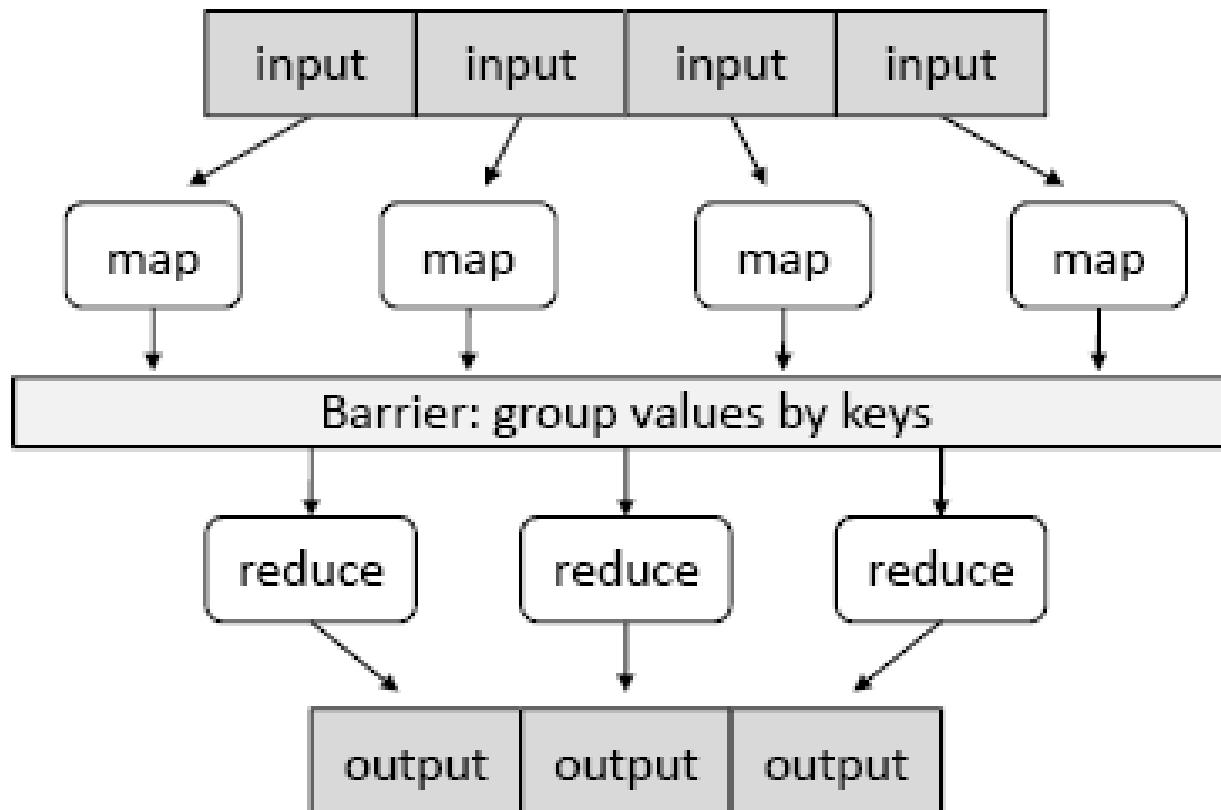
- Beispiel: Worthäufigkeit
- Phase 2 / Task 1
  - **Input:**  
`("this", 1), ("this", 1)`
  - **Output:**  
`("this", 2)`
- ...
- Phase 2 / Task 8
  - **Input:**  
`("text", 1), ("text", 1), ("text", 1)`
  - **Output:**  
`("text", 3)`

```
text:3
is:2
more:1
even:1
foo:2
the:2
bar:1
this:2
```

# Map/Reduce

- **Beobachtung:** Datenverarbeitungsschritte können oft mit Hilfe der zwei Funktionen `map()` und `reduce()` beschrieben werden
  - `map` – Bildet ein Eingabepaar  $(k_1, v_1)$  auf eine Liste von Ausgabepaaren  $(k_2, v_2)$  ab, z.B. **map( $k_1, v_1$ ) -> list( $k_2, v_2$ )**
  - `reduce` – Erhält als Eingabe einen Schlüssel und eine Liste von Werten und bildet die Eingabe auf ein (oder auch mehrere) Ausgabepaar  $(k_2, v_2)$  ab, z.B. **reduce( $k_2, list(v_2)$ ) -> (k<sub>2</sub>, v<sub>3</sub>)**
- Map => Reduce
  - Gruppiere alle Zwischenergebnisse mit gleichem Schlüssel  $k_2$  und leite die Liste von Werten **list( $v_2$ )** an `reduce()` weiter

# Map/Reduce



# Map/Reduce

- Beispiel: Worthäufigkeit
  - `map()`  
`emit (word, 1)` für jedes Wort im Dokument
  - `reduce()`  
summiert alle Werte für ein Wort auf  
`emit (word, total count)`

# Map/Reduce on Hadoop

- Beispiel: Worthäufigkeit (Mapper)

```
01: public static class TokenizerMapper extends Mapper<Object,
                                                Text, Text, IntWritable>
02: {
03:     private final static IntWritable one = new IntWritable(1);
04:     private Text word = new Text();
05:     public void map(Object key, Text value, Context context)
06:             throws IOException, InterruptedException
07:     {
08:         StringTokenizer itr =new StringTokenizer(value.toString());
09:         while (itr.hasMoreTokens()) {
10:             word.set(itr.nextToken());
11:             context.write(word, one);
12:         }
13:     }
}
```

# Map/Reduce on Hadoop

- Beispiel: Worthäufigkeit (Reducer)

```
01: public static class IntSumReducer extends Reducer
      <Text, IntWritable, Text, IntWritable>
02: {
03:     private IntWritable result = new IntWritable();
04:     public void reduce(Text key, Iterable<IntWritable> values,
05:                         Context context) throws IOException, InterruptedException
06:     {
07:         int sum = 0;
08:         for (IntWritable val : values) {
09:             sum += val.get();
10:         }
11:         result.set(sum);
12:         context.write(key, result);
13:     }
14: }
```

# Map/Reduce

- Combiner
- Beispiel: Worthäufigkeit
  - Mapper erzeugen für eine Eingabe wiederholt gleiche Ausgaben, z.B. ("is", 1)
  - (Fast) alle Ausgaben gehen über das Netzwerk (shuffle process)
  - Problem wird durch Anwendung einer Combiner-Methode auf dem Map-Rechner vermindert
  - Verwende Code von reduce() wird für combine()
    - `job.setCombinerClass(IntSumReducer.class);`
    - `job.setCombinerClass(InvertedIndexReducer.class);`

# MapReduce auf Hadoop

- Open Source Implementation von Apache
- Version 0.20
- Wer setzt Hadoop ein? <http://wiki.apache.org/hadoop/PoweredBy>
  - Yahoo!
    - *Biggest cluster: 2000 nodes, used to support research for Ad Systems and Web Search.*
  - Amazon
    - *Process millions of sessions daily for analytics, using both the Java and streaming APIs. Clusters vary from 1 to 100 nodes.*
  - Facebook
    - *Use Hadoop to store copies of internal log and dimension data sources and use it as a source for reporting/analytics. 600 machine cluster.*
  - 29.01.2010