

# Middleware – Cloud Computing – Übung

## MapReduce: Übersicht & Ablauf

---

Wintersemester 2025/26

Paul Bergmann, Christian Berger

Friedrich-Alexander-Universität Erlangen-Nürnberg  
Lehrstuhl Informatik 4 (Systemsoftware)

<https://sys.cs.fau.de>



Lehrstuhl für Informatik 4  
Systemsoftware



Friedrich-Alexander-Universität  
Technische Fakultät

## MapReduce

Einführung und Grundlagen

Ablauf eines MapReduce-Jobs

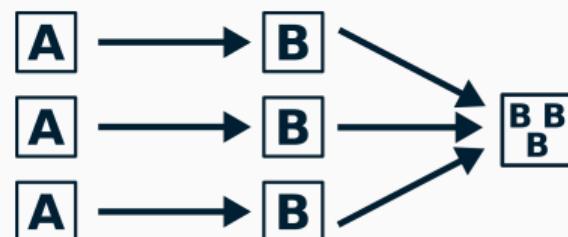
Aufgaben des Frameworks

# MapReduce

---

## Einführung und Grundlagen

- 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 Aufgaben in MapReduce
  - Aufteilen in (potentiell mehrere) Map- und Reduce-Schritte
  - Implementierung der Map- und Reduce-Methoden (Entwickler)
  - Parallelisierung und Verteilung (MapReduce-**Framework**)



- „*MapReduce: Simplified data processing on large clusters*“ (OSDI'04)
- Ursprüngliche Implementierung von Google nicht öffentlich
- Zahlreiche Open-Source-Implementierungen (z. B. **Apache Hadoop**, Disco, MR4C)
  - 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)



Quelle der Illustration: <https://blog.codecentric.de/2013/08/einführung-in-hadoop-die-wichtigsten-komponenten-von-hadoop-teil-3-von-5/>

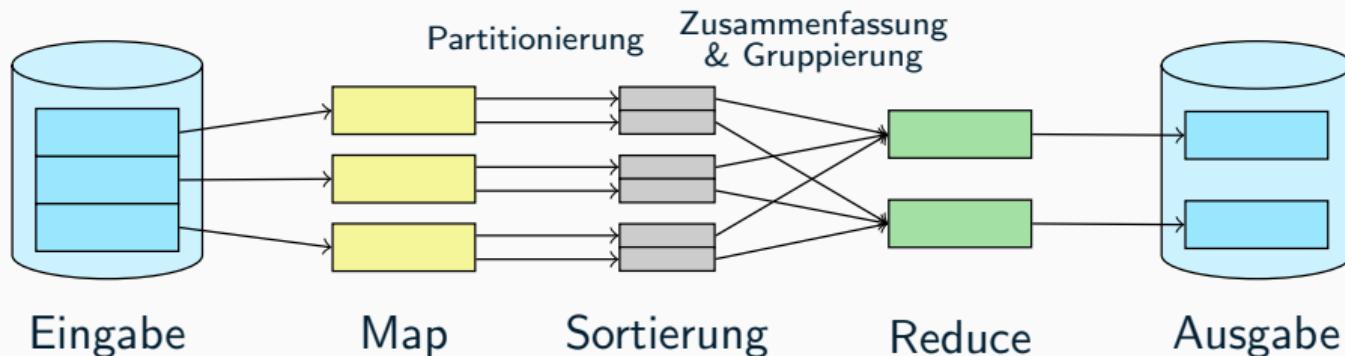
## MapReduce

---

### Ablauf eines MapReduce-Jobs

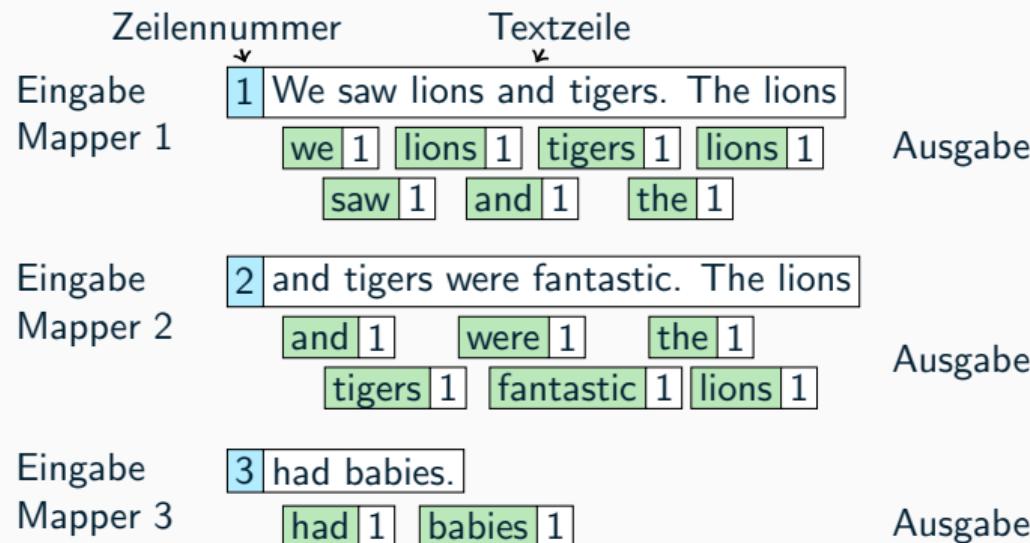
# Ablauf von MapReduce

- Übersicht: Ablauf eines MapReduce-Durchlaufs



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

- Abbildung in der Map-Phase
  - Parallel Verarbeitung verschiedener Teilbereiche der Eingabedaten
  - Eingabedaten in Form von Schlüssel-Wert-Paaren
  - Abbildung auf **variable Anzahl** von **neuen** Schlüssel-Wert-Paaren
- Beispiel: Zählen von Wörtern



- Schnittstelle **Mapper** in Apache Hadoop

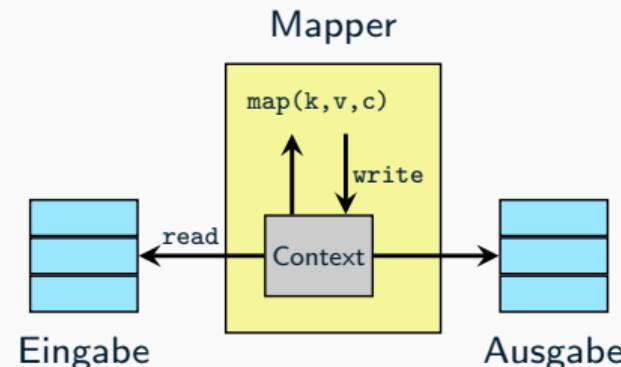
```
public class Mapper<KEYIN, VALUEIN, KEYOUT, VALUEOUT> {  
    void map(KEYIN key, VALUEIN value, Context context) {  
        context.write((KEYOUT) key, (VALUEOUT) value);  
    }  
}
```

- Festlegen von Datentypen mittels „Generics“

- Parameter:

- **key**: Schlüssel, z. B. Zeilennummer
- **value**: Wert, z. B. Inhalt der Zeile
- **context**: Ausführungskontext, enthält `write()`-Methode zur Ausgabe von Schlüssel-Wert-Paaren

- Jeder Mapper referenziert einen Context
- Context verwaltet die Ein- und Ausgabe des Mappers
  - Stellt Reader zum Lesen von Schlüssel-Wert-Paare aus Eingabe des Mappers bereit
  - Sammelt und bereitet Schlüssel-Wert-Paare für die Ausgabe des Mappers vor (z.B. Partitionierung)
- Datenfluss im Mapper:
  1. Reader liest nächstes Schlüssel-Wert-Paar aus Eingabe
  2. Schlüssel-Wert-Paar wird an map-Funktion übergeben
  3. map-Funktion übergibt Context das Ergebnis
  4. Context schreibt Ergebnis in die Ausgabe

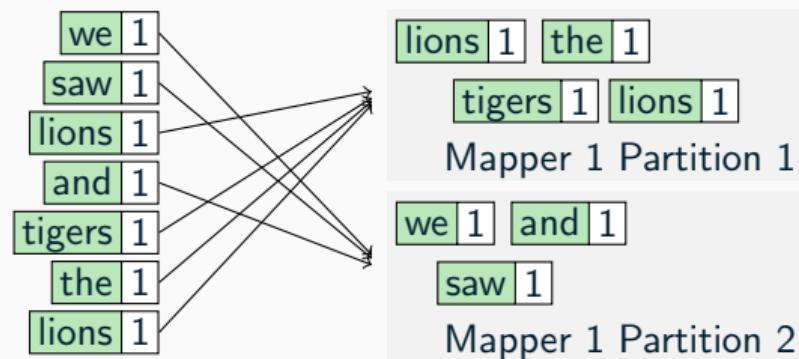


## Context-Parameter in map

Der Parameter `context` in `map` zeigt auf das selbe Objekt, das der Mapper intern verwendet. Diese Trennung erlaubt eine komfortablere Implementierung der `map`-Funktion.

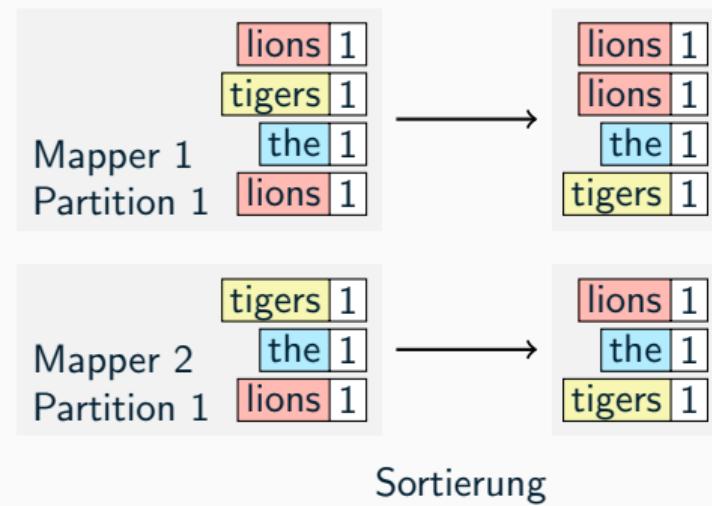
- Zuordnung der Mapper-Ausgabe zu späterem Reducer
  - Gleiche Schlüssel müssen zu gleichem Reducer
  - Eingaben der einzelnen Reducer sind unabhängig → parallelisierbar
- Schnittstelle **Partitioner** in Apache Hadoop

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



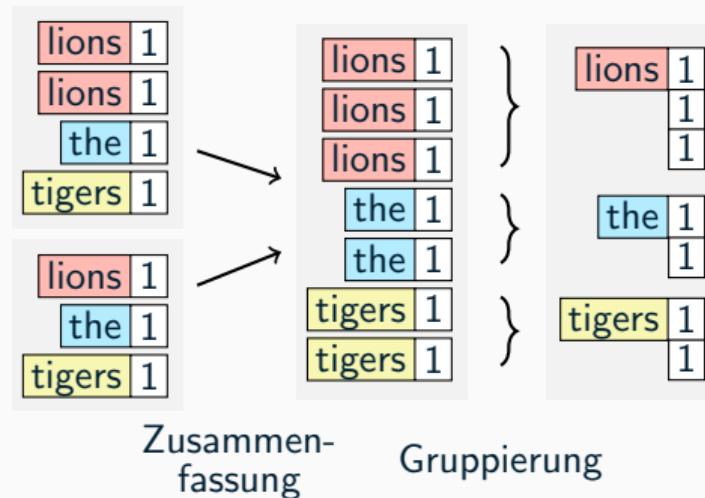
- Sortieren der Partitionen nach **Schlüssel**

- Lokale Vorsortierung nach Verarbeitung der Daten durch Mapper
- Jede Partition wird einzeln sortiert



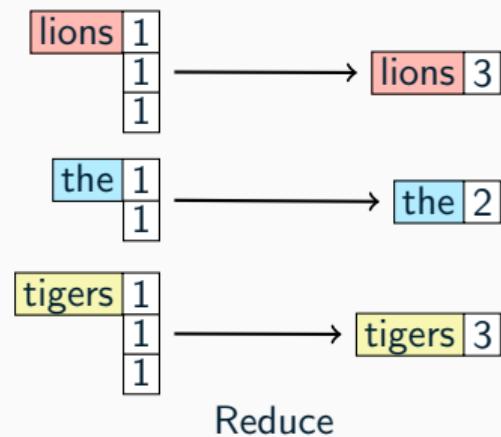
- Zusammenfassen und Gruppierung der Daten nach **Schlüssel**

- Eingaben für Reducer befinden sich in (mehreren) Mapper-Ausgaben
- Zusammenfassung** der vorsortierten Partitionen zu einer vollständig sortierten Gesamtliste
- Gruppierung** aller Werte unter identischem Schlüssel
- Statt Schlüssel-Wert-Paar nun Schlüssel und **Liste von Werten**



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

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



- 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);  
        }  
    }  
}
```

- Parameter:
  - **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

# **MapReduce**

---

## **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
  - Dateneingabe (Deserialisierung)
  - Mapper
  - Partitionierung
  - Sortierung/Gruppierung
  - Reducer
  - Datenausgabe (Serialisierung)