

18. Oktober 2010

(Advanced) Cloud Computing

Teamprojekt & Projekt

Veranstalter: Prof. Dr. Georg Lausen
Betreuer: Thomas Hordnung,
Alexander Schätzle,
Martin Przyaciel-Zablocki

Anforderungen

▶ Studienordnung

- **Master:** 16 ECTS
→ 480 Semesterstunden ~ 34h/Woche p.P.
- **Bachelor:** 6 ECTS
→ 180 Semesterstunden ~ 13h/Woche p.P.
- Teamgröße: 3–4 Studenten
- Projektbericht: ca. 15–25 Seiten p.P.
- Abschlusspräsentation: ca. 15min p.P.
- Arbeitsleistung einzelner Teilnehmer muss klar voneinander abzugrenzen sein

Organisation

▶ Zeit und Ort:

- Montag 14–17 Uhr (c.t.)
- Raum: SR 00 007 (MMR), Geb. 106

▶ Nächstes Treffen:

- Dienstag, 2. November 2010 14–17 Uhr (c.t.)
- Raum: 01–029, Geb. 51

▶ Weiterer Ablauf:

- Treffen mit Kurzpräsentationen aller Teams
- Weitere individuelle Termine auf Anfrage

Ziele

- ▶ Gemeinsame Arbeit an einem großen Projekt
- ▶ Eigenständiges Recherchieren und Arbeiten
- ▶ Verbesserung der individuellen Programmierfähigkeiten (hier: Java)
- ▶ Einarbeiten in neue Themen (hier: RDF und MapReduce)
- ▶ Probleme bei größeren Projekten Kennen und Lösen lernen
- ▶ Erfahrungen im Umgang mit MapReduce sammeln

Schlüsselfaktoren zum Erfolg

- ▶ Gute Team–interne Organisation
 - Aufteilung von Verantwortung
 - Erfüllen von Verantwortung
 - Einhalten von Fristen
 - Gegenseitige Hilfe und Unterstützung
 - Saubere Definition von Schnittstellen
- ▶ Nutzen entsprechender Software (z.B. SVN)
- ▶ Einbringen individueller Fähigkeiten
- ▶ Spezialisierung auf Teilgebiete, ohne den Blick für das Ganze zu verlieren

Benotungsgrundlage

- ▶ Insbesondere (aber nicht ausschließlich)
 - Umfang und Schwierigkeit der geleisteten Arbeit/Implementierung
 - Teamleistung: ein gelungenes Projekt wirkt sich in der Regel positiv auf die Noten einzelner Teammitglieder aus
 - Rolle und Mitarbeit im Team (Koordination etc.)
 - Qualität des Codes (Formatierung, Dokumentation)
 - Individuelle Ausarbeitung (Projektbericht)
 - Mündlicher Vortrag (Abschlusspräsentation)

Projektablauf

- ▶ **Einarbeitungsphase**
 - Bis Dienstag, 2. November 2010
 - Endgültige Themenvergabe
- ▶ **Kurzpräsentation**
 - 8. November 2010
 - Projektvorstellung
 - Eigene Milestones
 - Interne Arbeitsaufteilung
- ▶ **Implementierungsphase**
 - Programmierung & Dokumentation
 - 10. / 17. Januar 2011: Zwischenbericht zu den Milestones (Treffen oder Präsentation)
- ▶ **Abschlusspräsentation**
 - 7. Februar 2011
 - Abgabe Projektbericht (14. Februar 2011)

Aufgabenstellung

▶ Teamprojekt (Master)

- Entwurf und Implementierung eines verteilten RDF-Stores auf Basis von Hadoop (MapReduce)

▶ Projekt (Bachelor)

- Implementierung eines Graphenproblems auf Basis von Hadoop (MapReduce)
- Beispiel: Die Suche nach kürzesten Pfaden innerhalb eines RDF-Graphen

2. MapReduce

»» Principles & Basic Concepts

MapReduce

▶ Google's MapReduce

- Automatic parallelization of computations
- Fix and simple level of abstraction: [Map & Reduce](#)

▶ Distributed File System

- Clusters of commodity hardware
→ Fault tolerance by replication
- Very large files / write–once, read–many–times

▶ Hadoop

- Open Source implementation (Apache project)
- Used by Yahoo, Facebook, Amazon, IBM, Last.fm, ...

MapReduce (2)

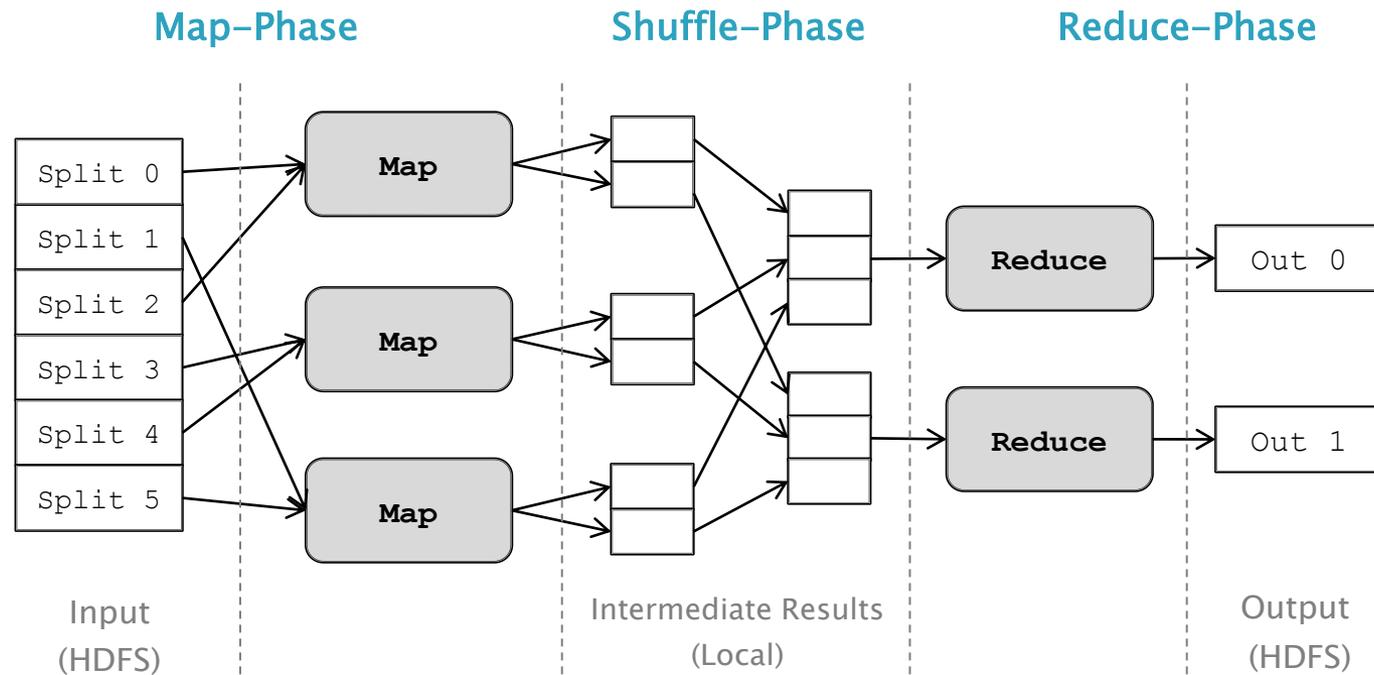
▶ Map

- `map(in_key, in_value) -> (out_key, intermediate_value) list`
- inputs: records from data source as (`key`, `value`) pairs, e.g. (`filename`, `line`)
- outputs: one or more intermediate values with an output key

▶ Reduce

- `reduce(out_key, intermediate_value list) -> out_value list`
- After map phase all intermediate values for **one** output key are combined together in a list
- reduce combines those intermediate values into one or more final values for the **same** output key

MapReduce (3)



Empfehlungen

- ▶ Hadoop Training
 - <http://www.cloudera.com/hadoop/>
- ▶ Cloudera's Distribution For Hadoop
 - Virtual Machine (→VMware Image)
 - <http://www.cloudera.com/downloads/>
 - CDH 3 (beta)
- ▶ Buch: "Hadoop: The Definitive Guide"
von Tom White

3. RDF

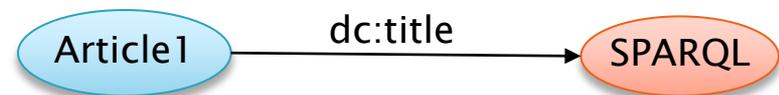
»» Principles & Basic Concepts

Resource Description Framework (RDF)

- ▶ Datenformat
- ▶ Grundpfeiler des Semantic Web
- ▶ Sprache um Aussagen und Informationen über Ressourcen formal zu beschreiben
- ▶ Vom W3C standardisiert
 - ausführliche Informationen unter <http://www.w3.org/RDF>
- ▶ Datenformat basiert auf Tripeln der Form
 - (Subjekt, Prädikat, Objekt)

RDF Triple

- ▶ Jedes Tripel repräsentiert einen Wissensfakt, z.B.
 - (Article1, dc:title, „SPARQL“)
- ▶ „**Subjekt**“ hat eine Eigenschaft „**Prädikat**“ mit dem Wert „**Objekt**“
 - „Article1“ hat den „Titel“ „SPARQL“
- ▶ Darstellung eines Tripels als eine gerichtete Kante in einem Graphen möglich
 - Subjekt, Objekt → **Knoten**
 - Prädikat → **Kanten**



RDF Triple (2)

- ▶ Formale Definition:
 - Gegeben drei Mengen:
 - U** – Uniform Resource Identifiers (URIs)
 - B** – Blank Nodes („leere Knoten“)
 - L** – Literale
- ▶ Ein RDF Tripel ist eine Element aus der Menge
 $(\mathbf{B} \cup \mathbf{U}) \times \mathbf{U} \times (\mathbf{B} \cup \mathbf{L} \cup \mathbf{U})$

- ▶ Beispiel:

(Article1, dc:title, „SPARQL“)

URI

URI

Literal

RDF Datenbanken

- ▶ Eine RDF Datenbank D (auch „Graph“ genannt) ist eine Menge von RDF Tripeln, formal

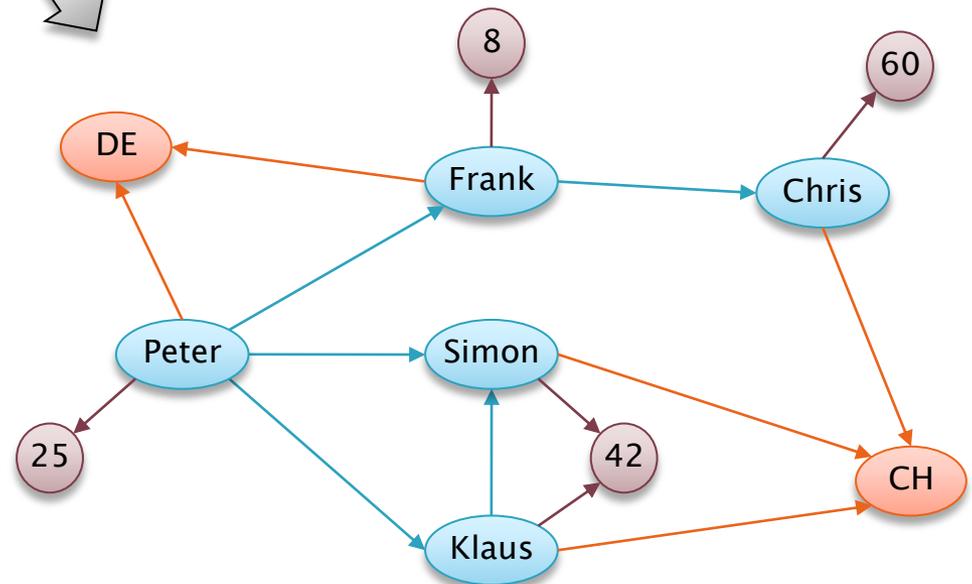
$$D \subseteq (B \cup U) \times U \times (B \cup L \cup U)$$

- ▶ Serialisierung von RDF Daten in verschiedenen Formaten möglich,
 - z.B. NTriples, N3, RDF/XML, ...

Beispiel

```
@prefix ex: <http://example.com/> .  
@prefix foaf: <http://xmlns.com/foaf/> .  
  
ex:Chris    foaf:knows    ex:Simon .  
ex:Chris    foaf:knows    ex:Sarah .  
ex:Sarah    foaf:country  ex:DE .  
            ...
```

RDF Dokument in N3



RDF Graph

Empfehlungen

- ▶ RDF Einführung
 - siehe Homepage
- ▶ W3C RDF Primer
 - <http://www.w3.org/TR/rdf-primer/>
- ▶ Vorlesungsfolien FGIS
 - <http://dbis/index.php?file=fruehereVeranstaltungen.html>
 - (SS 2009 / WS 2007)
- ▶ RDF Tutorial
 - <http://www.w3schools.com/rdf/default.asp>

Agenda

- ▶ Einarbeitungsphase in MapReduce, RDF und Aufgabenstellung
- ▶ Cloudera's Distribution for Hadoop installieren
- ▶ Team Mitglieder kennenlernen
- ▶ **Nächstes Treffen:**
 - Dienstag, 2. November 2010 14–17 Uhr (c.t.)
 - Raum: 01–029, Geb. 51