Vorlesung

Webbasierte Informationssysteme

(CS4130)

Datenverarbeitung mit Spark und Flink

Professor Dr. rer. nat. habil. Sven Groppe
https://www.ifis.uni-luebeck.de/index.php?id=groppe

Chronologische Übersicht über die Themen

Typischer Big Data Analytics Stack (z.B. Spark, Flink, Storm)

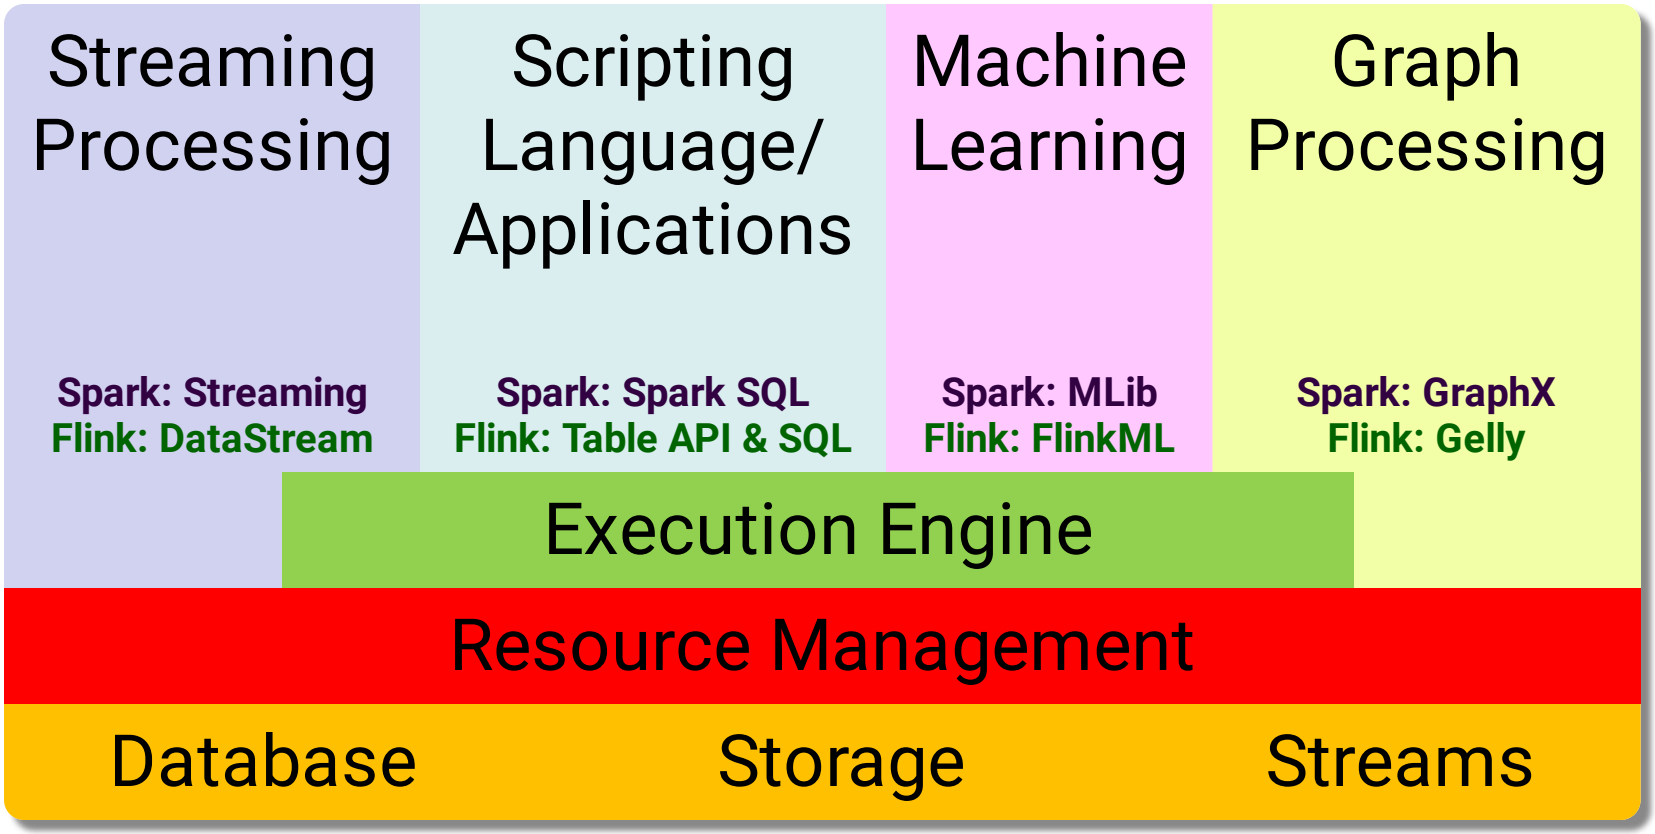

Evolution der Big Data Analytics Engines

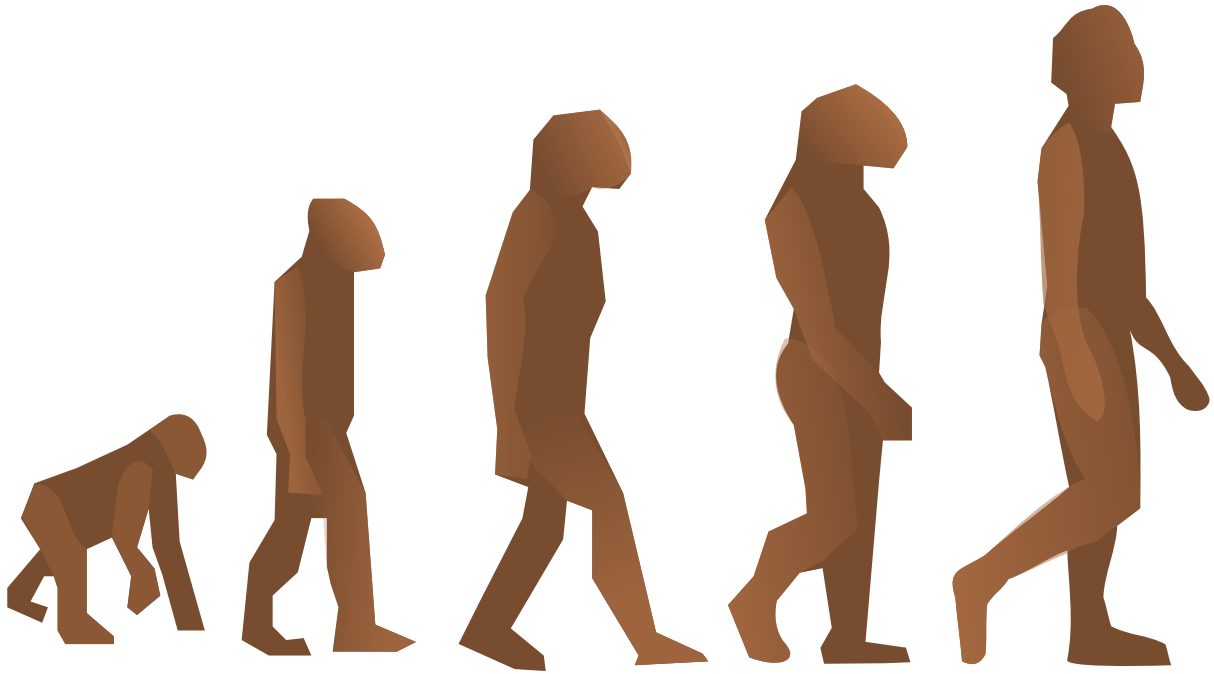

	1. Generation	2. Generation	3. Generation	4. Generation	5. Generation
Features	**Batch**	**+ Interactive**	**+ Near-Real-Time[1] + Iterative Processing**	**+ Real-Time Streaming + Native It. Processing**	**?**
Verarbeitungsmodell	**MapReduce**	**DAG Dataflows**	**Resilient[2] Distributed Datasets (RDD)**	**Cyclic Dataflows**	**?**
Engine	**Hadoop**	**TEZ**	**Spark**	**Flink**	**?**

[1] durch „Mini-Batches“ [2] resilient ≅ elastisch

Java 8 Stream API

- Parallele Ausführung im Hauptspeicher

```
(1)   Path path = Paths.get("C:\\test.txt");
      Map<String, Long> c = Files
(2)         .lines(path)  // read all lines from file as stream
            // split lines to words
(3)         .flatMap(line -> Arrays.stream(line.split("\\W+")))
            // for each word generate (word, 1)-tuple
(4)         .map(word -> new SimpleEntry<>(word,1))
            // group be the words and sum it up
(5)+(6)     .collect(Collectors.groupingBy(SimpleEntry::getKey, Collectors.counting()));
      // print out result
      c.forEach( (k,v) -> System.out.println(String.format("%s => %d", k, v)) );
```

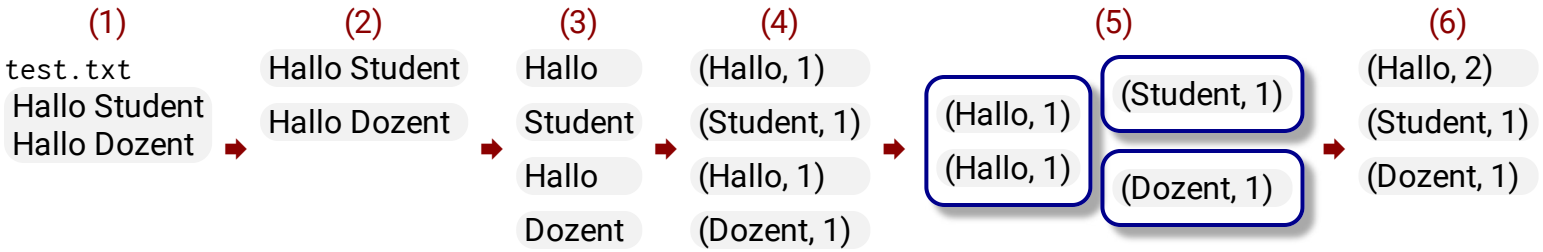

- Apache Spark/Flink
  - Ähnliche API für verteilte Ausführung und Externspeicherauslagerung bei Bedarf

Spark ↔ Flink

- Core

```
SparkSession sc = SparkSession.builder()
  .appName("WordCount").getOrCreate();
// read file
JavaRDD<String> text = sc.textFile("hdfs://...");
JavaPairRDD<String, Integer> counts = text
  // split into words
  .flatMap(s -> Arrays.asList(s.split(" ")).iterator())
  // for each word generate tuple (word, 1)
  .mapToPair(word -> new Tuple2<>(word, 1))
  // group by key and sum up tuple field "1"
  .reduceByKey((a, b) -> a + b);
```

- DataSet API

```
ExecutionEnvironment env = ExecutionEnvironment
                          .createLocalEnvironment();
DataSet<String> text = env.readTextFile("c:\\...");
DataSet<Tuple2<String, Integer>> counts = text
  // split up lines in words
  .flatMap((FlatMapFunction<String, String>)(s, o)
    -> {for(final String r: s.toLowerCase()
            .split("\\W+")){o.collect(r);}})
  .returns(String.class)
  // generate tuples (word, 1)
  .flatMap((FlatMapFunction<String,
            Tuple2<String, Integer>>)(s, o)
   -> {o.collect(new Tuple2<String, Integer>(s,1));})
  .returns(new TypeHint<Tuple2<String, Integer>>(){})
  .groupBy(0) // group by the tuple field "0"...
  .sum(1);    // ...and sum up tuple field "1"
```

- Streaming

```
JavaStreamingContext jssc = ...
...
JavaDStream<String> counts = text.flatMap(...
jssc.start();
jssc.awaitTermination();
```

- DataStream API

```
StreamExecutionEnvironment env =
   StreamExecutionEnvironment.getExecutionEnvironment();
DataStream<String> text = env.readTextFile("c:\\...");
DataStream<Tuple2<String, Integer>> counts = text
...    .keyBy(0).sum(1);
env.execute("Streaming Example");
```

Beobachtungen

- Ähnliche APIs
  - Java 8, Spark, Flink
  - Batch-Verarbeitung, Streaming bei Spark/Flink
- Unterschiede
  - Initialisierung der Ausführungsumgebung
  - Unterschiedliche Klassen für die Repräsentation der Datensätze/-ströme
    - Mit vielen gleichnamigen Methoden (⇝ ähnliche Verwendung der APIs)
    - Fehlende und zusätzliche Methoden teilweise mit ähnlicher, aber nicht gleicher Bedeutung
    - Ausgabe
      - Flink DataSet API: (dozent,1) (student,1) (hallo,2)
      - Flink DataStream API: (student,1) (hallo,1) (hallo,2) (dozent,1)
        Kontinuierliche und iterative Stromverarbeitung, „rollende“ Ergebnisse…

Spark $\leftrightarrow$ Flink

- Unterstützung von Batch- und Stromverarbeitung
- Sowohl API auf Tabellen als auch ganze SQL-Anfragen

- Kompatibel zu Hive
  - Daten, Anfragen, UDFs

```
df.filter(col.get("age").gt(21))
  .select(col("name"));
```

```
df.sql("SELECT name FROM table where age>21");
```

- Im Vergleich dazu relativ eingeschränktes SQL

```
table.where("age > 21")
     .select(col("name"));
```

```
table.sql("SELECT name FROM table where age>21");
```

Vorteile von Flink 1/2

- **Nativ in Java** programmiert und dadurch stimmigere Java-API (Spark ist in **nativ Scala** programmiert)
- Besseres **Memory-Management**
  - **Serialisierung von Daten** in Byte-Arrays,
  - **Buffermanagement vergleichbar zu DBMS**
  - **eigene Speicherverwaltung** (anstelle von zeitraubender Garbage Collection) vergleichbar zu C/C++

Vorteile von Flink 2/2

- **Automatische Optimierung**
  (z.B. Filter-Push-Down) der Verarbeitung
  (in Spark oft **manuelle Optimierung** notwendig)

- Unterstützung & Optimierung von **Iterationen**
  (`.iterate(…)` / `.iterateDelta(…)`)
  - Iterationen in Spark (und z.B. auch in Hadoop) in Applikationslogik, dadurch Overhead (z.B. Initialisierungen) in jeder Schleifeniteration

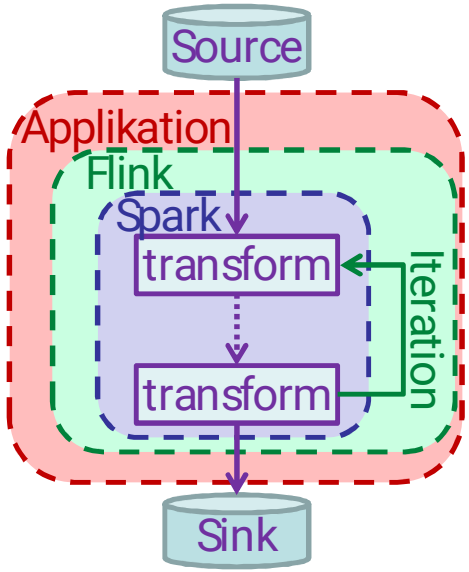

- Aber: **Spark holt** technologisch **auf** und entwickelt aktuelle APIs weiter (z.B. Memory-Management)…

Apache Flink API – Anatomie eines Flink-Programms 1/2

1. Beziehe eine **Ausführungsumgebung**
   - Basisklasse `ExecutionEnvironment` oder `StreamExecutionEnvironment` für Streams
     - `createLocalEnvironment()`: lokale Ausführungsumgebung
     - `createRemoteEnvironment(String host, int port, String... jarFiles)`: Cluster-Ausführungsumgebung
     - `getExecutionEnvironment()`: je nach Kontext Cluster- oder lokale Ausführungsumgebung
2. **Lade/kreiere** die initialen **Daten**
   - Durch Angabe einer Quelle, Standardquellen in Methoden der Ausführungseinheit
3. Spezifiziere **Transformationen** auf diesen Daten

Apache Flink API – Anatomie eines Flink-Programms 2/2

4. **Spezifiziere den Ablageort** der Ergebnisse
   - Durch Angabe einer Senke (engl. sink), z.B. `print()`, `writeAsText(String path)`
5. **Trigger** die Programmausführung
   - Batch-Verarbeitung: bereits durch Angabe einer Senke beginnt Ausführung
   - Stream-Verarbeitung: `environment.execute("Stream-Job");`

Viele der Ausführungen gelten analog für Spark (bis auf konkrete API-Calls und vorher erwähnte Unterschiede)

Apache Flink – Lazy Evaluation

- „initiale Daten laden/kreieren“ und „transformieren“
  - Hinzufügen von Operatoren zum Programmplan
  - Ausführung der Operatoren passiert nicht augenblicklich, sondern erst nach dem Triggern (und Optimierung des gesamten Programmplans)
  - Berechnung von nur so vielen Zwischenergebnissen wie notwendig für das Gesamtergebnis
    - Bsp.: `env.readCsvFile(…).flatMap(…).first(2).print();` liest und verarbeitet nur **zwei Zeilen** des CSV-Files (vgl. Iteratorkonzept bei Datenbanken)

Apache Flink – Unterstützte Datentypen 1/2

- Primitive Typen (z.B. `Integer`, `String`, `Double`)
- Java Tupel und Scala Case Classes
  - Zusammengesetzte Datentypen
  - `Tuple1` bis `Tuple25`, z.B. `new Tuple2<String, Integer>("hello", 1);`
- Java Plain old Java Objects (POJOs)
  - Klasse muss `public` sein mit einem `public` Konstruktor ohne Argumente (Default-Konstruktor)
  - Alle Felder entweder `public` oder durch Getter- und Setter-Methoden erreichbar
    Namensschema:
    `name` $\Rightarrow$ `setName(…)`, `getName()`
  - Unterstützung der Feld-Datentypen durch Flink
    - Zurzeit verwendet Flink Avro zur (De-)Serialisierung

```java
public class WC {
  public String word;
  private int count;
  public void setCount(int c){
    this.count = c;
  }
  public int getCount(){
    return this.count;
  }
}
```

Apache Flink – Unterstützte Datentypen 2/2

- Reguläre Klassen
  - (De-)Serialisiert durch Kryo
    - keine Unterstützung von File Pointers, I/O Streams oder andere native Ressourcen
  - Für Flink „Black Boxes“, teils kein effizienter Zugriff
- Values
  - Implementation der `Value`-Schnittstelle
    - `read(…)` und `write(…)`-Methoden zur expliziten Angabe der (De-)Serialisierung
  - Einige vordefiniert durch Flink:
    `ByteValue`, …, `StringValue`, `BooleanValue`
- Hadoop Writables
- Spezielle Typen
  - z.B. von Scala: Either, Option, Try

Apache Flink API – Schlüssel

- Angabe eines Schlüssels notwendig für
  - `join`, `coGroup`, `keyBy`, `groupBy` bei Methodenaufruf
  - `Reduce`, `GroupReduce`, `Aggregate`, `Windows`: Anwendung auf vorher (nach einem Schlüssel) gruppierten Daten
- Schlüssel nur „virtuell“,
  keine (!) Speicherung in Key-Value-Stores o.ä.
- Angabe des Schlüssels durch
  - Position: `input.keyBy(0)`, `input.keyBy(0, 1)`
  - Feldausdruck: `words.keyBy("word")`, `words.keyBy("wc.wc.word")`
  - Key Selektor-Funktion:

```
words.keyBy(new KeySelector<WC, Integer>() {
  public Integer getKey(WC wc) {
    return wc.word.length();
}});
```

```
public class WC {
  public String word;
  public WC wc;
}
```

Apache Flink API – “Type Erasure”

- Java Compiler wirft nach dem Kompilieren viele Typinformationen generischer Klassen weg
  ⇝ Type Erasure
  - Bsp.: Für die JVM nicht unterscheidbar:
    `DataStream<String>` und `DataStream<Long>`
- Aber: Flink benötigt zur Laufzeit Typinformationen (z.B. zum Deserialisieren)

Verwendung des Eclipse JDT Compiler enthalten in Eclipse Luna 4.4.2 (und höher) empfohlen, da dieser weniger Typinformationen wegwirft…

Apache Flink API – Typinferenz

- Vielfältige automatische Typinferenz durch Flink
  - `DataStream.getType()` liefert Instanz von TypeInformation zurück (Flinks Typrepräsentation)
- Manuelle Typangabe (bei Grenzen der automatischen Inferenz ⇝ Laufzeitfehler) durch
  - `.returns(…)`-Methoden
  - Extra-Parameter bei manchen Methoden (z.B. `.fromCollection(…)`)
  - Implementierung der `ResultTypeQueryable`-Schnitstelle bei Eingabeformaten und Funktionen

Apache Flink API – Spezifikation von Transformationsfunktionen

Implementation einer Schnittstelle

```
class MyMapFunction implements MapFunction<String, Integer> {
  public Integer map(String value) { return Integer.parseInt(value); }
};
data.map(new MyMapFunction());
```

+ Anonyme Klassen

```
data.map(new MapFunction<String, Integer> () {
  public Integer map(String value) { return Integer.parseInt(value); }
});
```

+ Java 8 Lambdas

```
data.filter(s -> s.startsWith("http://"));
```

Rich Functions

```
class MyMapFunction extends RichMapFunction<String, Integer> {
  public Integer map(String value) { return Integer.parseInt(value); }
};
```

- Bereitstellung zusätzlicher Methoden:
  `open`, `close`, `getRuntimeContext`, `setRuntimeContext`
- Dadurch Parametrisierung der Funktionen, Initialisierungs- und Finalisierungscode, Zugriff auf Broadcast-Variablen und Laufzeitinformationen möglich

Apache Flink API – Wichtige gemeinsame Methoden von `DataSet` und `DataStream`

map

- Bildet genau ein Element auf ein anderes ab

```
data.map(new MapFunction<String, Integer>() {
  public Integer map(String value) { return Integer.parseInt(value); }
});
```

flatMap

- Bildet ein Element auf beliebig viele (inklusive 0) Elemente ab

```
data.flatMap(new FlatMapFunction<String, String>() {
  public void flatMap(String value, Collector<String> out) {
    for (String s : value.split(" ")) { out.collect(s); }
  }
});
```

reduce

- Kombiniert eine Gruppe von Elementen in ein einzelnes durch Reduktion. `reduce` kann auf den ganzen Datensatz oder eine Gruppe angewendet werden.
- Bei **`DataStream`** wird pro verarbeitetes Element ein Zwischenergebnis weitergegeben („Rollende“ Berechnung)

```
data.reduce(new ReduceFunction<Integer> {
  public Integer reduce(Integer a, Integer b) { return a + b; }
});
```

Apache Flink API – Wichtige gemeinsame Methoden von `DataSet` und `DataStream`

aggregate

- Aggregation von vielen Elementen in ein einzelnes als vordefinierte `reduce`-Funktionen

```
DataSet<Tuple3<Integer, String, Double>> output = input.aggregate(SUM, 0).and(MIN, 2);
```

- Short-Hand Syntax:

```
DataSet<Tuple3<Integer, String, Double>> output = input.sum(0).andMin(2);
```

filter

- Evaluiert eine *Wahrheitsfunktion* und behält nur die Elemente, für die die Wahrheitsfunktion *wahr* ist

```
data.filter(new FilterFunction<Integer>() {
  public boolean filter(Integer value) { return value > 1000; }
});
```

distinct

- Nur **DataSet**: Eliminierung von Duplikaten

```
data.distinct();
```

project

- Bei Verarbeitung von Tupeln (**Tuple1** bis **Tuple25**) zusätzlich: Projizieren auf eine Teilmenge der Felder

```
DataSet<Tuple2<String, Integer>> out = in.project(2,0);
```

Apache Flink API – Wichtige gemeinsame Methoden von `DataSet` und `DataStream`

union

- Vereinigung zweier `DataSets`/`DataStreams`

```
DataSet<String> result = data1.union(data2);
```

join

- Kombiniert zwei Datensätze bei Gleichheit zweier Felder

```
result = input1.join(input2)
               .where(0)       // key of the first input (tuple field 0)
               .equalTo(1);    // key of the second input (tuple field 1)
```

- Bei **`DataSteam`** Join nur über die Daten eines Fensters (hier Daten der letzten 3 Sekunden (nicht überlappend)):

```
dataStream.join(otherStream)
    .where(<key selector>).equalTo(<key selector>)
    .window(TumblingEventTimeWindows.of(Time.seconds(3)))
    .apply (new JoinFunction () {...});
```

- Optional:
  Explizite Angabe einer **`JoinFunction`** zur Berechnung des Joinergebnisses (z.B. Vereinigung der Felder)

Apache Flink API – Nur `DataStream`

window

- Fenster zerteilen den Strom in endlich große Ausschnitte, über die Berechnungen durchgeführt werden können
  - „Keyed Windows“: Zerteilen & parallele Ausführung anhand eines Schlüssels

```
stream.keyBy(...)               // split according to key
      .window(...)              // define the window
      .reduce/fold/apply(...) // determine window-result in parallel
```

  - „Non-keyed Windows“: Nur 1 Fenster (in einem Task berechnet)

```
stream
      .windowAll(...)           // define the window
      .reduce/fold/apply(...) // determine window-result in one task
```

Apache Flink API – Window Assigners (Nur `DataStream`)

- Tumbling Windows
  - Verarbeitung nicht überlappender Ausschnitte der Daten aus Zeitintervallen gleicher Größe

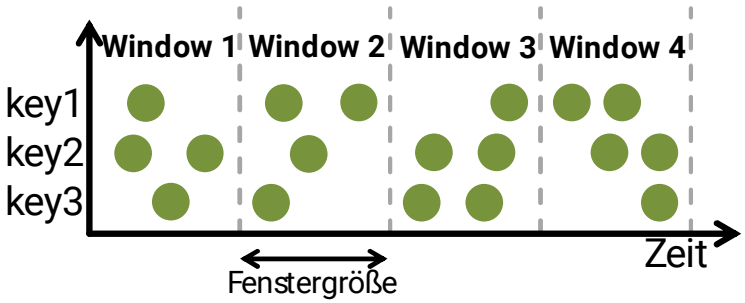

- Sliding Windows
  - Verarbeitung gleitender und überlappender Ausschnitte der Daten aus Zeitintervallen gleicher Größe

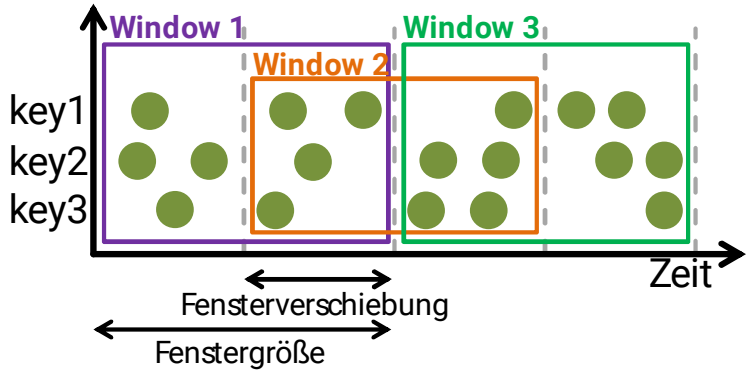

- Flink unterstützt weitere Arten von Windows

„Think like a vertex!“ (Pregel[1]-ähnliche Systeme)

- Algorithmus
  „aus Sicht eines Knotens“
  - Eigener Knotenwert kann verändert werden
  - Nachrichten können an andere (beliebige) Knoten (mit bekannter ID) versendet und empfangen werden

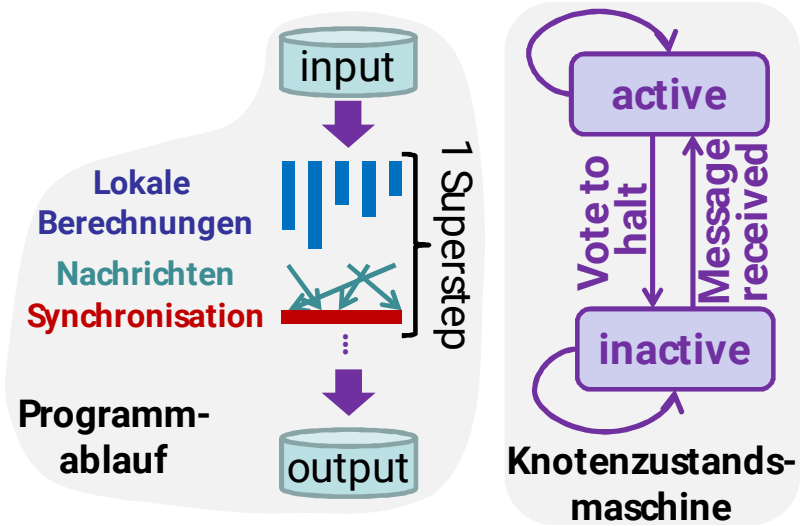

- Wiederholung bis keine Änderungen/Nachrichten oder maximale Iterationsanzahl erreicht
- Motivation
  - Alle Programme dieses Programmiermodells sind hoch parallelisierbar (⇝ Verteilung der Knotenberechnungen)

[1] G. Malewicz et al.: **Pregel: a system for large-scale graph processing**. In SIGMOD, 2010.

Apache Flink/Gelly

- Unterstützung mehrerer Programmiermodelle für Graphberechnungen
  - Am Allgemeinsten: **Knotenzentrisch (Pregel)**
  - aber Ausführung anderer (eingeschränkter) Programmiermodelle (Scatter-Gather/Gather-Sum-Apply) evtl. performanter
    - Einschränkungen z.B.
      - Nachrichten können nur zu Nachbarn versendet werden
      - Trennung der Knotenwertaktualisierung vom Nachrichtenversand

Single-Source-Shortest-Path
als Pregel-Programm

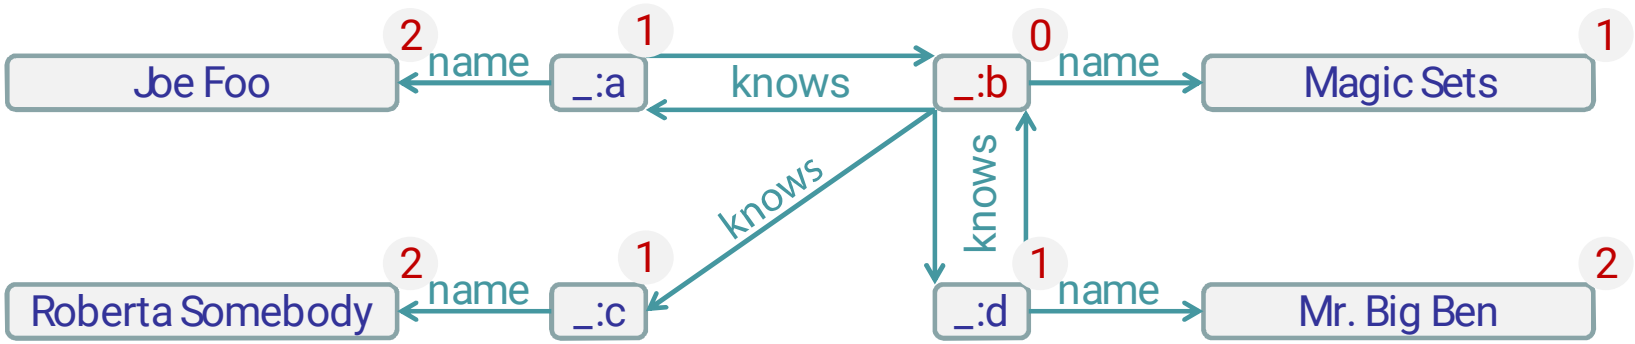

Zum Weiterlesen…

- Apache Spark
  - Projektwebseite
- Apache Flink
  - Projektwebseite
  - Apache Flink basiert auf Stratosphere: Alexandrov et al., **The Stratosphere platform for big data analytics**. The VLDB Journal 23 (6), 2014. DOI: 10.1007/s00778-014-0357-y

Zusammenfassung

- Apache Spark/Flink als 3./4. Generation von Cloud Computing-Frameworks
  - Umfangreiche APIs, z.B.
    - Batch-Verarbeitung
    - Stromverarbeitung
    - SQL
    - Graphdatenbanken
      - Berechnungsmodell nach Pregel
- Apache Flink zurzeit teilweise bessere Backendtechnologien