Processamento paralelo é distribuído com Big Data

Dr. Kleber Vieira

UNIVERSIDADE FEDERAL
DE SANTA CATARINA

Big Data

O que é Big Data?

Porque precisamos de novas técnicas ?

Big Data

5 características do Big Data segundo Khan, Uddin e Gupta (2014).

- Volume
- Variedade
- Velocidade
- Veracidade
- Valor

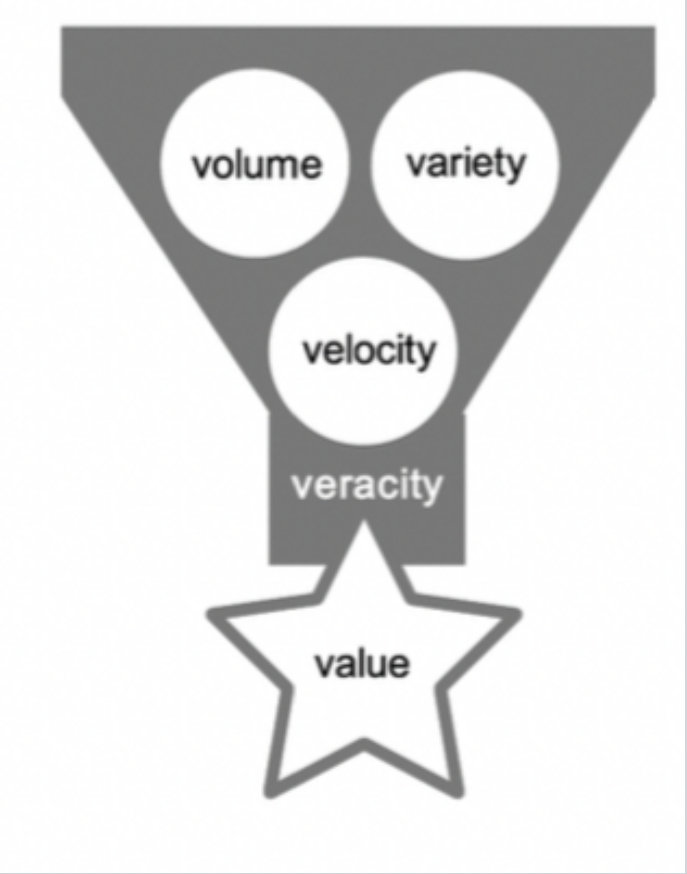

Big Data

Porque precisamos de novas técnicas ?

Complexidade computacional.

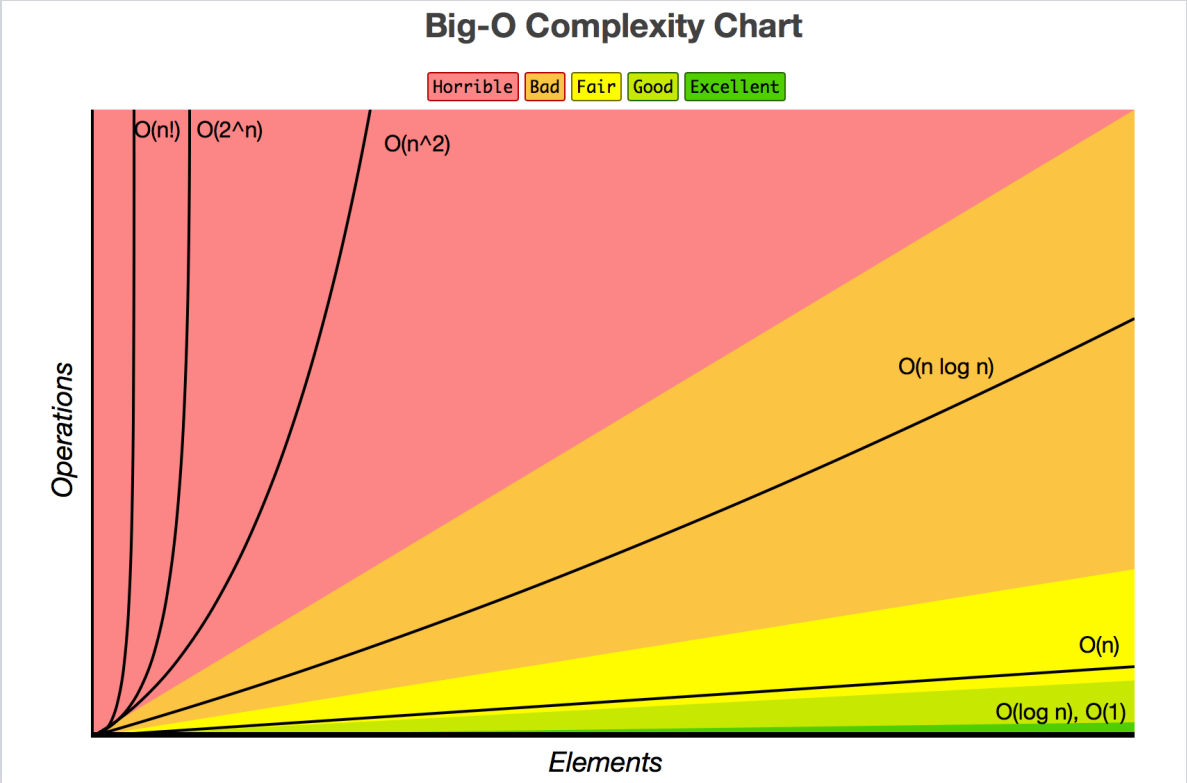

Problemas com Big Data

Exemplo:

- IoT na agricultura;
  - Cada maquina gera 25 registros de sensores por segundo;
  - Ligada 12 horas por dias envia 43.200 vezes 25 1.080.000
  - Mil Dispositivos gera mais de 1 bilhão de registros.

Problemas com Big Data

Exemplo:

- Para cada segundo é enviada a coordenada GPS, dados de coleta, insumos, velocidade, operação executava etc…

Problemas com Big Data

Exemplo:

- Ao receber os dados o é necessário:
- Verificar em qual talhão

Problemas com Big Data

Exemplo:

- Ao receber os dados o é necessário:
- Verificar em qual talhão foi trabalhado.
- Quais atividades foram realizada.
- Consolidar os identificados dos registros enviados com os dados do banco.

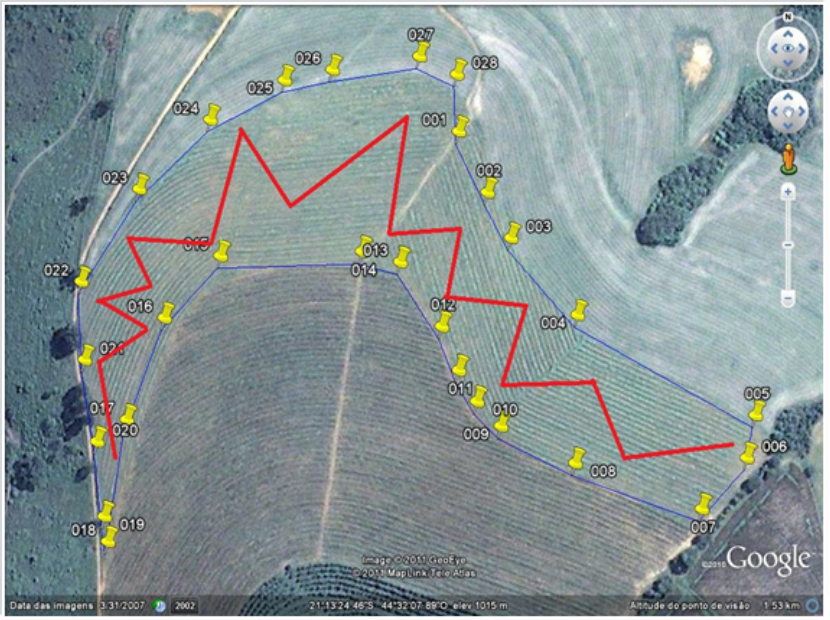

Problemas com Big Data

Exemplo:

- Reduzir os dados para que consultas extração de dados sejam geradas rapidamente.

- Se em 1 minuto não houve mudança de atividade agrupa os 60 registros em apenas 1.

Como organizar o código para tratar todo esse processamento ?

Design Pattern:

Flyweight

https://github.com/iluwatar/java-design-patterns/tree/master/flyweight/src/main/java/com/iluwatar/flyweight

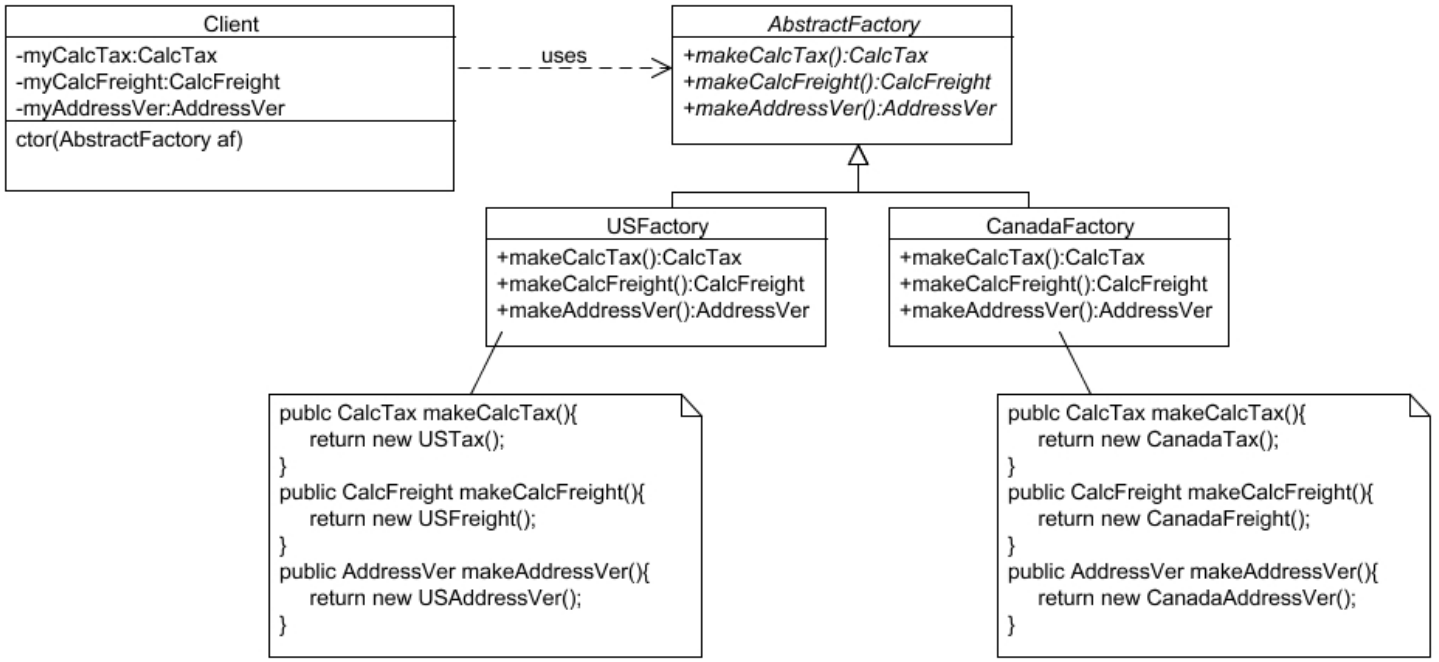

Map Reduce

- Mapear os dados em estrutura de dados;
- Reduzir;

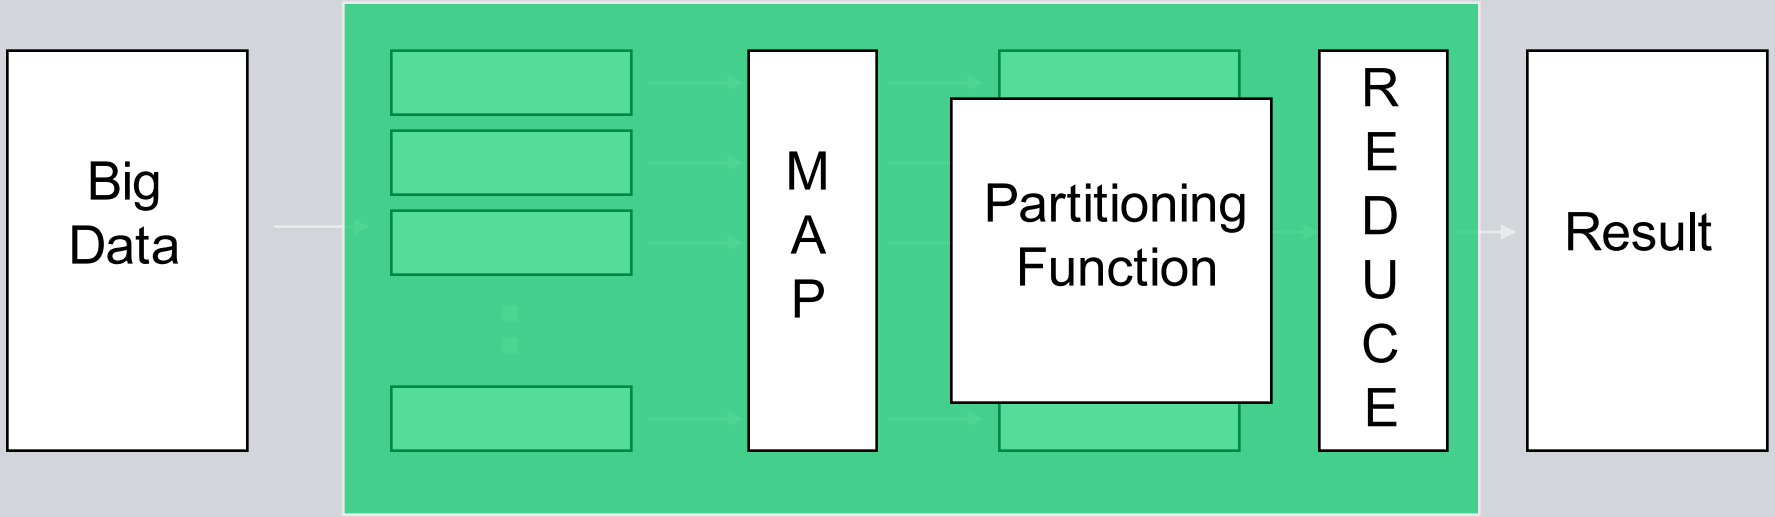

Ferramenta Hadoop

Google desenvolveu o Hadoop;

Framework para realizar o processamento Big Data em ambientes distribuídos.

Ferramenta Hadoop

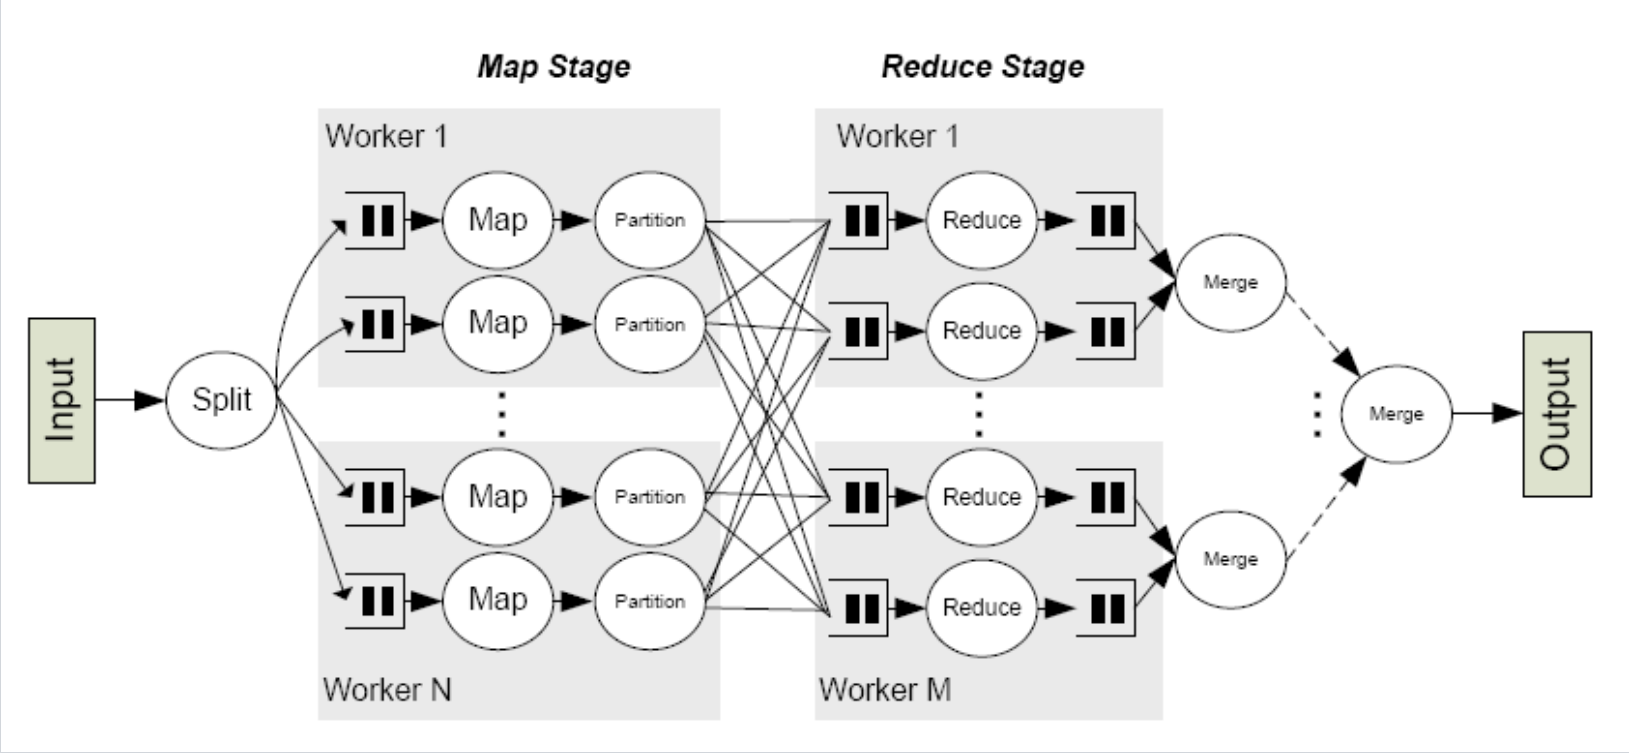

Ferramenta Hadoop

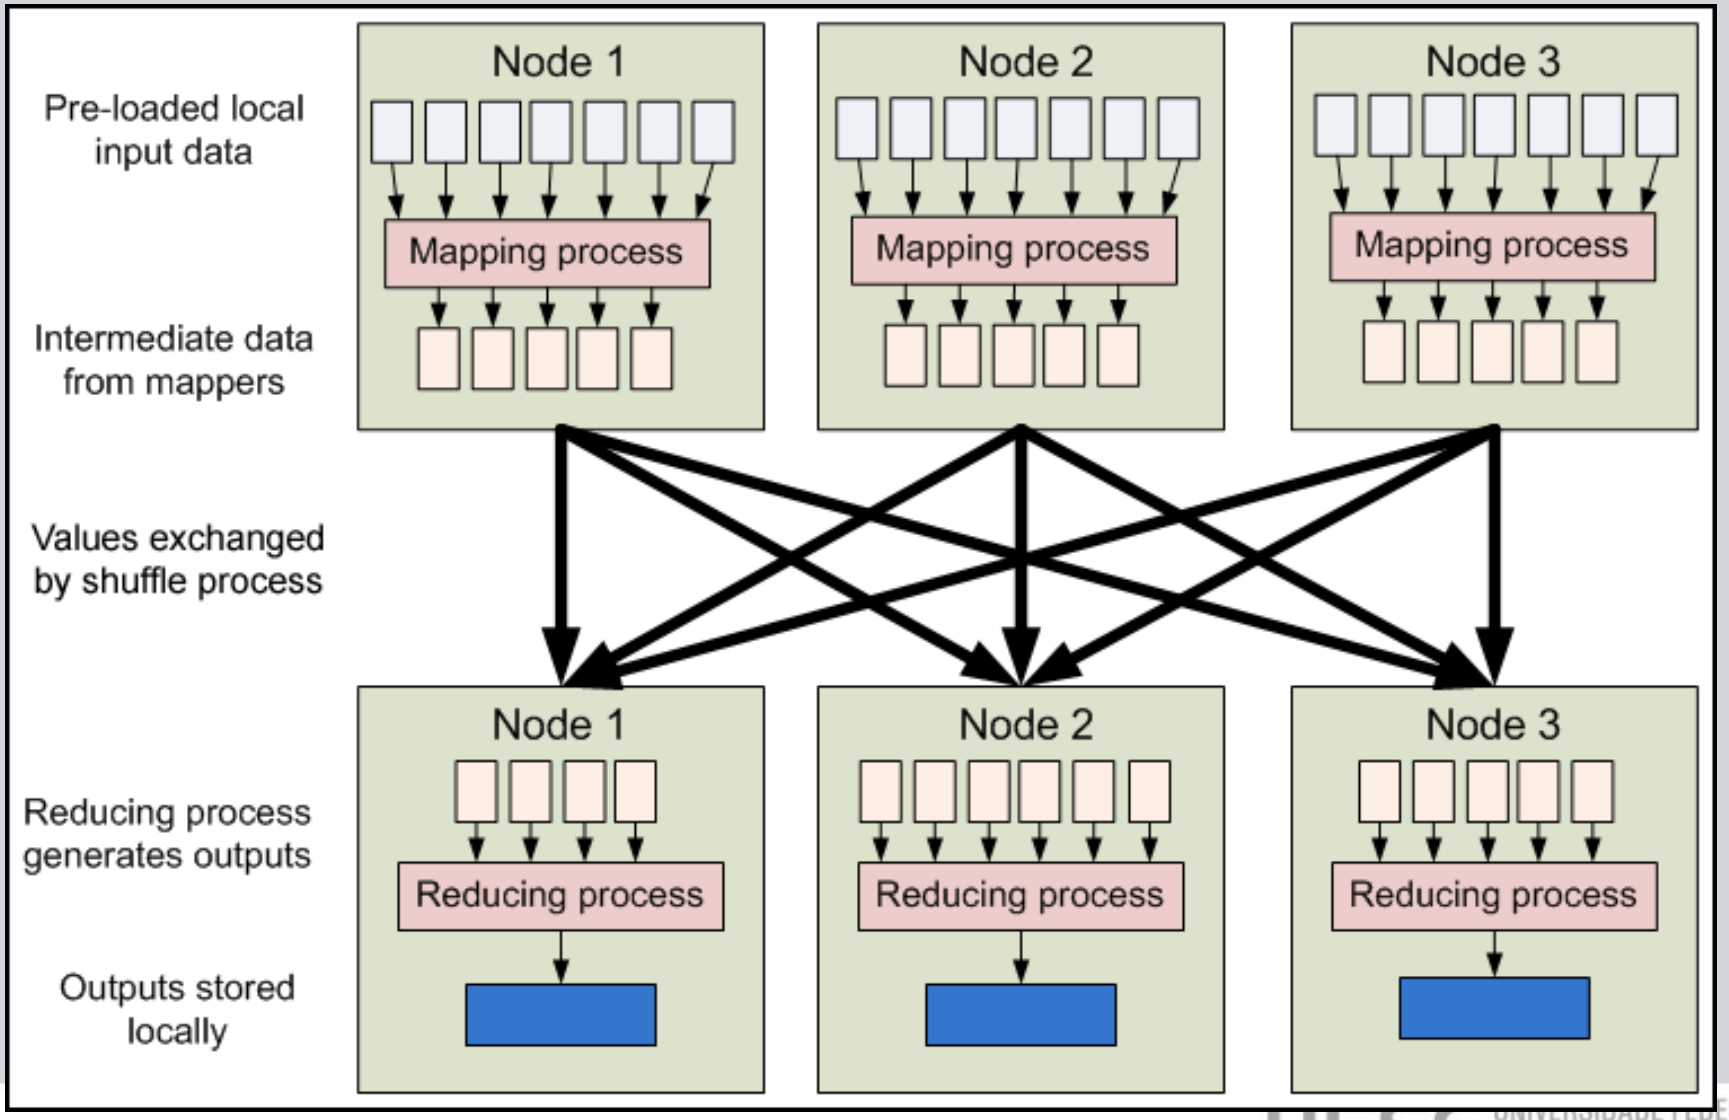

Ferramenta Hadoop

Como usar ?

Instalar o Hadoop:

http://hadoop.apache.org/releases.html

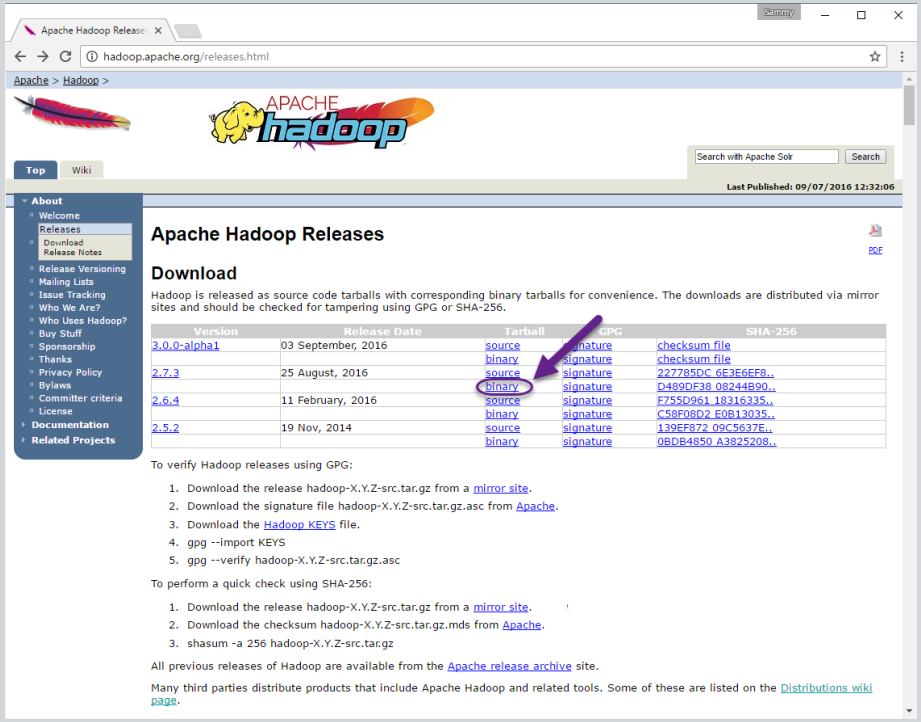

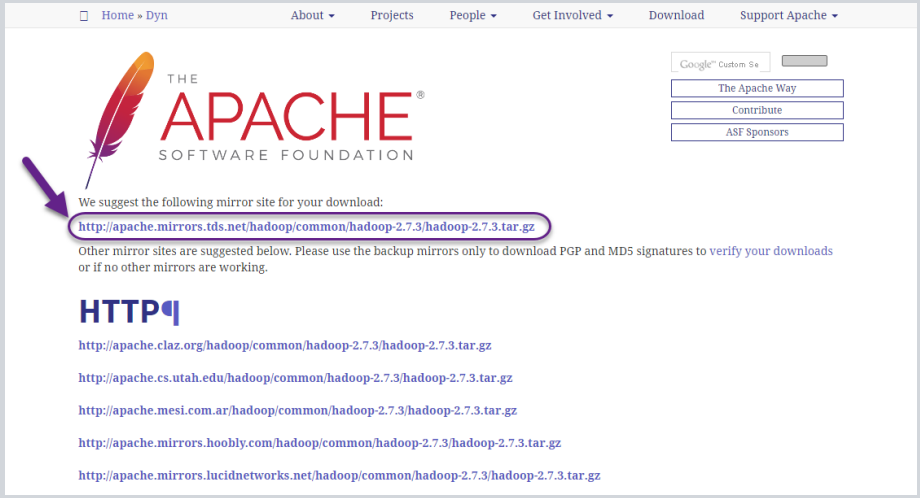

Ferramenta Hadoop

Como usar ?

Instalar o Hadoop:

http://hadoop.apache.org/releases.html

```
wget http://apache.mirrors.tds.net/hadoop/common/hadoop-2.7.4/
hadoop-2.7.4.tar.gz

tar -xzvf hadoop-2.7.4.tar.gz

sudo mv hadoop-2.7.4 /usr/local/hadoop

readlink -f /usr/bin/java | sed “s:bin/java::”

sudo nano /usr/local/hadoop/etc/hadoop/hadoop-env.sh
#export JAVA_HOME=${JAVA_HOME}
export JAVA_HOME=/usr/lib/jvm/java-8-openjdk-amd64/jre/
```

Ferramenta Hadoop

Como usar ?

Instalar o Hadoop:

http://hadoop.apache.org/releases.html

```
/usr/local/hadoop/bin/hadoop

mkdir ~/input

/usr/local/hadoop/bin/hadoop jar /usr/local/hadoop/share/hadoop/
mapreduce/hadoop-mapreduce-examples-2.7.3.jar grep ~/input ~/grep_example
'principal[.]*'
```

Ferramenta Hadoop

Projeto:

https://goo.gl/TNnQMv

Ferramenta Hadoop

Projeto:

https://goo.gl/TNnQMv

Atividade:
Mudar o código para contar apenas uma coleção específica de palavras.

Ferramenta Hadoop

Projeto:

ht

```
public static void main(String[] args) throws Exception {
    Configuration conf = new Configuration();

    Job job = new Job(conf, "wordcount");
    job.setJarByClass(WordCount.class);

    job.setOutputKeyClass(Text.class);
    job.setOutputValueClass(IntWritable.class);

    job.setMapperClass(Map.class);
    job.setReducerClass(Reduce.class);

    job.setInputFormatClass(TextInputFormat.class);
    job.setOutputFormatClass(TextOutputFormat.class);

    FileInputFormat.addInputPath(job, new Path(args[0]));
    FileOutputFormat.setOutputPath(job, new Path(args[1]));

    job.waitForCompletion(true);
}
```

Ferramenta Hadoop

Projeto:

```
public static class Map extends
        Mapper<LongWritable, Text, Text, IntWritable> {
    private final static IntWritable one = new IntWritable(1);
    private Text word = new Text();

    public void map(LongWritable key, Text value, Context context)
            throws IOException, InterruptedException {
        String line = value.toString();
        StringTokenizer tokenizer = new StringTokenizer(line);
        while (tokenizer.hasMoreTokens()) {
            word.set(tokenizer.nextToken());
            context.write(word, one);
        }
    }
}
```

Ferramenta Hadoop

Projeto:

```
public static class Reduce extends
        Reducer<Text, IntWritable, Text, IntWritable> {

    public void reduce(Text key, Iterable<IntWritable> values,
            Context context) throws IOException, InterruptedException {
        int sum = 0;
        for (IntWritable val : values) {
            sum += val.get();
        }
        context.write(key, new IntWritable(sum));
    }
}
```

AWS

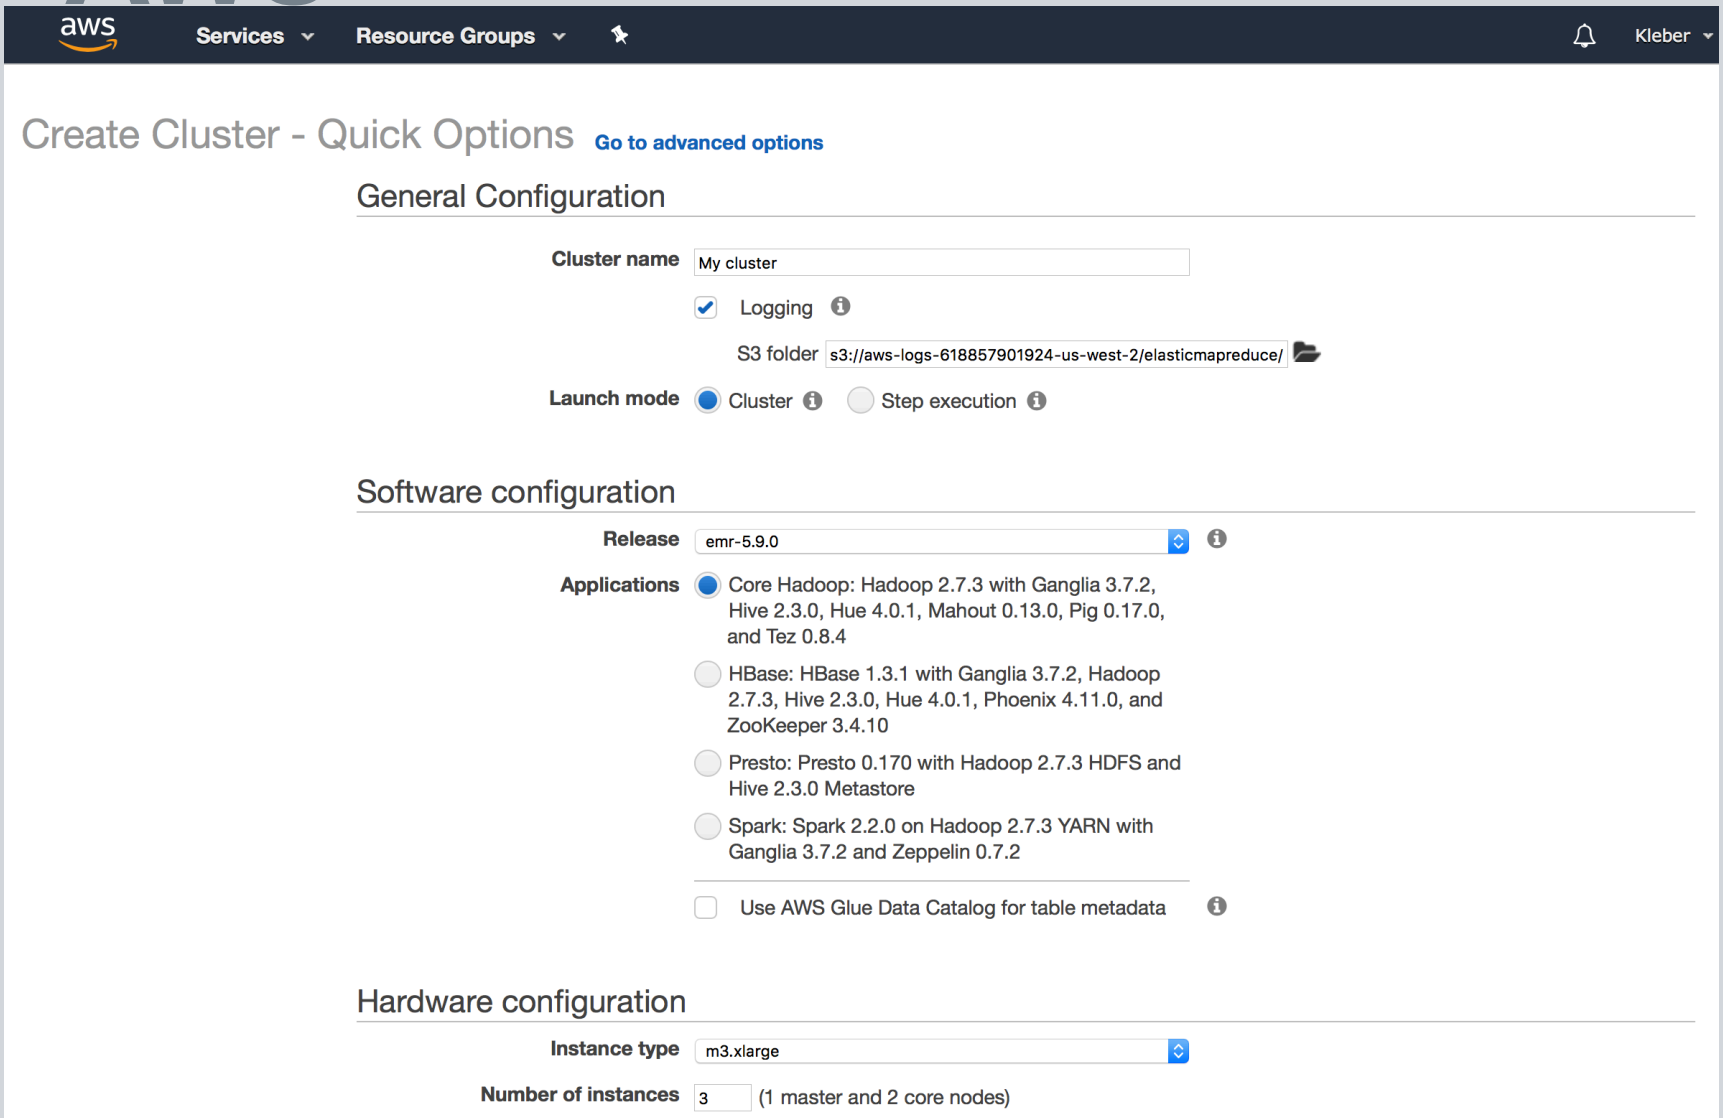
aws
Services
Resource Groups
Kleber
Create Cluster - Quick Options
Go to advanced options
General Configuration
Cluster name
My cluster
Logging
S3 folder
s3://aws-logs-618857901924-us-west-2/elasticmapreduce/
Launch mode
Cluster
Step execution
Software configuration
Release
emr-5.9.0
Applications
Core Hadoop: Hadoop 2.7.3 with Ganglia 3.7.2, Hive 2.3.0, Hue 4.0.1, Mahout 0.13.0, Pig 0.17.0, and Tez 0.8.4
HBase: HBase 1.3.1 with Ganglia 3.7.2, Hadoop 2.7.3, Hive 2.3.0, Hue 4.0.1, Phoenix 4.11.0, and ZooKeeper 3.4.10
Presto: Presto 0.170 with Hadoop 2.7.3 HDFS and Hive 2.3.0 Metastore
Spark: Spark 2.2.0 on Hadoop 2.7.3 YARN with Ganglia 3.7.2 and Zeppelin 0.7.2
Use AWS Glue Data Catalog for table metadata
Hardware configuration
Instance type
m3.xlarge
Number of instances
3
(1 master and 2 core nodes)

Contato

E-mail: klebermagno@gmail.com

UNIVERSIDADE FEDERAL
DE SANTA CATARINA