NÁSKOK
DÍKY
ZNALOSTEM

PROFINIT

A4M33BDT
Technologie pro velká data

Milan Kratochvíl

22. března 2017

MapReduce

PROFINIT

MapReduce

- Paradigma/framework/programovací model pro distribuované paralelní výpočty
- Princip:
  - MAP
    - vstupní data ve formátu <KEY1, VALUE1> konvertuje na <KEY2,VALUE2>
  - REDUCE
    - vstupní data ve formátu <KEY2, LIST(VALUE2)> konvertuje na <KEY3, VALUE3>

- `<K1,V1>` ➔ `<K2,V2>` ➔ `<K2,LIST(V2)>` ➔ `<K3,V3>`

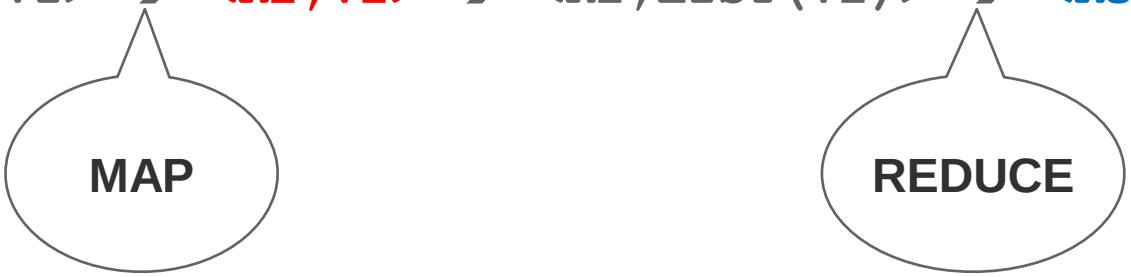

PROFINIT

MapReduce – příklad: Počet slov podle délky

MAP

SHUFFLE & SORT

REDUCE

Ó, náhlý déšť již zvířil prach a čilá laň teď běží s houfcem gazel k úkrytům.

1: ó
5: náhlý
4: déšť
1: a
...

1: LIST(ó, a, s, k)
3: LIST(již, laň, teď)
4: LIST(déšť, čilá, běží)
5: LIST(náhlý, prach, gazel)
...

1: 4
3: 3
4: 3
5: 3
6: 1
7: 2

PROFINIT

MapReduce podrobně

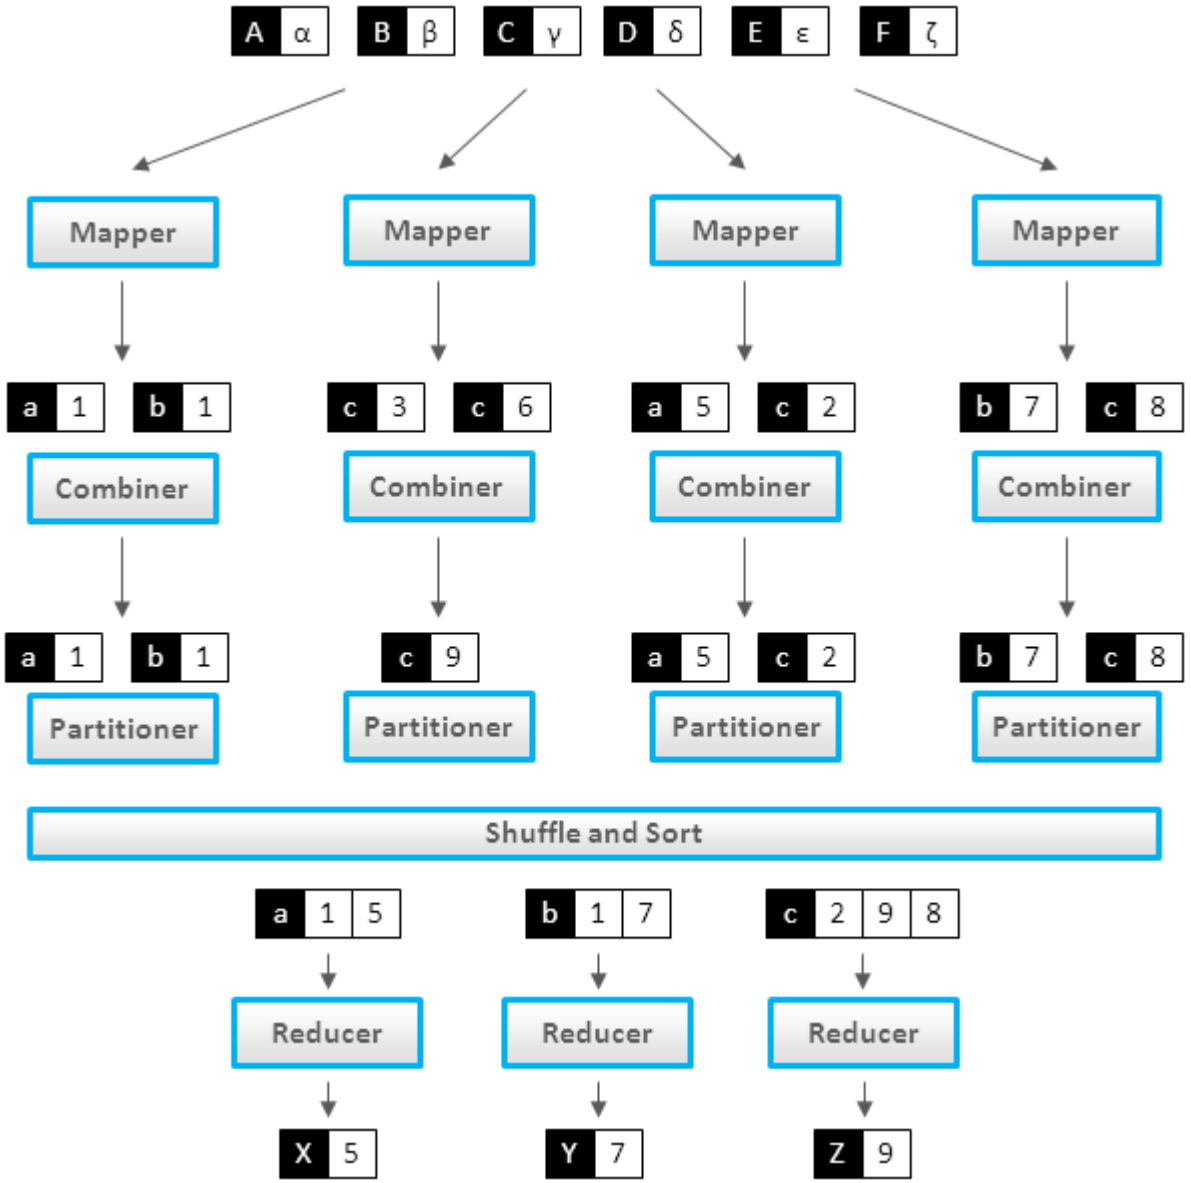

https://highlyscalable.wordpress.com/2012/02/01/mapreduce-patterns/

PROFINIT

Příprava

- Definice zdrojových dat
- **Split**
  - Pokud je soubor větší než 1 HDFS blok, splitne se na menší
- Podle rozmístění jednotlivých bloků naplánuje YARN optimálně, které nody spustí které joby
  - Snaha o maximální lokálnost
  - Snaha o eliminaci „zbytečných“ transferů přes síť
  - To všechno usnadňuje replikace dat v HDFS
- Pokud to ale povaha problému neumožňuje, lze zakázat splittování – pak každý mapper zpracuje celý soubor.

Mapper

<K1,V1> ➔ <K2,V2>

- Vstupní údaje **mapuje** na hodnoty typu klíč – hodnota
- Vstupem je formálně také klíč – hodnota
  - Ale často nás klíč vůbec nezajímá! Je to třeba offset souboru
- Klíč se může libovolně opakovat, hodnota může být různá
- Data jsou na konci setříděna podle klíče (zpravidla, ne vždy)
- Typicky probíhá v mnoha paralelních jobech
  - Každý soubor, resp. split je zpracován samostatným mapperem
- **Výstup se zapisuje na lokální disk**

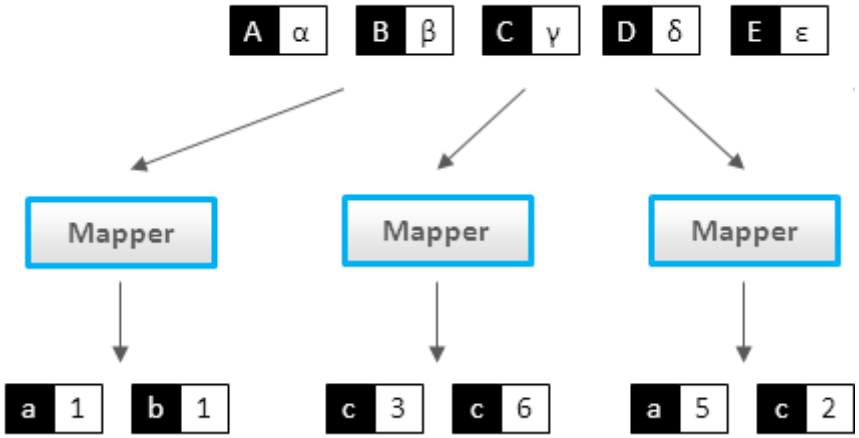

Ó, náhlý déšť již zvířil prach a čilá laň teď běží s houfcem gazel k úkrytům.

1: ó
1: a
1: k
1: s
3: laň
3: teď
3: již
4: déšť
5: běží
...

PROFINIT

Shuffle & Sort

<K2,V2> ➔ <K2,LIST(V2)>

- Probíhá během/po skončení mapperů
- Vstupem jsou **vygenerované soubory z mapperů**
- Všechna data se **stejným klíčem slije na jeden node**
  - Tj. musí data načíst z jednotlivých nodů (disková operace)
  - Ale čte je jen z lokálních disků, nikoli z HDFS
  - A pak musí data přenést (síť)
- Setřídí data podle klíče (merge)
- Optimalizace – malá data pošle rovnou do reduceru, velká merguje na lokálním disku
- Typicky nejnáročnější operace

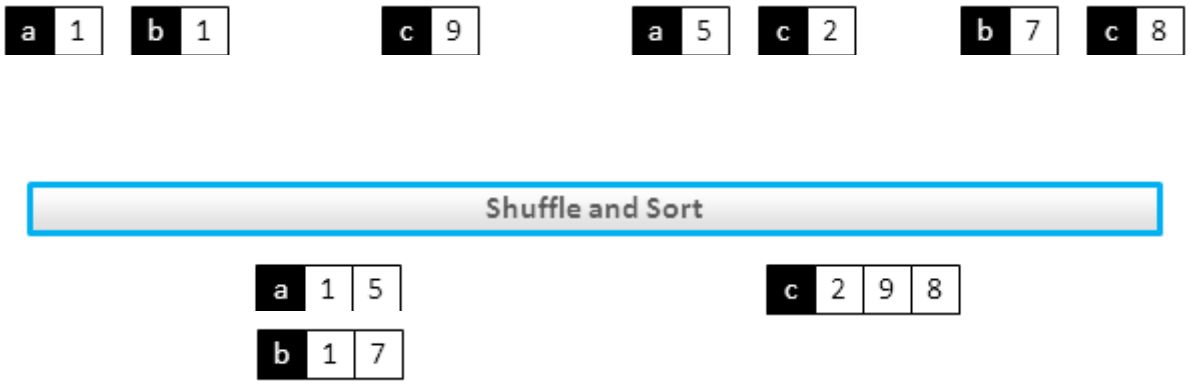

PROFINIT

Reduce

`<K2,LIST(V2)>` ➔ `<K3,V3>`

- Čte produkovaná pomocí Shuffle & Sort
- „Redukuje“ list hodnot čtených z výstupy Shuffle & Sort
- Zpravidla je reducerů (řádově) méně než mapperů
- Počet lze definovat, default je 1
- Každý reducer generuje 1 soubor do HDFS
- Výstup se nijak nesortuje

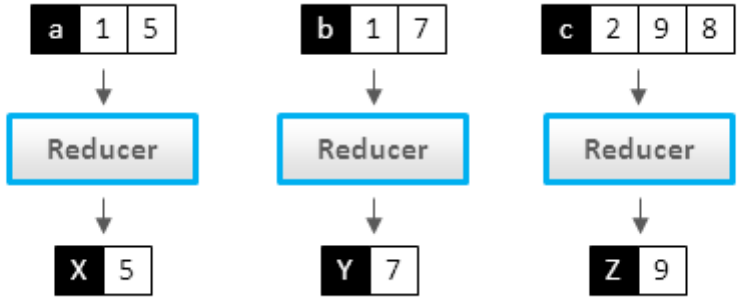

PROFINIT

Combiner

`<K2,LIST(V2)>` ➔ `<K3,V3>`

- Volitelná část zpracování mapperu
- Provádí reduce na straně mapperu
- Stejné rozhraní jako Reducer
- Proč použít combiner
  - data jsou načtena v paměti, ušetří se IO operace – čtení
  - často je výstup menší než vstup, ušetří se IO operace – zápis (a následné čtení)
- Nemá zpravidla smysl, pokud combiner generuje více dat než je jejich vstup
- Často lze použít stejný kód jako pro reducer!
  - Anebo si lze napsat úplně vlastní

PROFINIT

Partitioner

- Partitioner rozděluje data do několika partitions
  - podle klíče
  - podle hodnoty
- MapReduce zajišťuje, že jedna partition je zpracována jedním reducerem
- Defaultně – počítá se `hash klíče` **`modulo`** `počet reducerů`
  - to pro většinu případů znamená velmi rovnoměrné rozdělení do jednotlivých partitions
- Vlastní partitioner lze použít např. v případech, kdy
  - chci znát nějaké specifické rozdělení (např. věkové kategorie)
  - mám velmi nevyvážené klíče (jeden klíč se vyskytuje abnormálně často) – problém celebrit

MapReduce podrobně

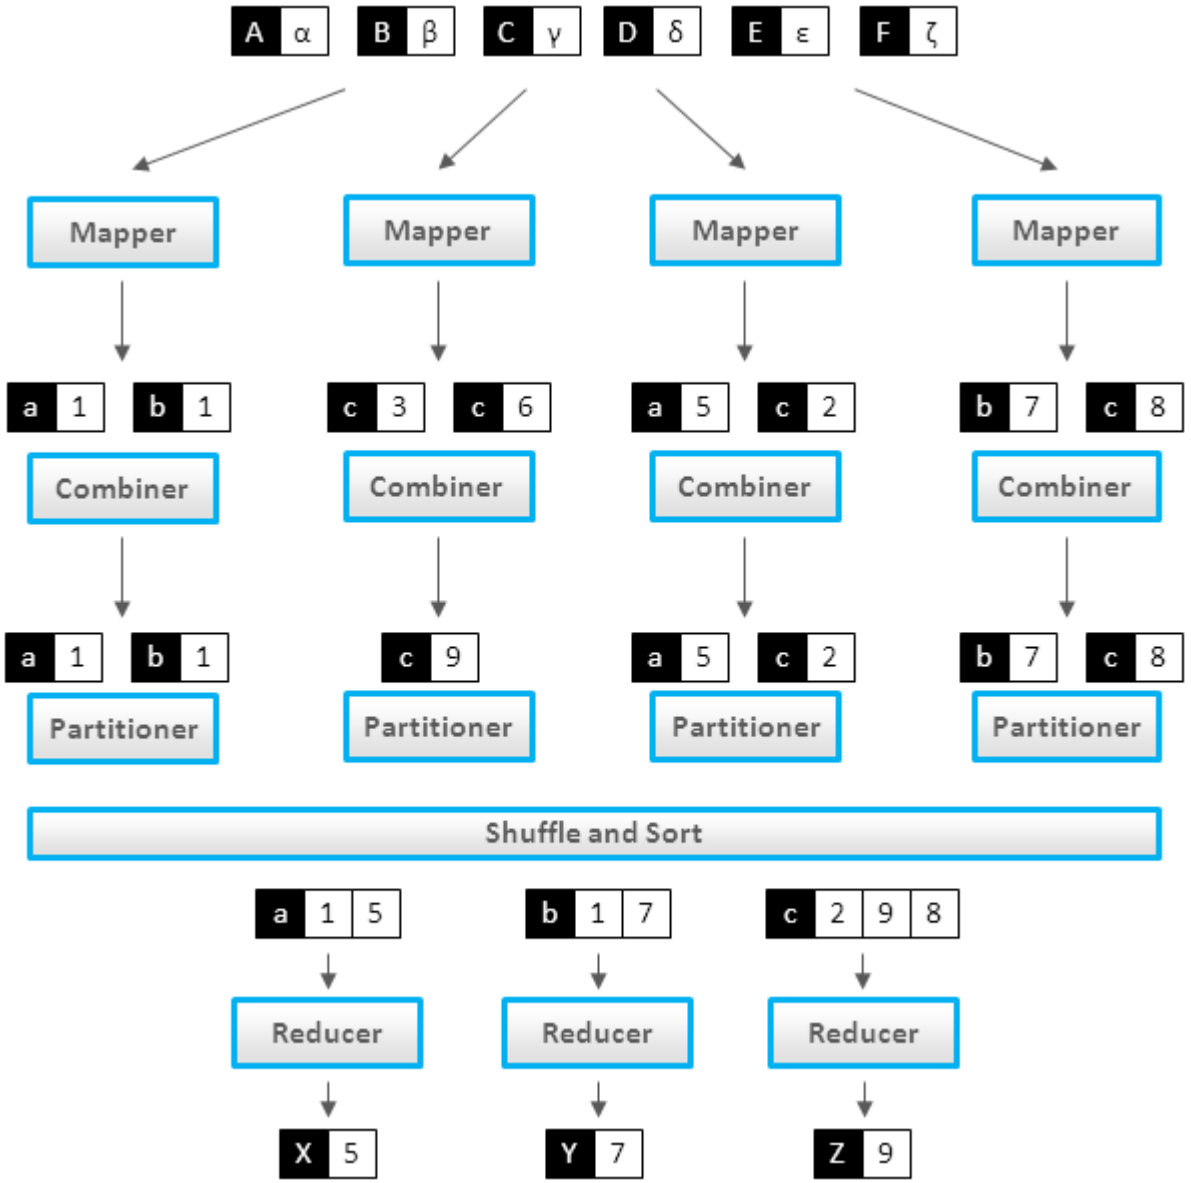

https://highlyscalable.wordpress.com/2012/02/01/mapreduce-patterns/

PROFINIT

Třída úloh, které lze MapReduce zpracovat

- Metoda „Rozděl a panuj“

- **Formální požadavky**
- Každá MapReduce operace ▲ musí splňovat
  a) asociativitu, tj. (A ▲ B) ▲ C = A ▲ (B ▲ C)
  b) existenci neutrálního prvku ◊, tj. A ▲ ◊ = A
  c) komutativita, tj. (A ▲ B) = (B ▲ A) [přísně vzato není povinná]

- Proč
  a) neovlivníme pořadí vykonávaných operací
  b) node, který nemá výstup/nezpracovává data, neovlivní výsledek
  c) mapper/shuffle může změnit pořadí dat
     komutativita umožňuje použít combiner

Příklady – vhodné úlohy

- „Školní úlohy“
  - počet slov v textu
  - četnost slov
- Praktičtější úlohy
  - reporting – načítání řady dílčích výsledků (prodeje)
    - podle klienta
    - produktu
    - lokality
  - řazení dat (sortování)
  - výpis pořadí např. prodávaných výrobků podle prodaných kusů
  - filtrování dat
  - validace
  - hledání „distinktních“ hodnot (SELECT DISTINCT a FROM t)
  - extrakce snímků z videa

PROFINIT

Příklady – nevhodné úlohy

- Medián
  - nesplňuje asociativitu
- Průměr
  - nesplňuje asociativitu
- Násobení matic
  - nesplňuje komutativitu

- ALE: **Úlohy lze vhodně přeformulovat!**

Průměr

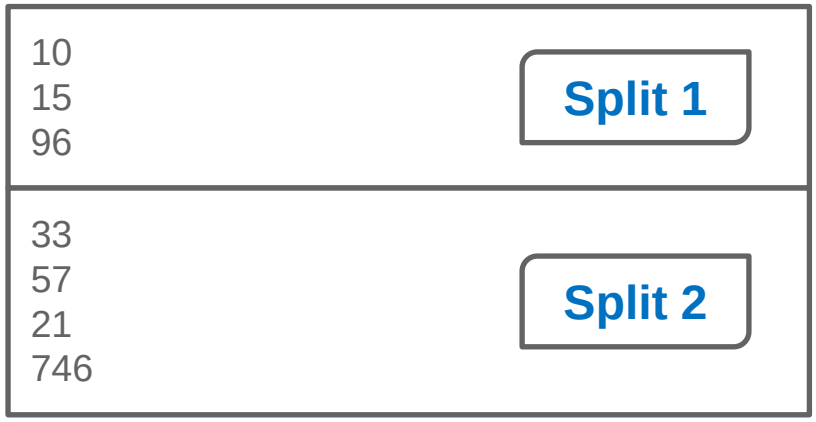

- Combiner
  - spočítat průměr
- Výstup mapperu
  - SPLIT1:40.3333
  - SPLIT2:214.25
- Výstup reduceru
  - AVG:234.4166666666

- Combiner
  - spočítat průměr **a počet**
- Výstup mapperu
  - SPLIT1:40.3333:3
  - SPLIT2:214.25:4
- Výstup reduceru
  - AVG:139.714

PROFINIT

Java API

Java API – příklad

- Zajímá nás četnost výskytu jednotlivých slov v textu

Java API - Mapper

```java
package eu.profinit.hadoop;

import java.io.IOException;

import org.apache.hadoop.io.LongWritable;
import org.apache.hadoop.io.Text;
import org.apache.hadoop.mapreduce.Mapper;
import org.apache.hadoop.mapreduce.lib.input.FileSplit;

public class MRMapper extends Mapper < LongWritable, Text, Text, LongWritable > {

    @Override
    protected void map(LongWritable key, Text value,
        Mapper < LongWritable, Text, Text, LongWritable > .Context context)
    throws IOException,
    InterruptedException {

        String[] words = value.toString().split("[\\.,;!?\\)\\(\\s]");

        for (String word: words) {
            if (word.length() > 4) {
                context.write(new Text(word.toUpperCase()), new LongWritable(1));
            }
        }

    }

}
```

PROFINIT

Java API – Reducer

```java
package eu.profinit.hadoop;

import java.io.IOException;

import org.apache.hadoop.io.LongWritable;
import org.apache.hadoop.io.Text;
import org.apache.hadoop.mapreduce.Reducer;

public class MRReducer extends Reducer < Text, LongWritable, Text, LongWritable > {

    @Override
    protected void reduce(Text key, Iterable < LongWritable > values,
        Reducer < Text, LongWritable, Text, LongWritable > .Context context)
    throws IOException,
    InterruptedException {

        long sum = 0;

        for (LongWritable count: values) {
            sum += count.get();
        }

        context.write(key, new LongWritable(sum));
    }

}
```

PROFINIT

Java API – Driver

```java
package eu.profinit.hadoop;

import org.apache.hadoop.conf.Configuration;
import org.apache.hadoop.fs.Path;
import org.apache.hadoop.io.LongWritable;
import org.apache.hadoop.io.Text;
import org.apache.hadoop.mapreduce.Job;
import org.apache.hadoop.mapreduce.lib.input.FileInputFormat;
import org.apache.hadoop.mapreduce.lib.output.FileOutputFormat;

public class MRDriver {

    public static void main(String[] args) throws Exception {

        Configuration conf = new Configuration();
        conf.set("mapreduce.output.textoutputformat.separator", ";");

        Job job = Job.getInstance(conf);

        job.setJarByClass(MRDriver.class);

        job.setJobName("CetnostSlov");
        job.setMapperClass(MRMapper.class);
        job.setReducerClass(MRReducer.class);
        job.setOutputKeyClass(Text.class);
        job.setOutputValueClass(LongWritable.class);
        job.setMapOutputKeyClass(Text.class);
        job.setMapOutputValueClass(LongWritable.class);

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

        job.setNumReduceTasks(4);

        boolean success = job.waitForCompletion(true);

        System.exit(success ? 0 : 1);
    }
}
```

PROFINIT

Java API – Combiner

- Lze provést optimalizaci velmi snadným způsobem:
  - job.setCombinerClass(MRReducer.class);
- Combiner je použit stejný jako Reducer!
  - Ale pozor, toto neplatí vždy!
- Výrazně se omezí množství přenášených dat

Java API – další možnosti

- Map a Reduce probíhají záznam po záznamu
- Je možné také spustit kód při inicializaci a ukončení celého procesu
- Podobné pro Mapper i Reducer
- `setup()`
  - spustí se jedenkrát při inicializaci jobu
  - typicky si zde načtu data z cache
- `cleanup()`
  - typicky uvolnění externích zdrojů (zavření souborů atd.)

PROFINIT

Jak pustit MapReduce program?

1. Zkompilovat zdrojové kódy do JAR
2. Spustit příkaz

```
hadoop jar wc.jar eu.profinit.hadoop.MRDriver /data/capek /data/vystup
```

3. Výstup

```
17/03/21 14:50:46 INFO mapred.LocalJobRunner: Starting task:
attempt_local699809073_0001_m_000003_0
17/03/21 14:50:46 INFO output.FileOutputCommitter: File Output Committer Algorithm version is 1
17/03/21 14:50:46 INFO mapred.Task:  Using ResourceCalculatorProcessTree : [ ]
17/03/21 14:50:46 INFO mapred.MapTask: Processing split: hdfs://localhost/data/capek/Karel_Capek-
-Povidky_z_druhe_kapsy.txt:0+274512
17/03/21 14:50:46 INFO mapred.MapTask: (EQUATOR) 0 kvi 26214396(104857584)
17/03/21 14:50:46 INFO mapred.MapTask: mapreduce.task.io.sort.mb: 100
17/03/21 14:50:46 INFO mapred.MapTask: soft limit at 83886080
17/03/21 14:50:46 INFO mapred.MapTask: bufstart = 0; bufvoid = 104857600
17/03/21 14:50:46 INFO mapred.MapTask: kvstart = 26214396; length = 6553600
17/03/21 14:50:46 INFO mapred.MapTask: Map output collector class =
org.apache.hadoop.mapred.MapTask$MapOutputBuffer
17/03/21 14:50:46 INFO mapred.LocalJobRunner:
17/03/21 14:50:46 INFO mapred.MapTask: Starting flush of map output
17/03/21 14:50:46 INFO mapred.MapTask: Spilling map output
17/03/21 14:50:46 INFO mapred.MapTask: bufstart = 0; bufend = 327529; bufvoid = 104857600
17/03/21 14:50:46 INFO mapred.MapTask: kvstart = 26214396(104857584); kvend =
26135552(104542208); length = 78845/6553600
17/03/21 14:50:46 INFO mapreduce.Job:  map 30% reduce 0%
17/03/21 14:50:46 INFO mapred.MapTask: Finished spill 0
17/03/21 14:50:46 INFO mapred.Task: Task:attempt_local699809073_0001_m_000003_0 is done. And is
in the process of committing
17/03/21 14:50:46 INFO mapred.LocalJobRunner: map
17/03/21 14:50:46 INFO mapred.Task: Task 'attempt_local699809073_0001_m_000003_0' done.
```

PROFINIT

Co je výstupem programu?

```
[cloudera@quickstart capek_new]$ hadoop fs -ls /data/vystup
Found 5 items
-rw-r--r--   3 cloudera supergroup          0 2017-03-21 14:50 /data/vystup/_SUCCESS
-rw-r--r--   3 cloudera supergroup     181885 2017-03-21 14:50 /data/vystup/part-r-00000
-rw-r--r--   3 cloudera supergroup     177191 2017-03-21 14:50 /data/vystup/part-r-00001
-rw-r--r--   3 cloudera supergroup     176376 2017-03-21 14:50 /data/vystup/part-r-00002
-rw-r--r--   3 cloudera supergroup     179476 2017-03-21 14:50 /data/vystup/part-r-00003

[cloudera@quickstart capek_new]$ hadoop fs -cat /data/vystup/part-r-00002 | head -n 20
*TROMS;1
1876-77;1
80-86425-58-4;1
ABECEDU;1
ABELIÍ;1
ABOVARIO:;1
ABOVO;1
ABSOLUTISM;5
ABSOLUTISMEM;1
ABSOLUTISTICKÝ;1
ABSOLUTISTIČTÍ;1
ABSOLUTISTŮ;1
ABSOLUTNOSTI;1
ABSOLUTNÍM;1
ABSOLVOVAT;1
ABSTRAKTNÍCH;2
ABSURDUM;1
ABYCHOM;72
ACERJAPONICUM;1
ACETYLSALICYLAZID;1
```

PROFINIT

Příklady

„SQL“

- Hive jako tradiční dotazovací nástroj používá MapReduce. Jak?

- `SELECT COUNT(*) FROM SOME_TABLE;`

- MAP
  - pro každý řádek zapíšeme stejný klíč a číslo 1
  - `__row|1`
- REDUCE
  - jeden jeden klíč!
  - na výstup zapíšeme počet (nebo sumu) hodnot ke klíči row
  - `__count|633214`

PROFINIT

„SQL“

```
SELECT COUNT(*), NAME FROM SOME_TABLE
WHERE COUNTRY='CZ'
GROUP BY NAME
HAVING COUNT(*) > 100;
```

- MAP
  - přeskočíme všechny záznamy, které nemají CZ
  - pro každý řádek zapíšeme stejný klíč – NAME
  - hodnota bude 1
  - ```
    Novak|1
    Sladek|1
    ```
- REDUCE
  - tolik klíčů, kolik máme jmen!
  - spočítáme ke každému klíči počet (nebo sumu) hodnot ke klíč
  - na výstup zapíšeme, jen ty, které jsou větší než 100
  - ```
    Novak|654
    Sladek|162
    ```

PROFINIT

Joinování

```
SELECT S.SALES, S.YEAR, C.NAME
FROM ALL_SALES S JOIN ALL_CUSTOMER C
ON S.CUST_ID = C.CUST_ID
```

- Map-side join
  - mapování probíhá na straně mapperu
  - zpravidla vyžaduje přepřipravit data
  - není třeba přenášet mnoho dat do reduceru
- Reduce-side join
  - jednodušší na zápis
  - ale méně efektivní
- MapReduce driver
  - je třeba spustit 2 mappery pro každou tabulku
  - ```
    MultipleInputs.addInputPath(job, salesInputPath,
    TextInputFormat.class, SalesMapper.class);

    MultipleInputs.addInputPath(job, custInputPath,
    TextInputFormat.class, CustMapper.class);
    ```

PROFINIT
    ```

Reduce-side join

- MAP - CustMapper
  - na výstupu je klíč joinovací atribut (CUST_ID)
  - hodnota na výstupu je identifikace tabulky a NAME
  - `ID447:CustMapper:Novak Jaroslav`
- MAP – SalesMapper
  - na výstupu je klíč joinovací atribut (CUST_ID)
  - hodnota na výstupu je identifikace tabulky a SALES a YEAR
  - `ID447:SalesMapper:254122:2016`
- REDUCE
  - Iterace přes prvky values
  - Pro každý klíč dostanu (patrně) jeden záznam z CustMapper a několik ze SalesMapper
  - `ID447:SalesMapper:254122:2016:Novak Jaroslav`

PROFINIT

Map-side join

- Typicky druhý soubor **je výrazně menší a vejde se do paměti**
- Použití DistributedCache
- MAP
  - v metodě `setup()` načtení hodnot z DistributedCache do paměti (třeba HashMap pro rychlý přístup)
  - v samotné metodě `map()` načítám data z většího souboru a dohledávám k němu údaje v lokální cache
- REDUCE
  - nic zvláštního

PROFINIT

Co je MapReduce algoritmus?

- Řada složitých algoritmů si nevystačí se zpracováním v jednom běhu MapReduce.
- Typické je řetězení
  - jeden program vytvoří/připraví výstup do dočasného úložiště
  - následující program načte data z dočasného úložiště jako vstup
- Není nutné řetězit celé MapReduce programy, je možné řetězit jen několik mapperů pracujícími nad týmiž daty
  - pracují ve stejném JVM – odpadá režie s inicializací VM
  - typicky filtry, validace

Příklad na řetězení

```
SELECT S.SALES, S.YEAR, C.NAME
FROM ALL_SALES S JOIN ALL_CUSTOMER C
ON S.CUST_ID = C.CUST_ID
ORDER BY NAME;
```

- Předpokládám použití Reduce-side join
- 1. MapReduce provede joinování
- 2. MapReduce
  - klíč na výstupu mapperu bude NAME
  - dojde k sortování podle klíče
  - v reduceru pak změníme pořadí údajů na původní, ale dostaneme správně seřazený seznam

PROFINIT

MapReduce – shrnutí

Vlastnosti MapReduce

- Odladěná implementace
- Spolehlivé
  - když ostatní nástroje „padají“, MapReduce jede
- Velmi „malé“ požadavky na operační paměť
  - v paměti se drží jen malé bloky
  - slučování fragmentů probíhá merge sortem na discích
- Velmi četné zapisování na disk
  - nicméně na HDFS je jenom finální vstup a výstup
- Často generuje násobky dočasných dat ve srovnáním z množství vstupních dat
  - a často většinu dat musí zároveň uložit
- Toto je základní rys, zároveň silná i slabá stránka
- Tedy ve srovnání s jinými nástroji výrazně pomalejší

Slabé stránky

- Dlouhá doba, než se zpracování spustí
  - desítky sekund až minuty
- Při startu se inicializuje nový proces, JVM, nahrávají se knihovny...
  - a to se děje v mnoha instancích (na druhou stranu to separuje případné problémy do izolovaného procesu)
- Někdy složité na implementaci (mnoho knihoven)
- Mnoho konfigurací

Kdy použít MapReduce

- Tam, kde úloha umožňuje paralelizaci
  - a lze ji převést na úlohu vhodnou pro MapReduce
- Při práci se skutečně velkými daty (petabajty)
  - tak velká data se v paměti nedají uchovávat/zpracovat
- Při práci s výpočetně náročnými úlohami, kde se spíše data načítají než zapisují
- Když není čas kritický
- Stačí dávkové zpracování
- Když není dostatek paměti v clusteru

Kdy není vhodný MapReduce

- Tam, kde úlohu nelze paralelizovat a převést na MapReduce kompatibilní ☺
- Je-li vyžadována okamžitá reakce
  - i pro jednoduché úlohy trvá inicializace velmi dlouho
- Když je úkol „malý“

Kde se používá

- Kdekoli
- Zpracování velkého množství strukturovaných dat
  - ETL
  - **HIVE**
- Text mining
- Zpracování obrazu a videa
- Zkoumání lidského genomu
- Statistické modely
- Některé algoritmy strojového učení
  - např. K-Means

Alternativy v Hadoop

- Apache Tez
  - optimalizovaná „verze“ MapReduce
  - princip je podobný, stále se zapisují mezivýsledky na disk
  - ale množství zápisů se optimalizuje, některé úkoly se slučují
  - násobně zvyšuje rychlost a prostupnost dat

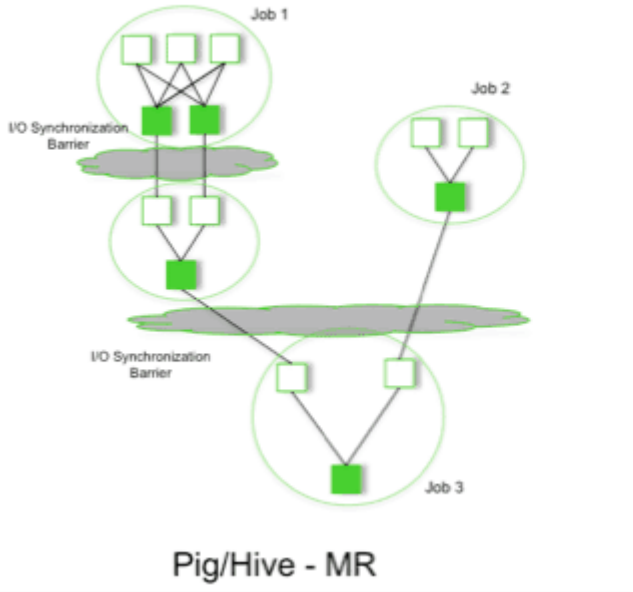

Pig/Hive - MR

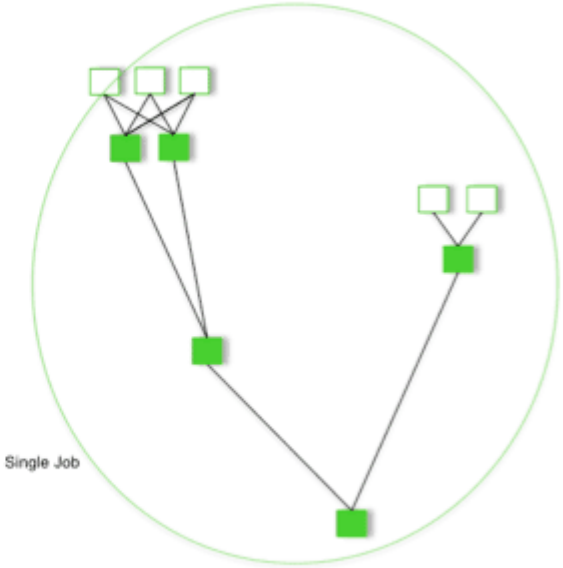

Pig/Hive - Tez

https://hortonworks.com/blog/introducing-tez-faster-hadoop-processing/

PROFINIT

Alternativy v Hadoop

- Apache Spark
  - příští přednáška
  - podobné paradigma
  - místo ukládání mezivýsledků na disk vše drží v paměti
  - často řádové rozdíly ve výkonu
  - vhodný i pro ad hoc analýzy

- Přijďte za 2 týdny a dozvíte se více!

Díky za pozornost

PROFINIT
NÁSKOK DÍKY ZNALOSTEM

Profinit EU, s.r.o.
Tychonova 2, 160 00 Praha 6

Telefon
+ 420 224 316 016

Web
www.profinit.eu

LinkedIn
linkedin.com/company/profinit

Twitter
twitter.com/Profinit_EU