Skladištenje i paketna obrada podataka

Hadoop, HDFS, MapReduce, Apache Spark

1

Sadržaj

- Skladištenje podataka
- Osnovi distribuirane obrade podataka
- Distribuirani sistemi datoteka (HDFS)
- Distribuirana obrada podataka (MapReduce)
- Apache Spark (paketna obrada)
- Pomoćni alati

2

Skladištenje podataka

3

Skladištenje podataka

- Skladištenje podataka je jedan od osnovnih elemenata inženjerstva podataka
  - sve ostale komponente ASVSP kontinualno komuniciraju sa skladištem podataka
    - radi pisanja i čitanja podataka
  - odabir odgovarajućeg skladišta podataka je od velikog značaja
    - kako za paketnu obradu tako i za obradu u realnom vremenu
    - za paketnu obradu posebno, zbog potrebe za učitavanjem i smeštanjem velikih količina podataka
      - optimizacija skladišta ovde ima mnogo veće posledice na performantnost sistema za obradu

4

Skladištenje podataka

- Osnovni pogledi na skladišta podataka
  - **Osnovne komponente skladišta podataka** (engl. *raw ingredients*)
    - medijumi za skladištenje podataka
    - upravljanje memorijom na niskom nivou apstrakcije
  - **Sistemi za skladištenje podataka** (engl. *storage systems*)
  - **Logičke apstrakcije skladišta podataka** (engl. *storage abstractions*)

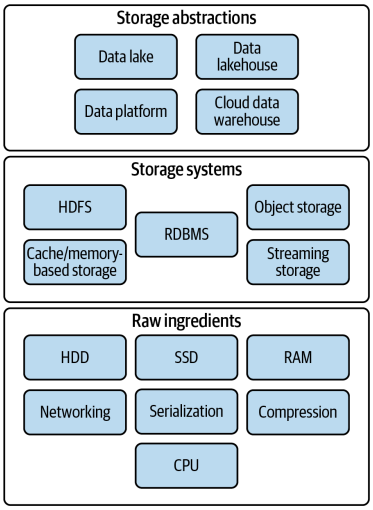

izvor: Joe Reis, Matt Housley: *Fundamentals of Data Engineering, O'Reilly* 5

5

Osnovne komponente skladišta podataka

- **Magnetni diskovi** (engl. *hard disk drives*, HDD)
  - sastavljeni od pokretnog magnetnog diska sa "glavom" za čitanje i pisanje
    - nastali 1950ih i od tada da neprestano unapređuju
  - veoma prisutni i postrojenjima za čuvanje podataka
    - najpovoljnija cena po gigabajtu skladišta (2 cent/GB)
    - moguć visok stepen paralelizacije prenosa podataka
      - dodavanjem novih diskova u paralalelno strukture
      - osnovna ideja računarskih sistema u oblaku
        - **mrežne komponente i CPU igraju bitnu ulogu u skladištenju i obradi podataka**

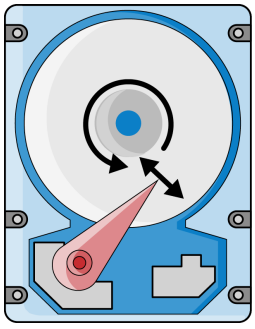

izvor: Joe Reis, Matt Housley: *Fundamentals of Data Engineering, O'Reilly* 6

6

Osnovne komponente skladišta podataka

- Magnetni diskovi
  - ograničeni zakonima fizike
    - **brzina prenosa** podataka ne skalira proporcionalno sa kapacitetom diska
      - kapacitet skalira sa *prostornom gustinom* (GB/mm²)
      - brzina prenosa skalira sa *linearnom gustinom* (GB/mm)
      - tipično 200–300 MB/s
    - **vreme traženja** je ograničeno fizičkim pomeranjem magnetnog diska i glave
      - vreme potrebno da se magnetni disk pozicionira ispod glave za čitanje se naziva rotaciona latencija (engl. *rotational latency*)
      - tipična prosečna latencija je 4ms za disk sa 7200 RPM
    - ograničen broj **ulazno-izlaznih operacija u sekundi** (engl. *input/output operations per second*, IOPS)
      - veoma bitno za transakcione sisteme
      - tipične vrednosti 50 do 500 IOPS-a

7

7

Osnovne komponente skladišta podataka

- **Poluprovodnički diskovi** (engl. *solid-state drives,* SSD)
  - skladište podatke u fleš memoriji
    - bez mehaničkih komponenti
  - omogućavaju
    - **kratko vreme traženja slučajno odabranog podatka** (0,1 ms)
    - skaliranje brzine prenosa podataka i IOPS-a
      - **particionisanjem skladišnog prostora**
      - **uvođenjem više kontrolera**, po jedan za svaku particiju
      - moguće skaliranje do mnogo GB/s i nekoliko 10.000 IOPSa
  - mnogostruko unapredili vremena odziva i propusnu moć OLTP sistema
    - ukoliko se koriste za *cache*, mogu unaprediti i OLAP sisteme
  - i dalje nisu prvi izbor za skladištenje velikih količina podataka
    - viša cena skladištenja po gigabajtu (20-30 centi/GB)

8

8

Osnovne komponente skladišta podataka

- **Memorija sa slučajnim pristupom** (engl. *random-access memory,* RAM)
  - skladišti podatke u kondenzatorima (dinamički RAM)
    - bez mehaničkih komponenti
  - omogućavaju
    - izuzetno brz pristup podacima jer je direktno povezana sa CPU-om, tj. dele adresni prostor (~100ns)
    - veliku brzinu prenosa podataka (100 GB/s) i veliki broj IOPS-a (1.000.000 IOPS-a)
  - memorija privremenog karaktera
    - prestankom napajanja gube se podaci
    - visoka cena skladištenja (10 dolara/GB)
    - ograničen kapacitet koji neki CPU može da podrži

9

9

Osnovne komponente skladišta podataka

- **Mrežne komponente** (engl. *network components*) i **procesori** (engl. *core processing unit,* CPU)
  - bitne komponente u skladištenju podataka
    - usled distribuirane prirode tih skladišta
    - bitne komponente u razmatranju razvoja ASVSP
  - da bi se omoguća paralelizacija čitanja i pisanja velikih količina podataka
    - **propusna moć mreže** koja povezuje komponente je od velike važnosti
    - **brzina procesora** takođe određuje propusnu moć tj. broj zahteva koji se mogu obraditi u jedinici vremena

10

10

Osnovne komponente skladišta podataka

- ***Cache*-iranje** podataka
  - proces skladištenja najčešće ili poslednje pročitanih podataka u memoriji
  - hijerarhijska organizacija *cache*-a
    - što je viši nivo to je veći prostor za memorisanje a manja brzina pristupa i propusna moć
    - najniži nivo - CPU *cache*
    - najviši nivo - skladišta za arhiviranje podataka
      - obrnuti *cache* (engl. *reverse cache*)

Storage type	Data fetch latency[a]	Bandwidth	Price
CPU cache	1 nanosecond	1 TB/s	N/A
RAM	0.1 microseconds	100 GB/s	$10/GB
SSD	0.1 milliseconds	4 GB/s	$0.20/GB
HDD	4 milliseconds	300 MB/s	$0.03/GB
Object storage	100 milliseconds	10 GB/s	$0.02/GB per month
Archival storage	12 hours	Same as object storage once data is available	$0.004/GB per month

[a] A microsecond is 1,000 nanoseconds, and a millisecond is 1,000 microseconds.

11

11

Osnovne komponente skladišta podataka

- **Serijalizacija podataka** (engl. *serialization*)
  - **serijalizacija** je proces pretvaranja strukturiranih objekata u nizove bajtova spremnih za slanje preko mreže ili skladištenje na disku
    - obrnut proces, pretvaranja nizova bajtova u strukturirane objekte naziva se **deserijalizacija**
  - obuhvata
    - logiku za upravljanje tipovima podataka
    - pravila za strukturiranje podataka
    - pravila za identifikaciju i potencijalno otklanjanje grešaka
      - npr. ciklične reference u strukturiranim podacima
  - utiče na
    - **brzinu prenosa podataka** – ondos između korisnih podataka i formatnih sekvenci
    - **brzinu čitanja i pisanja podataka**

12

12

Osnovne komponente skladišta podataka

- Serijalizacija podataka
  - tipovi serijalizacije
    - **serijalizacija po redovima**
    - **serijalizacija po kolonama**
    - **hibridna serijalizacija**
  - poželjne karakteristike serijalizacije
    - **kompaktnost serijalizovanih podataka**
      - korišćenje kompaktnog formata kako bi se najefikasnije iskoristio disk ili mrežni saobraćaj
    - **brza serijalizacija/deserijalizacija**
      - poželjno da sam proces serijalizacije/deserijalizacije traje što kraće
    - **proširivost procesa serijalizacije**
      - novim koracima i novim algoritmima
    - **interoperabilnost**
      - između različitih programskih jezika i hardverskih sistema
    - **pogodnost za domen primene**

13

13

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po redovima**
    - **svi podaci o nekom entitetu se serijalizuju zajedno, na jednom mestu**
      - organizovani u vidu redova
    - format ***Comma Separated Values*** **(CSV)**
      - smešta podatke u redovima, sa vrednostima razdvojenim nekim znakom
      - često susretan format, posebno često korišćen za arhiviranje podataka
        - u tom slučaju potrebno čuvati u datotekama detaljan opis strukture zarad lakšeg kasnijeg učitavanja podataka
      - ne postoji standard, svako ostavljeno na raspolaganje da bira znakove za formatiranje
      - preporuka da se izbegava korištenje formata CSV
        - veoma podložan greškama
        - ne postoji standard

14

14

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po redovima**
    - format ***Comma Separated Values*** **(CSV)**

```
Name,Birthdate,Birthplace,Sex
Chris Pratt,6/21/79,"Virginia, MN, USA",M
Ellen Barkin,4/16/54,"New York City, New York, USA",F
Lee Byung-hun,8/13/70,"Seongnam, South Korea",M
Eduardo Noriega,8/1/73,"Santander, Cantabria, Spain",M
Michael Dorman,4/26/81,"Auckland, New Zealand",M
Emily Blunt,2/23/83,"London, England, UK",F
Frances McDormand,6/23/57,"Gibson City, IL, USA",F
Ron Livingston,6/5/67,"Cedar Rapids, IA, USA",M
Morgan Freeman,6/1/37,"Memphis, TX, USA",M
Noomi Rapace,12/28/79,"Hudiksvall, Sweden",F
Djimon Hounsou,4/24/64,"Cotonou, Benin",M
Natalia Reyes,2/6/87,"Bogota, Columbia",F
```

15

15

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po redovima**
    - format ***Extensible Markup Language*** **(XML)**
      - podaci se serijalizuju u strukture proizvoljne kompleksnosti, koristeći tagove koji predstavljaju semantiku podataka koji se u njima nalaze
      - nekada popularan format podataka u začecima interneta
        - zbog svoje povezanosti sa jezikom HTML
        - sada se ne koristi toliko često, mahom prisutan u nasleđenim sistemima
          - danas ga zamenio format JSON
      - poseduje mehanizme za jasno definisanje strukture dokumenata
        - iako podržava i strukturirane i polustrukturirane dokumente
      - uopšteno, spor za serijalizaciju i deserijalizaciju

16

16

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po redovima**
    - format ***Extensible Markup Language*** **(XML)**

```
<?xml version="1.0" encoding="UTF-8"?>
- <EmployeeData>
  - <employee id="34594">
      <firstName>Heather</firstName>
      <lastName>Banks</lastName>
      <hireDate>1/19/1998</hireDate>
      <deptCode>BB001</deptCode>
      <salary>72000</salary>
    </employee>
  - <employee id="34593">
      <firstName>Tina</firstName>
      <lastName>Young</lastName>
      <hireDate>4/1/2010</hireDate>
      <deptCode>BB001</deptCode>
      <salary>65000</salary>
    </employee>
</EmployeeData>
```

17

17

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po redovima**
    - format ***JavaScript Object Notation*** **(JSON)**
      - podaci se serijalizuju u vidu parova ključ i vrednost
        - gde vrednosti mogu biti prostog tipa, objekti ili liste
        - dozvoljeno proizvoljno ugnežđavanje struktura
      - standardizovan način za razmenu podataka preko interneta
        - posebno u prisustvu komunikacije putem protokola HTTP
      - veoma popularan i za serijalizaciju pri skladištenju podataka
        - zahvaljujući usponu NoSQL baza podataka kao što je MongoDB
        - sve više relacionih baza podržava skladištenje JSON dokumenata u svojim relacijama
          - kao i proširenja jezika SQL za rad sa formatom JSON
    - format ***JSON Lines*** **(JSONL)**
      - verzija formata JSON u kojoj dokument ne predstavlja jedan korenski JSON objekat već podržava kreiranje sekvence JSON objekata
        - svaki objekat je u novom redu

18

18

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po redovima**
    - formati ***JavaScript Object Notation*** **(JSON)** i ***JSON Lines*** **(JSONL)**

```
{
    "orders": [
        {
            "orderno": "748745375",
            "date": "June 30, 2088 1:54:23 AM",
            "trackingno": "TN0039291",
            "custid": "11045",
            "customer": [
                {
                    "custid": "11045",
                    "fname": "Sue",
                    "lname": "Hatfield",
                    "address": "1409 Silver Street",
                    "city": "Ashland",
                    "state": "NE",
                    "zip": "68003"
                }
            ]
        }
    ]
}
```

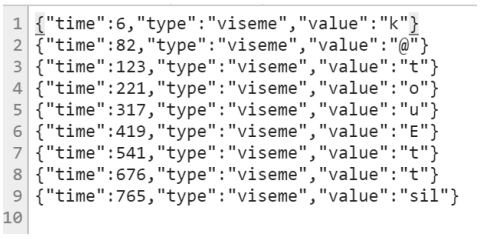

```
{"time":6,"type":"viseme","value":"k"}
{"time":82,"type":"viseme","value":"@"}
{"time":123,"type":"viseme","value":"t"}
{"time":221,"type":"viseme","value":"o"}
{"time":317,"type":"viseme","value":"u"}
{"time":419,"type":"viseme","value":"E"}
{"time":541,"type":"viseme","value":"t"}
{"time":676,"type":"viseme","value":"t"}
{"time":765,"type":"viseme","value":"sil"}
```

19

19

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po redovima**
    - format ***Apache Avro***
      - podaci se serijalizuju u binarnom formatu sa metapodacima definisanim u okviru JSON datoteka
        - u svakoj poruci, šalju se i šema i podaci
      - prednosti obuhvataju
        - mala količina izvandomenskih podataka
        - pogodan za upotrene u tokovima podataka
        - podržava evoluciju šeme
      - veoma popularan u Hadoop ekosistemu
        - podržan od strane svih većih pružaoca usluga u oblaku

20

20

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po redovima**
    - format ***Apache Avro***

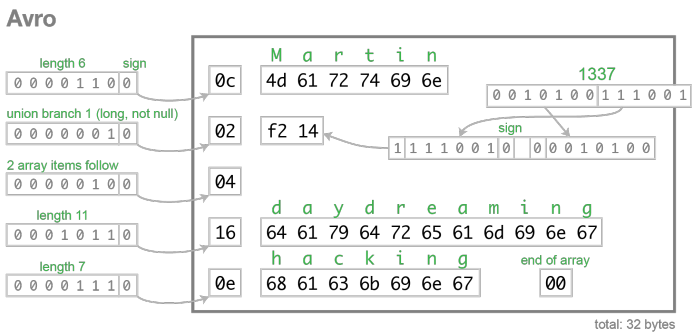

izvor: Martin Kleppmann: *Designing Data Intensive applications, O'Reilly* 21

21

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po kolonama**
    - **sve vrednosti nekog obeležja se serijalizuju zajedno, na jednom mestu**
      - podaci o jednom entitetu rasuti u mnogo različitih redova, u zavisnosti od obeležja koje entitet poseduje
      - zajedno smeštene vrednosti istog tipa
        - pogodno za kompresiju, posebno u slučajevima gde se vrednost ponavlja mnogo puta
        - čak i u slučajevima kada nemam ponavljanje iste vrednosti već se mogu uvideti šabloni unutar samih vrednosti
        - obično se koriste u kombinaciji sa nekim kompresionim algoritmom
    - dozvoljava efikasno čitanje svih vrednosti za podskup skupa svih obeležja
      - nije potrebno pročitati celi dokument
      - pogodna je za primenu u analitičkim sistemima
    - nije pogodna za transakcione sisteme
      - učitavanje vrednosti o jednom entitetu
      - modifikaciju vrednosti nekog entiteta

22

22

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po kolonama**
    - format ***Apache Parquet***
      - podaci rastavljeni na kolone, vrednosti kolona grupisane i sačuvane u datoteci, u svakom redu sve vrednosti za datu kolonu
        - sadrži zaglavlje sa metapodacima o datoteci
        - šema je ugrađena zajedno sa podacima u poruke koje se prenose
          - podržava i ugneždene strukture
      - visoko portabilan serijalizacioni format
        - većina servisa za rad sa podacima u oblaku podržava ovaj format serijalizacije
      - često se koristi u kombinaciji sa kompresijom
        - posebno je popularna kombinacija sa algoritmom Snappy

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po kolonama**
    - format ***Apache Parquet***

Row count Size in bytes Column chunk size: compressed / uncompressed / ratio

```
row group 1:          RC:2840100 TS:154947976 OFFSET:4
--------------------------------------------------------------------------------
ss_sold_time_sk:     INT32 SNAPPY DO:0 FPO:4 SZ:2419027/5886237/2.43 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_item_sk:          INT32 SNAPPY DO:0 FPO:2419031 SZ:5040887/5040503/1.00 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_customer_sk:      INT32 SNAPPY DO:0 FPO:7459884 SZ:4200678/7168827/1.71 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_cdemo_sk:         INT32 SNAPPY DO:0 FPO:11660562 SZ:4179788/7133528/1.71 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_hdemo_sk:         INT32 SNAPPY DO:0 FPO:15840350 SZ:3948359/4755600/1.20 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_addr_sk:          INT32 SNAPPY DO:0 FPO:19788709 SZ:4199290/7144061/1.70 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_store_sk:         INT32 SNAPPY DO:0 FPO:23987999 SZ:1405046/2279438/1.62 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_promo_sk:         INT32 SNAPPY DO:0 FPO:25393045 SZ:3264270/3341421/1.02 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_ticket_number:    INT32 SNAPPY DO:0 FPO:28657315 SZ:3748010/7125883/1.90 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_quantity:         INT32 SNAPPY DO:0 FPO:32405325 SZ:2569908/2646790/1.03 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_wholesale_cost:   INT32 SNAPPY DO:0 FPO:34975233 SZ:5036313/5113188/1.02 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_list_price:       INT32 SNAPPY DO:0 FPO:40011546 SZ:5422519/5500119/1.01 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_sales_price:      INT32 SNAPPY DO:0 FPO:45434065 SZ:5386171/5463066/1.01 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_ext_discount_amt: INT32 SNAPPY DO:0 FPO:50820236 SZ:3721043/6098549/1.64 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_ext_sales_price:  INT32 SNAPPY DO:0 FPO:54541279 SZ:11202990/11309483/1.01 VC:2840100 ENC:PLAIN,BIT_PACKED,RLE
ss_ext_wholesale_cost: INT32 SNAPPY DO:0 FPO:65744269 SZ:11235173/11309896/1.01 VC:2840100 ENC:PLAIN,BIT_PACKED,RLE
ss_ext_list_price:   INT32 SNAPPY DO:0 FPO:76979442 SZ:11232056/11307593/1.01 VC:2840100 ENC:PLAIN,BIT_PACKED,RLE
ss_ext_tax:          INT32 SNAPPY DO:0 FPO:88211498 SZ:6226701/6299755/1.01 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_coupon_amt:       INT32 SNAPPY DO:0 FPO:94438199 SZ:3721043/6098549/1.64 VC:2840100 ENC:PLAIN_DICTIONARY,BIT_PACKED,RLE
ss_net_paid:         INT32 SNAPPY DO:0 FPO:98159242 SZ:11192504/11308687/1.01 VC:2840100 ENC:PLAIN,BIT_PACKED,RLE
ss_net_paid_inc_tax: INT32 SNAPPY DO:0 FPO:109351746 SZ:11219364/11308178/1.01 VC:2840100 ENC:PLAIN,BIT_PACKED,RLE
ss_net_profit:       INT32 SNAPPY DO:0 FPO:120571110 SZ:11235592/11308829/1.01 VC:2840100 ENC:PLAIN,BIT_PACKED,RLE
```

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po kolonama**
    - format ***Optimized Row Column (ORC)***
      - preteča *Parquet* formata, vrlo sličnih karakteristika
        - intenzivno korištena u okviru alata *Apache Hive*
      - danas se ređe koristi od formata Parquet
        - veliki broj alata podržava uvlačenje podataka iz ovog formata
          - ali ne i snimanje podataka u ovaj format

25

25

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po kolonama**
    - format ***Optimized Row Column (ORC)***

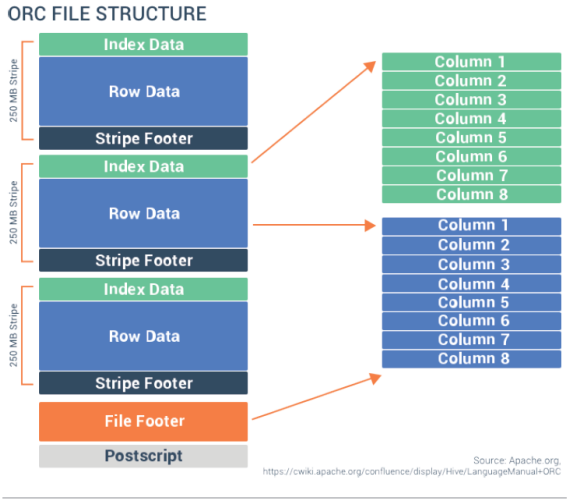

26

26

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po kolonama**
    - format ***Apache Arrow***
      - omogućava istu binarnu reprezentaciju podataka za skladištenje i razmenu kao što je slučaj sa podacima u radnoj memoriji
        - "gusto pakovanje" podataka kao što je to slučaj sa nizovima u C-u
          - moguće zbog fiksne dužine tipa
        - svaka kolona dobija svoj deo memorije
          - za ugneždene strukture kreira se mapiranje između lokacije vrednosti u originalnoj strukturi i nove, kreirane kolone za ugneždenu strukturu
            - vrsta pokazivača
            - engl. *shredding*
      - omogućava direktno kopiranje strukture sa diska u radnu memoriju bez potrebe za serijalizacijom ili deserijalizacijom
        - omogućava veoma brzu zamenu delova velike datoteke između radne memorije i diska

27

27

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po kolonama**
    - format ***Apache Arrow***
      - problem različite binarne reprezentacije u različitim programskim jezicima
        - prevaziđen korišćenjem biblioteke za serijalizaciju koja je napisana za veliki broj trenutno korišćenih jezika
          - ponekad enkapsuliran kod niskog nivoa napisan u C-u
          - omogućava interoperabilnost između programskih jezika

28

28

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **serijalizacija po kolonama**
    - format ***Apache Arrow***

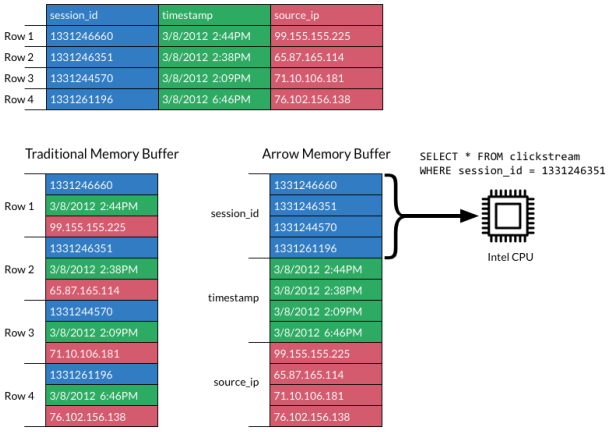

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **hibridna serijalizacija**
    - format ***Hadoop Update Delete Incremental (Hudi)***
      - deo podataka serijalizuje po redovima a deo po kolonama
      - omogućava dobre analitičke performanse i omogućava transakcione modifikacije entiteta
        - nove modifikacije entiteta se skladište po redovima
          - nastale npr. kao rezultat CDC mehanizma neke baze podataka
        - većina ostatka baze podataka je skladištena po kolonama
          - periodično se podaci skladišteni po redovima prepakuju u kolone
        - upit se izvršava nad oba tipa datoteka

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **hibridna serijalizacija**
    - format ***Hadoop Update Delete Incremental (Hudi)***

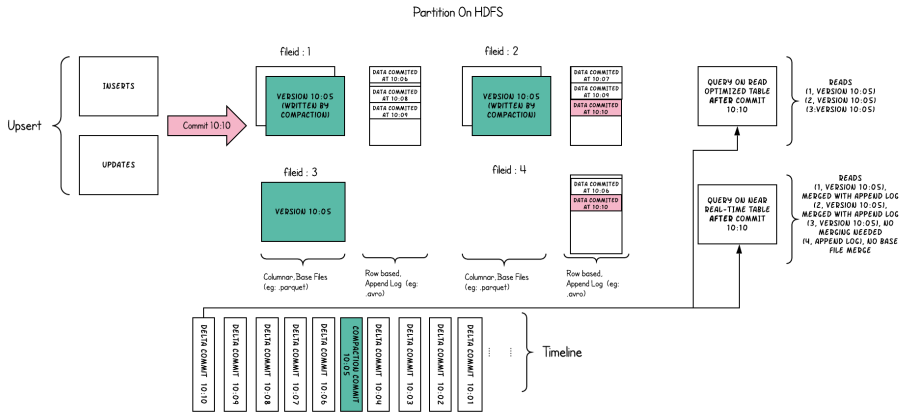

Osnovne komponente skladišta podataka

- Serijalizacija podataka – formati
  - **hibridna serijalizacija**
    - format ***Apache Iceberg***
      - slično kao i *Hudi*
      - visoke mogućnosti upravljanja metapodacima tabela
        - prati sve datoteke koje čine sadržaj tabele
        - prati sve istorijske verzije svake od tih datoteka
        - podržava evoluciju šeme

Osnovne komponente skladišta podataka

- **Kompresija** podataka (engl. *compression*)
  - proces smanjivanja količine memorije koju podaci zauzimaju naprednim tehnikama kodovanja
  - prednosti korišćenja kompresije
    - **omogućava da se više podataka smesti na manjem skladišnom prostoru**
    - **praktično povećava propusnu moć sistema**
      - više podataka se pretražuje u jedinici vremena
      - ako je kompresija sa faktorom 10:1, 200 MB/s efektivno postaje 2000 MB/s
    - **ubrzava razmenu podataka preko mreže** kao i razmenu podataka sa diskom
  - mana je **potreba za dodatnim vremenom i resursima** da se podaci iščitaju ili upišu
    - usled potrebe za kompresijom i dekompresijom
  - što je veća količina podataka koja se skladišti izraženiji su benefiti koje kompresija donosi
    - stoga izuzetno bitan element svakog (distribuiranog) sistema datoteka
  - postoji veliki broj formata, alata i algoritama za kompresiju
    - **različiti kompresioni formati imaju različit odnos vremena potrebnog za kompresiju/dekompresiju i uštede prostora**

33

33

Osnovne komponente skladišta podataka

- Kompresija podataka
  - formati

Compression format	Tool	Algorithm	Filename extension	Splittable?
DEFLATE[a]	N/A	DEFLATE	*.deflate*	No
gzip	*gzip*	DEFLATE	*.gz*	No
bzip2	*bzip2*	bzip2	*.bz2*	Yes
LZO	*lzop*	LZO	*.lzo*	No[b]
LZ4	N/A	LZ4	*.lz4*	No
Snappy	N/A	Snappy	*.snappy*	No

34

34

Sistemi za skladištenje podataka

- **Sistemi za skladištenje podataka** (engl. *data storage systems*)
  - apstrakcija nad osnovnim komponentama skladišta podataka
  - **distribucija** sistema skladišta podataka je veoma bitna karakteristika
    - koja se mora uzeti u obzir prilikom projektovanja ASVSP
    - zahtevana ukoliko je kapacitet jedne mašine nedovoljan za skladištenje svih podataka
    - zahteva
      - veći stepen koordinacije između hardverskih komponenti,
      - više mrežnog saobraćaja
      - posebne principe projektovanja
    - veoma je bitno jasno definisati nivo konzistentnosti podataka u ovakvim sistemima
      - BASE ili ACID

35

35

Sistemi za skladištenje podataka

- **Sistemi za skladištenje podataka** (engl. *data storage systems*)
  - **sistemi datoteka** (eng. *file storage / file systems*)
    - obuhvataju strukture i metode za upravljanje datotekama i direktorijumima
      - implementirani od strane operativnog sistema
    - **datoteka** je skup podataka sa pridruženim karakteristikama čitanja, pisanja i referenciranja
      - koju koriste aplikacije ili operativni sistem
      - poseduje sledeće karakteristike
        - **konačna dužina** (engl. *finite length*)
        - **mogućnost proširenja** (engl. *append oprations*)
        - **pristup slučajno odabranom slogu** (engl. *random access*)
    - strukturalna organizacija putem direktorijuma

36

36

Sistemi za skladištenje podataka

- **Sistemi za skladištenje podataka** (engl. *data storage systems*)
  - **sistemi datoteka** (eng. *file storage / file systems*)
    - tipovi sistema datoteka
      - **lokalni sistem datoteka** (engl. *local disk storage*)
        - prisutan na lokalnim HDD ili SSD diskovima kojima upravlja operativni sistem
        - obično podržavaju visoku konzistenciju
          - *read-after-write consistency*
        - podržavaju mehanizam zaključavanja resursa
      - **mrežni sistem datoteka** (engl. *network-attached storage*, NAS)
        - omogućava klijent/server komunikaciju sa sistemom datoteka preko mreže
        - udaljeni sistem datoteka se koristi na računaru koji se ponaša kao klijent

37

37

Sistemi za skladištenje podataka

- **Sistemi za skladištenje podataka** (engl. *data storage systems*)
  - **sistemi datoteka** (eng. *file storage / file systems*)
    - tipovi sistema datoteka
      - **distribuirani sistem datoteka** upravlja datotekama i direktorijumima smeštenim na više od jednog računara
        - koristi se kada količina podataka preraste mogućnosti skladištenja na jednom računaru
        - kompleksniji za implementaciju i održavanje
      - **sistem datoteka u oblaku** (engl. *cloud filesystem services*)
        - sistemi datoteka koji se nude kao servis od strane pružaoca usluga u oblaku
        - mogu se koristiti iz virtualnih mašina, kontejnera ili drugih usluga u oblaku
        - slični mrežnim sistemima datoteka, sa skrivenim detaljima upravljanja mrežom
        - npr. *Amazon Elastic File System (EFS)*

38

38

Sistemi za skladištenje podataka

- **Sistemi za skladištenje podataka** (engl. *data storage systems*)
  - **blokovsko skladište** (eng. *block storage*)
    - sirovo skladište koje koristi primitivne, atomičke jedinice upravljanja skladištenjem na HDD i SSD
    - **blok** predstavlja najmanju jedinicu čitanja i pisanja na memorijski medijum
      - trenutno, veličine oko 4096 bajta na diskovima
    - standardni način skladištenja podataka u virtualnim mašinama u oblaku
      - najveće mogućnosti podešavanja veličine skladišta, skalabilnosti i dugotrajnosti podataka
    - transakcione baze podataka često organizuju blokove u optimalne strukture za rad sa podacima
    - **mrežno blokovsko skladište** (engl. *storage area network*)
      - nudi blokovsko skladište iz skupa spremnih skladišta putem mreže
      - osnova za blokovska skladišta u oblaku

39

39

Sistemi za skladištenje podataka

- **Sistemi za skladištenje podataka** (engl. *data storage systems*)
  - **objektno skladište** (eng. *object storage*)
    - skladište **nepromenjlivih objekata** u okviru **parova tipa ključ/vrednost**
    - **objekat** u ovom kontekstu predstavlja bilo koji konstrukt koji sadrži podatke
      - npr. tekstualna datoteka, slika, audio ili video zapis
      - **konačna dužina objekata**
      - **nema mogućnost proširenja veličine i sadržaja objekta**
        - potrebno je prepisati objekat
      - **ne podržava performantan pristup slučajno odabranom slogu**
        - iako podržava slučajan pristup putem mehanizma pristupa opsegu bajtova unutar objekta
          - engl. *range requests*
    - izuzetno popularni sistemi za skladištenje podataka u oblaku
      - npr. *Amazon S3, Azure Blob Storage,* i *Google Cloud Storage (GCS)*
      - iako mogu biti instalirani na lokalnim diskovima, obično se koriste verzije u oblaku

40

40

Sistemi za skladištenje podataka

- **Sistemi za skladištenje podataka** (engl. *data storage systems*)
  - **objektno skladište** (eng. *object storage*)
    - nema potrebe za zaključavanjem objekata
      - usled njihove nepromenljivosti
      - upisivanje nove verzije objekta podrazumeva upisivanje celokupnog objekta
        - moguće je **verzionisanje** objekata čuvanjem starih verzija u celosti
        - može dovesti do problema sa **konzistentnošću** objekata
          - posebno u slučaju visokog nivoa replikacije
    - nema potrebe za sinhronizacijom izmena
    - ne postoji hijerarhijska struktura direktorijuma
      - ravna struktura sa tagovima i ključevima pridruženim svakom objektu
    - **veoma skalabilna rešenja** usled prethodno navedenih mogućnosti
      - omogućena velika paralelizacija operacija pisanja i čitanja tokova podataka
    - predstavlja kamen temeljac u razdvajanju procesnih elemenata arhitekture od elemenata za skladištenje

41

41

Logičke apstrakcije skladišta podataka

- **Logičke apstrakcije skladišta podataka** (engl. *storage abstractions*)
  - apstrakcije nad sistemima skladištenja koje odražavaju šablone čitanja i pisanja podataka odabranim spram vrednosti sledećih parametara
    - cilj čuvanja podataka i slučaj korišćenja
    - željeni šabloni ažuriranja podataka
    - dozvoljena cena čuvanja podataka
    - odvajanje procesne moći od sistema za skladištenje
  - tipovi logičkih apstrakcija skladišta podataka
    - **skladište podataka** (engl. *data warehouse*)
    - **jezero podataka** (engl. *data lake*)
    - **skladište u jezeru podataka** (engl. *data lakehouse*)
    - **platforme za skladištenje podataka** (engl. *data platforms*)
    - **katalozi podataka** (engl. *data catalogs*)

42

42

Logičke apstrakcije skladišta podataka

- **Logičke apstrakcije skladišta podataka**
  - **skladište podataka** (engl. *data warehouse*)
    - standardne arhitekture OLAP baza podataka
      - obično zasnovane na relacionom modelu podataka
      - u tradicionalnom smislu se odnosile na visoko strukturirane podatke
    - termin koji obuhvata
      - koncept centralizacije podataka i arhitekture sistema koji nju podržavaju
      - tehnološke platforme koje su u ponudi u oblaku
      - organizacioni šablon podataka unutar neke kompanije

43

43

Logičke apstrakcije skladišta podataka

- **Logičke apstrakcije skladišta podataka**
  - **jezero podataka** (engl. *data lake*)
    - veoma veliko skladište podataka za čuvanje podataka u sirovom, izvornom obliku
      - bez velike brige o metapodacima i šemi samih podataka
    - u zadnjih par godina prešlo se sa Hadoop klastera na objektna skladišta
      - uvidela se potreba da ipak treba da postoji skladište metapodataka
  - **skladište u jezeru podataka** (engl. *data lakehouse*)
    - arhitektura koja kombinuje aspekte skladišta objekata i jezera podataka
      - koristi objektna skladišta za čuvanje podataka
      - koristi mehanizma za čuvanje metapodataka i kreiranje šeme nad (delom) podataka
        - sa podrškom za modifikaciju podataka
        - često u kombinaciji sa formatima poput *Hudi* i *Iceberg*
  - **platforme za skladištenje podataka** (engl. *data platforms*)
    - skladišta u jezeru podataka koje neki proizvođači nude kao *SaaS* platformu
    - zajedno sa svim pratećim alatima koji olakšavaju rad sa podacima u okviru platforme

44

44

Logičke apstrakcije skladišta podataka

- **Logičke apstrakcije skladišta podataka**
  - **katalozi podataka** (engl. *data catalogs*)
    - centralizovana skladišta metapodataka
      - za sve druge platforme sa podacima u celokupnoj organizaciji
    - omogućavaju konzistentnu semantiku podataka i šema podataka
    - omogućavaju interoperabilnost i lakšu komunikaciju unutar timova
    - omogućavaju lakše deljenje znanja

45

45

Osnovi distribuirane obrade podataka

46

Osnovi distribuirane obrade podataka

- Postoji potreba za skladištenjem i obradom velike količine podataka
  - kapacitet skladišta raste zadovoljavajućom brzinom
    - **ali brzina pristupa podacima ne prati trend** povećanja količine podataka
    - imamo velika ali spora skladišta podataka
  - potrebno je obraditi podatke u odgovarajućem vremenu
  - jedno rešenje je **paralelizacija čitanja i pisanja podataka** (horizontalno skaliranje)
    - kompleksno rešenje sa stanovišta implementacije i eksploatacije
  - drugo rešenje je pronalaženje i korišćenje novih uređaja koji omogućavaju bolje performanse (vertikalno skaliranje)
    - skupo rešenje

47

47

Osnovi distribuirane obrade podataka

- Potreba za skladištenjem i obradom velike količine podataka
  - rešenje: paralelizacija čitanja i pisanja podataka
    - **skladištenje podataka na više diskova istovremeno**
      - u distribuiranom sistemu datoteka
      - veliko ubrzanje u pristupu podacima u odnosu na nedistribuirani sistem
        - posebno u slučaju magnetnih diskova
      - izazovi
        - otkaz pojedinačnih diskova
          - uvođenje redundanse replikacijom podataka, npr. RAID
        - kompleksno upravljanje infrastrukturom (mrežom)
    - **paralelna obrada podataka**
      - zahtev da analiza podataka obuhvati podatke sa više diskova istovremeno
        - potreban mehanizam koji apstrahuje sinhronizaciju i čitanje podataka u distribuiranom okruženju, npr. MapReduce
      - izazov - što bolje iskorišćenje resursa distribuiranog sistema

48

48

Distribuirani sistem datoteka (HDFS)

49

Distribuirani sistemi datoteka

- Distribuirani sistem datoteka (engl. *distributed file system*)
  - **distribuirani sistem datoteka** upravlja datotekama i direktorijumima smeštenim na više od jednog računara
    - koristi se kada količina podataka preraste mogućnosti skladištenja na jednom računaru
    - kompleksniji za implementaciju i održavanje
  - **sistem datoteka** čiji su klijenti, serveri i skladišni uređaji raspoređeni na više računara u okviru distribuiranog sistema
    - **servis** - softver koji se izvršava na jednom ili više računara i pruža određeni tip funkcionalnosti klijentima koji nisu unapred poznati
    - **server** - računar na kojem se izvršava servis
    - **klijent** - proces koji komunicira sa servisom
      - koristeći skup operacija koje čine **interfejs klijenta**
      - klijent sistema datoteka ima proste operacije za rad sa datotekama u interfejsu
        - kreiranje, brisanje, čitanje i pisanje

50

50

Distribuirani sistem datoteka

- Distribuirani sistem datoteka - očekivane karakteristike
  - **interfejs klijenta bi trebalo da bude transparentan**
    - tj. da apstrahuje lokaciju datoteke i da se ne vidi eksplicitno razlika između lokalnih i udaljenih datoteka
  - **performanse distribuiranog sistema datoteka trebalo bi da budu uporedive sa centralizovanim sistemom datoteka**
    - čak i u prisustvu dodatnog mrežnog saobraćaja
  - distribuirani sistem datoteka treba da **omogući linearno skaliranje performansi sa povećanjem broja čvorova**
    - ili makar približno linearno skaliranje

51

51

Distribuirani sistem datoteka

- Distribuirani sistemi datoteka
  - Andrew File System (AFS)
    - distribuirani sistem datoteka kod kojeg je osnovni cilj da pruži što veću mogućnost skaliranja
      - male datoteke koje je moguće keširati i koje se ne dele među korisnicima
      - učestanost čitanja je mnogo veća od učestanosti pisanja
      - preovladava sekvencijalno čitanje podataka
  - Network File System (NFS)
    - razvijen od strane kompanije *Sun Microsystems*
    - omogućava da se direktorijumi logički jedinstvenog sistema datoteka, fizički nalaze na različitim mašinama
      - autonomnost klijenata i servera u arhitekturi
  - **Hadoop File System** (HDFS)
    - često korišćeni distribuirani sistem datoteka
    - deo alata Hadoop

52

52

Distribuirana obrada podataka

- Tipovi obrade i izvršenja programa
  - konkurentna obrada
    - obrada od strane više procesa nad istim vremenskim intervalom
      - svaki od procesa dobije deo procesorskog vremena
      - obrada nije paralelna
        - ne postoji koordinacija između procesa
        - ne postoji komunikacija između procesa
  - paralelna obrada
    - obrada od strane više procesa istovremeno
      - zahteva postojanje više jezgara procesora
      - ne postoji koordinacija niti komunikacija između procesa
  - **distribuirana obrada**
    - obrada od strane više procesa koji međusobno komuniciraju radi izvršavanja obrade
      - najčešće se procesi izvršavaju na različitim procesorima/računarima

53

53

Distribuirana obrada podataka

- Paketna obrada podataka (engl. *batch processing*)
  - **distribuirana obrada velike količine podataka smeštenih u distribuiranom sistemu datoteka**
    - prilikom obrade podataka čitaju se isključivo paketi podataka
      - paketi su iste, unapred podešene veličine
    - pisanje podataka u distribuirani sistem datoteka se najčešće obavlja za međurezultate koraka obrade
  - može se koristiti paradigma obrade podataka MapReduce
    - ili alternativni model distribuirane obrade podataka: Spark, Hama, Giraph, MPI, Tez
    - ili neki od alata koji povišuju stepen apstrakcije: Pig, Hive, Presto

54

54

Paketna obrada podataka

- Paketna obrada podataka

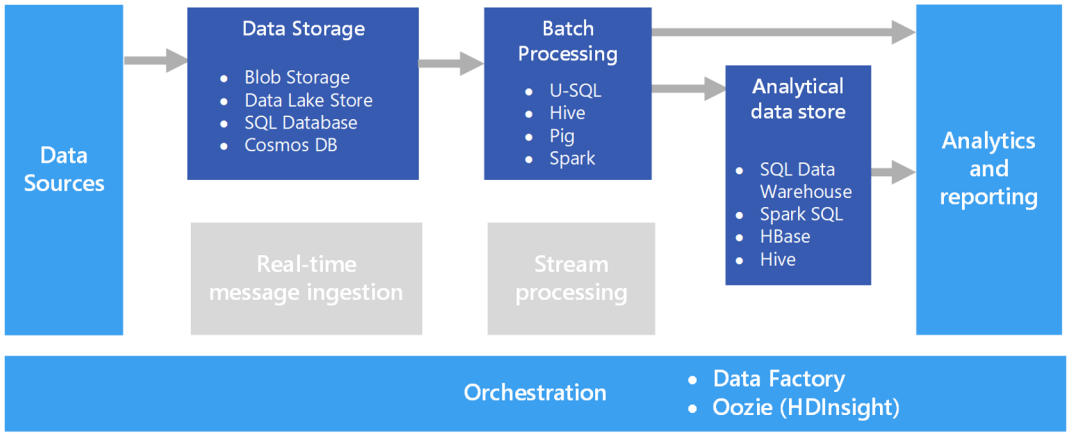

izvor: *Big data architectures, Microsoft,* https://docs.microsoft.com/en-us/azure/architecture/data-guide/big-data/batch-processing

55

55

Hadoop

- Hadoop je distribuirani sistem za skladištenje i analizu podataka koji obuhvata
  - **HDFS** za skladištenje podataka
  - **MapReduce** za obradu podataka
- Hadoop - istorija
  - kreator Doug Cutting
    - kreator Apache Lucene biblioteke
    - bivši radnik kompanije Yahoo!
  - kreiran za potrebe web pretraživača
    - 2002, inicijalno kao biblioteka Apache Nutch koja je deo projekta Apache Lucene
      - NDFS i MapReduce
    - 2008. kao samostalan projekat Apache Hadoop
      - obuhvata MapReduce i HDFS
        - Hadoop v2 podržava i druge paradigme za distribuiranu obradu podataka
      - obuhvata i veliki broj drugih alata i biblioteka

56

56

Distribuirani sistem datoteka Hadoop (HDFS)

- Distribuirani sistem datoteka Hadoop (engl. *Hadoop Distributed File System*, HDFS)
  - sistem datoteka implementiran u okviru alata Hadoop
  - koristi se Hadoop I/O apstrakcija nad sistemom datoteka
    - tj. implementacioni detalji HDFS-a skriveni od krajnjeg korisnika
  - nije obavezno koristiti HDFS sa Hadoop-om
    - Hadoop podržava i druge distribuirane sisteme datoteka
      - ali se najčešće koristi HDFS

57

57

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osobine
  - **HDFS je distribuirani sistem datoteka projektovan da omogući skladištenje izuzetno velikih datoteka, pruži optimizovane metode za čitanje podataka, i da radi na klasteru napravljenom od regularnog hardvera**
  - **izuzetno velike datoteke**
    - u ovom kontekstu, datoteke veličine od nekoliko stotina megabajta do nekoliko terabajta
    - postoje Hadoop klasteri koji skladište i nekoliko petabajta podataka
      - npr. Yahoo! klaster
  - **optimizovane metode za čitanje podataka**
    - šablon upravljanja podacima: **piši jednom, čitaj više puta**
      - podaci su generisani ili kopirani iz nekog izvora
      - obrade nad podacima se ponavljaju više puta
    - svaka obrada obuhvata čitanje (skoro) celokupnog skupa podataka
      - **vreme čitanja celog skupa je bitnije od čitanja pojedinačnog podatka**

58

58

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osobine
  - **radi na regularnom hardveru** (engl. *commodity hardware*)
    - hardver koji je napravljen za svakodnevnu upotrebu u različitim domenima primene
      - standardni delovi svakog personalnog računara
    - napravljen od strane različitih proizvođača

59

59

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osobine
  - HDFS nije pogodan za obradu u sledećim slučajevima
    - pristup podacima sa niskom latencijom
      - engl. *low-latency data access*
      - HDFS je projektovan za prenos i čitanje velike količine podataka i zbog toga nije pogodan za pristup sa niskom latencijom
        - bolje rešenje je korišćenje **HBase** baze podataka
    - postojanje velikog broja malih datoteka
      - usled potrebnog indeksiranja i održavanja liste datoteka u sistemu
    - postojanje višestrukih programa koji pišu podatke i izmena slučajnog sloga datoteke
      - **HDFS podržava postojanje samo jednog programa koji piše u datoteku**
      - **podaci se uvek upisuju na kraj datoteke**

60

60

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osnovni koncepti
  - **blok** (engl. *block*)
    - osnovna jedinica manipulacije podacima u HDFS-u
    - ukoliko nije izmenjena, veličina bloka je 64MB (Hadoop 1.x) ili 128MB (Hadoop 2.x)
      - blok je namerno napravljen da bude veliki zbog prirode obrade koja se izvršava nad HDFS sistemom datoteka
        - potreba za čitanjem, traženjem, i razmenom velike količine podataka
    - **datoteke su podeljene u blokove fiksne veličine koji su smešteni nezavisno jedan od drugog**
      - moguće je da su smešteni i na različitim računarima u klasteru
      - **fiksna veličina blokova omogućava procenu kapaciteta, lakšu replikaciju i jednostavnije upravljanje memorijom**
    - ukoliko je datoteka manja od veličine bloka, ona ne zauzima celi blok na disku
      - kao što je to slučaj sa uobičajenim sistemima datoteka

61

61

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osnovni koncepti
  - **imenski čvorovi** (engl. *namenodes*) i **čvorovi sa podacima** (engl. *datanodes*)
    - dve vrste čvorova u HDFS klasteru
    - **imenski čvorovi**
      - sadrži **registre svih datoteka** koji se nalaze u sistemu datoteka
        - meta-podaci o svim datotekama i direktorijumima
        - trajno uskladišteni na imenskom čvoru
        - sastoji se od **slike imenskog prostora** (engl. *namespace image*) i **logova izmena** (engl. *edit logs*)
      - sadrže **lokacije blokova** svake datoteke
        - ne skladište se trajno na disku, već svi čvorovi sa podacima prijavljuju blokove prilikom svakog pokretanja sistema
    - **čvorovi sa podacima**
      - čvorovi na kojima se skladište blokovi sa podacima
      - po zahtevu imenskog čvora, čitaju i pišu blokove u trajnu memoriju

62

62

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osnovni koncepti
  - **imenski čvorovi i čvorovi sa podacima**
    - bez imenskog čvora HDFS ne bi mogao da funkcioniše
    - gubitak računara sa imenskim čvorom bi značio gubitak svih datoteka
      - **ne postoji mogućnost rekonstruisanja registra pomoću čvorova sa podacima**
    - neophodno je obezbediti da perzistentni deo imenskog čvora bude što je moguće otporniji na otkaze
      - način 1: **paralelno zapisivanje meta-podataka na lokalni i udaljeni sistem datoteka** (upis podataka je atomična i sinhrona operacija)
      - način 2: **postojanje sekundarnog imenskog čvora**
        - nema ulogu imenskog čvora u arhitekturi već isključivo radi periodično prebacivanje zapisa iz loga izmena u sliku imenskog prostora
        - posebna mašina jer prebacivanje zapisa zahteva dosta vremena CPU-a
        - u slučaju otkaza gubitak podataka je siguran jer sekundarni čvor ima starije podatke od imenskog čvora

63

63

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osnovni koncepti
  - **klijenti** (engl. *clients*)
    - softverske komponente koje pristupaju podacima ili koriste usluge HDFS-a
    - mogu biti klijentski programi izvan Hadoop ekosistema
    - mogu biti MapReduce programi ili druge komponente Hadoop ekosistema

64

64

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osnovni koncepti
  - **HDFS federacija** (engl. *HDFS federation*)
    - dozvoljava skaliranje klastera dodavanjem novih imenskih čvorova
      - svaki imenski čvor se brine o posebnom delu sistema datoteka
        - imenski čvorovi ne komuniciraju međusobno
        - otkaz jednog čvora ne dovodi do otkaza drugih imenskih čvorova
        - skladište blokova **nije particionisano** i **deljeno je od strane svih imenskih čvorova**
      - npr. `/user` i `/share` mogu biti u nadležnosti različitih imenskih čvorova
    - porast broja datoteka dovodi do porasta broja zapisa u perzistentnom delu imenskog čvora
      - memorija imenskog čvora postaje ograničavajući faktor

65

65

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osnovni koncepti
  - **visok nivo dostupnosti HDFS-a** (engl. *high availability*)
    - čak i u slučaju paralelnog pisanja meta-podataka i postojanja sekundarnog imenskog čvora, imenski čvor predstavlja usko grlo sistema
      - otkazom imenskog čvora ceo sistem otkazuje dok administrator ne pokrene novi imenski čvor
        - što može i da potraje do 30 minuta na većim klasterima
      - dugotrajno pokretanje imenskog čvora ima posledice na **trajanje procesa održavanja sistema**
        - u praksi bitniji slučaj usled male verovatnoće otkaza imenskog čvora
    - potrebno omogućiti postojanje **paralelnih imenskih čvorova**
      - jedan u aktivnom stanju a drugi u stanju pripravnosti

66

66

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osnovni koncepti
  - **visok nivo dostupnosti HDFS-a – paralelni imenski čvorovi**
    - neophodno je da imenski čvorovi dele log izmena
      - kako bi mogli uvek rekonstruisati sliku imenskog prostora
    - svi čvorovi sa podacima šalju odgovore i izveštaje svim imenskim čvorovima
    - HDFS klijenti moraju biti konfigurisani sa parametrima koji im omogućavaju da vide oba imenska čvora i u slučaju otkaza izvrše preključivanje
    - u slučaju otkaza aktivnog čvora, čvor u pripravnosti postaje aktivni imenski čvor
      - nakon nekoliko desetina sekundi
        - usled posedovanja poslednje slike imenskog prostora
    - u slučaju otkaza oba čvora
      - potrebno je podići novi imenski čvor od nule
        - svodi se na slučaj bez paralelnih imenskih čvorova

67

67

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osnovni koncepti
  - **visok nivo dostupnosti HDFS-a**
    - **preuzimanje posla** (engl. *failover*)
      - može biti inicirano ručno, od strane administratora, ili automatski u slučaju otkaza aktivnog imenskog čvora
        - prebacivanje sa aktivnog na čvor u pripravnosti je zaduženje **kontrolera za preuzimanje posla** (engl. *failover controller*)
    - **ograđivanje** (engl. *fencing*)
      - u slučaju automatskog preuzimanja posla potrebno je osigurati se da je aktivni imenski čvor otkazao
        - a ne samo da nije privremeno dostupan zbog mrežnih problema
        - jer vraćanje aktivnog imenskog čvora u sistem koji nije svestan izmene statusa može imati velike posledice po konzistentnost sistema
      - čvoru u otkazu su uklonjena sva prava pristupa čvorovima sa podacima a procesu je poslat signal za zaustavljanje i prestanak rada sa mrežom

68

68

Distribuirani sistem datoteka Hadoop (HDFS)

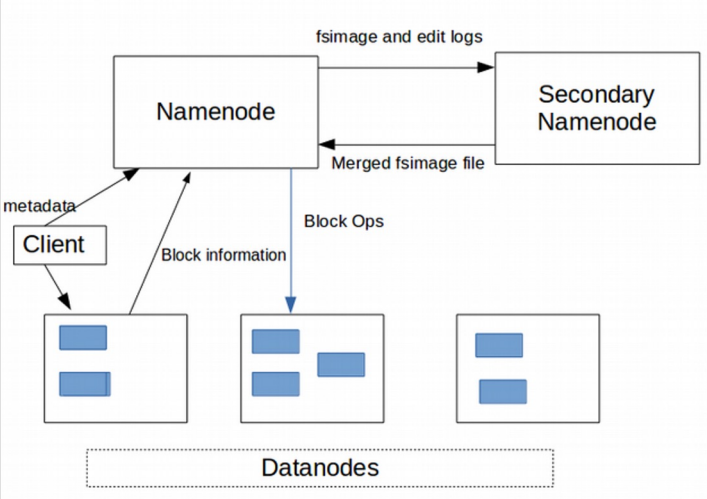

69

69

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osnovne naredbe
  - `hadoop fs <args>`
    - `hadoop fs -help`
      - za potpun spisak naredbi pogledati https://hadoop.apache.org/docs/r2.4.1/hadoop-project-dist/hadoop-common/FileSystemShell.html

```
% hadoop fs -copyFromLocal input/docs/test.txt hdfs://localhost/user/vdimitrieski/test.txt

% hadoop fs -copyToLocal hdfs://localhost/user/vdimitrieski/test.txt test.copy.txt
% md5 input/docs/test.txt test.copy.txt
MD5 (input/docs/test.txt) = a16f231da6b05e2ba7a339320e7dacd9
MD5 (test.copy.txt) = a16f231da6b05e2ba7a339320e7dacd9

% hadoop fs -mkdir books
% hadoop fs -ls .
Found 2 items
drwxr-xr-x - tom supergroup 0 2009-04-02 22:41 /user/vdimitrieski/books
-rw-r--r-- 1 tom supergroup 118 2009-04-02 22:29 /user/vdimitrieski/test.txt
```

70

70

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osnovni koncepti
  - **Hadoop apstrakcija sistema datoteka**
    - HDFS je samo jedna implementacija tzv. Hadoop sistema datoteka
    - moguće vršiti obradu nad bilo kojim sistemom datoteka
      - preporuka da se to radi samo nad sistemima koji podržavaju lokalizaciju obrade podataka
        - kao što je to slučaj sa HDFS-om

71

71

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osnovni koncepti
  - **Hadoop apstrakcija sistema datoteka**

Sistem datoteka	URI schema	Java Implementacija	Opis
Local	*file*	fs.LocalFileSystem	lokalni sistem datoteka
HDFS	*hdfs*	hdfs.DistributedFileSystem	HDFS
HFTP	*hftp*	hdfs.HftpFileSystem	omogućava samo čitanje iz HDFS sistema datoteka preko HTTP protokola
HSFTP	*hsftp*	hdfs.HsftpFileSystem	omogućava samo čitanje iz HDFS sistema datoteka preko HTTPS protokola
WebHDFS	*webhdfs*	hdfs.web.WebHdfsFileSystem	čitanje i pisanje u HDFS-u preko HTTP protokola. Zamena za HFTP i HSFTP

72

72

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osnovni koncepti
  - **Hadoop apstrakcija sistema datoteka**

Sistem datoteka	URI schema	Java Implementacija	Opis
HAR	*har*	fs.HarFileSystem	sistem za arhiviranje datoteka koji se implementira kao poseban sloj nad HDFS-om
KFS (CloudStore)	*kfs*	fs.kfs.KosmosFileSystem	CloudStore sistem datoteka (Google, C++)
FTP	*ftp*	fs.ftp.FTPFileSystem	sistem datoteka koji obuhvata FTP server
S3 (native)	*s3n*	fs.s3native.NativeS3FileSystem	sistem datoteka koji obuhvata Amazon S3 servis
S3 (block based)	*s3*	fs.s3.S3FileSystem	sistem datoteka koji obuhvata Amazon S3 servis ali smešta datoteke u blokovima kako bi se prevazišlo ograničenje od 5GB po datoteci

73

73

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - osnovni koncepti
  - **Hadoop apstrakcija sistema datoteka**

Sistem datoteka	URI schema	Java Implementacija	Opis
Distributed RAID	*hdfs*	hdfs.DistributedRaidFileSystem	sistem za arhiviranje datoteka koji se implementira kao HDFS sa podrškom za RAID
View	*viewfs*	viewfs.ViewFileSystem	obuhvata tabelu povezanih skladišta koja je implementirana na klijentskoj strani. Uobičajno korišćena za kreiranje HDFS federacije

74

74

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - pristup čvorovima
  - pristup preko HTTP protokola
    - direktan pristup
      - ugrađeni web server u imenskom čvoru
    - indirektan pristup
      - preko HTTP Proxy-ja
    - *slika desno*
  - pristup iz programskih jezika
    - Java, C
  - pristup iz bilo kog Unix OS-a
    - HDFS može biti zakačen kao bilo koji disk u UNIX sistemu

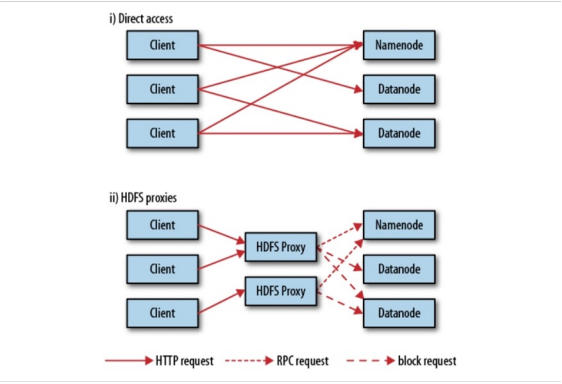

izvor: *Hadoop - The Definitive Guide, Tom White*

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - **čitanje podataka**
  - (1) otvaranje datoteke
  - (2) dobijanje lokacija blokova
    - imenski čvor vraća **najbližu** lokaciju sa blokom
  - (3-5) čitanje blok po blok
    - u redosledu u kojem blokovi sačinjavaju datoteku
  - u slučaju nemogućnosti komunikacije sa čvorom sa podacima
    - bira se **najbliži** alternativni čvor koji sadrži željeni blok

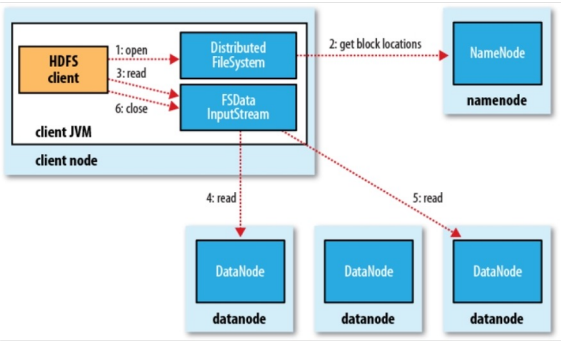

izvor: *Hadoop - The Definitive Guide, Tom White*

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - mrežna topologija
  - **blizina čvorova**
    - zapravo predstavlja brzinu i količinu podataka koja može biti razmenjena
  - u Hadoopu postoji stablo čvorova
    - distanca predstavlja sumu udaljenosti čvorova do zajedničkog pretka
  - distance(/d1/r1/n1, /d1/r1/n1) = 0
  - distance(/d1/r1/n1, /d1/r1/n2) = 2
  - distance(/d1/r1/n1, /d1/r2/n3) = 4
  - distance(/d1/r1/n1, /d2/r3/n4) = 6

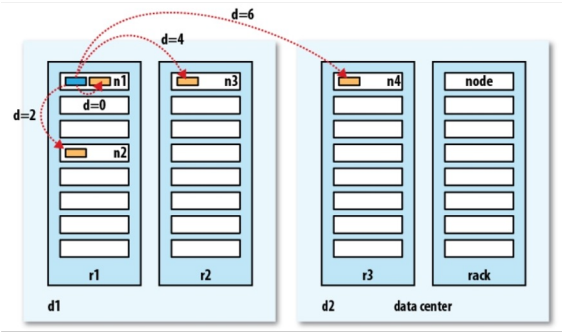

izvor: *Hadoop - The Definitive Guide, Tom White* 77

77

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - **pisanje podataka**
  - (1) iniciranje kreiranja datoteke
  - (2) kreiranje datoteke u imenskom čvoru
  - (3-5) slanje podataka za upis
    - podaci se dele na pakete i pored upisa repliciraju se na dodatne čvorove sa podacima
    - čvorovi obrazuju **lanac replikacije**
      - engl. *replication pipeline*
  - (6) nakon upisa zatvara se datoteka
  - (7) imenskom čvoru se šalje signal za završetak upisa

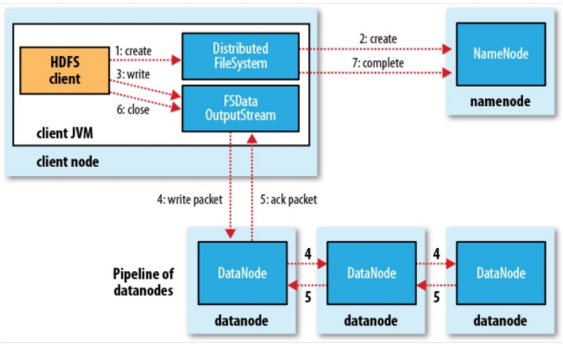

izvor: *Hadoop - The Definitive Guide, Tom White* 78

78

Distribuirani sistem datoteka Hadoop (HDFS)

- HDFS - pisanje podataka
  - odabir čvora za skladištenje replike zavisi od nekoliko faktora
    - brzina upisa i količina prenetih podataka
      - replike je potrebno postaviti što bliže kako bi se povećala brzina upisa podataka
    - otpornost na greške
      - replike je potrebno postaviti što dalje kako bi se smanjila mogućnost potpunog otkaza
  - Hadoop strategija
    - prva replika u isti čvor kao i original
    - druga replika se postavlja na drugi *rack*
    - treća replika na isti *rack* kao i druga ali u drugi slučajno odabrani čvor

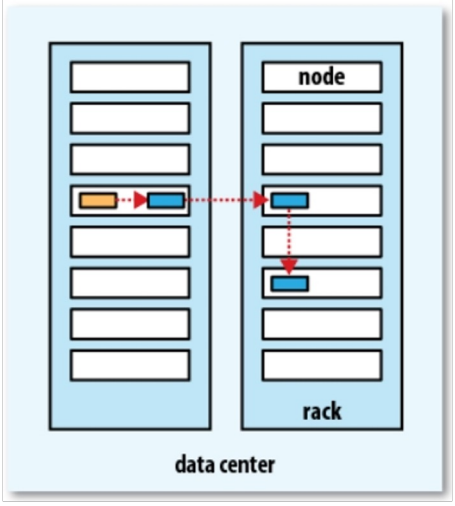

izvor: *Hadoop - The Definitive Guide, Tom White*

79

79

Hadoop I/O

- Hadoop I/O koncepti i primitive
  - predstavljaju softverske elemente koji koriste usluge HDFS-a
    - i nalaze se na višem nivou apstrakcije
  - koncepti koji su od posebnog značaja pri radu sa velikim količinama podataka i velikim datotekama od više terabajta
  - koncepti nezavisni od Hadoop-a
    - **integritet podataka** (engl. *data integrity*)
    - **kompresija** (engl. *compression*)
  - koncepti sa specifičnom Hadoop implementacijom
    - **radni okviri za serijalizaciju** (engl. *serialization frameworks*)
    - **strukture podataka na disku** (engl. *on-disk data structures*)

80

80

Hadoop I/O

- **Integritet podataka**
  - pisanje podataka u sistem datoteka nosi sa sobom rizik od pojave grešaka i oštećenih podataka
    - što je veća količina upisanih podataka i rizik je veći
  - računanje kontrolne sume (engl. *checksum*)
    - uobičajeni način za identifikaciju oštećenja u snimljenim podacima
      - detekcija ali ne i oporavak od grešaka
      - često korišćen algoritam CRC-32 (engl. *Cyclic Redundancy Check*)
        - sračunava 32 bitni integer na osnovu ulaznih podataka bilo koje veličine
    - **računa se prvi put kada se podaci snime** u sistem datoteka
    - **računa se svaki naredni put kada se podaci čitaju**

81

81

Hadoop I/O

- Integritet podataka - HDFS
  - u HDFS-u se kontrolna suma izračunava u pozadini, bez eksplicitnog zahtevanja od strane korisnika
    - **prilikom svakog upisa podataka**
    - zbog male veličine podataka koji predstavljaju kontrolnu sumu, **manje od 1%** podataka obuhvata kontrolne sume
    - čvorovi sa podacima su zaduženi za proveru podataka koje skladište
      - bilo da su podaci direktno upisani ili primljeni usled replikacije
      - čvor koji je **poslednji u replikacionom lancu proverava kontrolnu sumu**
      - čvorovi čuvaju istoriju provere kontrolne sume za svaki podatak
        - izuzetno bitno za detekciju kvarova na disku
  - kontrolna suma se proverava **prilikom svakog čitanja podataka**
    - klijenti koji čitaju podatke proveravaju kontrolnu sumu
      - poredeći je sa kontrolnom sumom skladištenom na čvoru sa podacima

82

82

Hadoop I/O

- Integritet podataka - HDFS
  - u HDFS-u moguća je ispravka grešaka u podacima
    - povlačenjem jedne od replikacionih kopija sa drugih čvorova sa podacima
      - **ne prevlači se na čvor na kojem je otkrivena greška već se podaci repliciraju na novi čvor** (ili čvorove) da bi predefinisani broj validnih replika bio ponovo tačan
      - originalni oštećeni blok sa podacima se briše iz čvora
        - ažuriraju se zapisi u imenskom čvoru
  - moguće je isključiti proveru kontrolne sume prilikom čitanja podataka
    - korisno ukoliko imamo oštećene blokove i želimo da vidimo šta se može spasiti od podataka pre nego što se blok obriše

83

83

Hadoop I/O

- Kompresija - Hadoop kodeci
  - Kodek (engl. *codec*)
    - skraćeno od kompresija-dekompresija
    - predstavljaju implementaciju algoritama za kompresiju i dekompresiju

Compression format	Hadoop CompressionCodec
DEFLATE	org.apache.hadoop.io.compress.DefaultCodec
gzip	org.apache.hadoop.io.compress.GzipCodec
bzip2	org.apache.hadoop.io.compress.BZip2Codec
LZO	com.hadoop.compression.lzo.LzopCodec
LZ4	org.apache.hadoop.io.compress.Lz4Codec
Snappy	org.apache.hadoop.io.compress.SnappyCodec

84

84

Hadoop I/O

- Kompresija i MapReduce paketi
  - podrška kompresionog formata za MapReduce se ogleda u podršci za **razdvajanje kompresovane datoteke**
    - razdvajanje podrazumeva podelu kompresovane datoteke na delove kod kojih je moguće dekompresovati svaki deo pojedinačno
  - razdvajanje omogućava da MapReduce čita pojedine kompresovane blokove
    - bez ponovnog kreiranja cele datoteke
  - u slučaju nedostatka podrške razdvajanju
    - MapReduce zadatak mora dobaviti sve blokove iz svih čvorova sa podacima
      - koji ne moraju biti smešteni isti čvor na kojem se izvršava zadatak niti moraju biti u istom *rack*-u

85

85

Hadoop I/O

- Kompresija - uputstva (sortirana po efikasnosti)
  - koristiti strukture podataka na disku koje omogućavaju kompresiju i razdvajanje i zatim iskoristiti neki od bržih kompresionih algoritama
    - npr. LZO, LZ4, Snappy
  - koristiti kompresioni format koji podržava razdvajanje
    - npr. bzip2 - inače spor algoritam
    - neophodno za velike fajlove
      - jer su inače MapReduce zadaci neefikasni
  - aplikativno podeliti datoteke na delove koji se mogu nezavisno kompresovati
    - kompresovani delovi bi trebalo da su veličine HDFS bloka
  - ne koristiti kompresiju

86

86

Hadoop I/O

- **Serijalizacija** - Hadoop
  - Hadoop serijalizacioni format - **Writeable** interfejs
    - kojeg nasleđuju sve konkretne klase čije objekte je moguće serijalizovati
    - moguće kreirati svoju klasu koja implementira interfejs

```
import java.io.DataOutput;
import java.io.DataInput;
import java.io.IOException;
public interface Writable {
  void write(DataOutput out) throws IOException;
  void readFields(DataInput in) throws IOException;
}
```

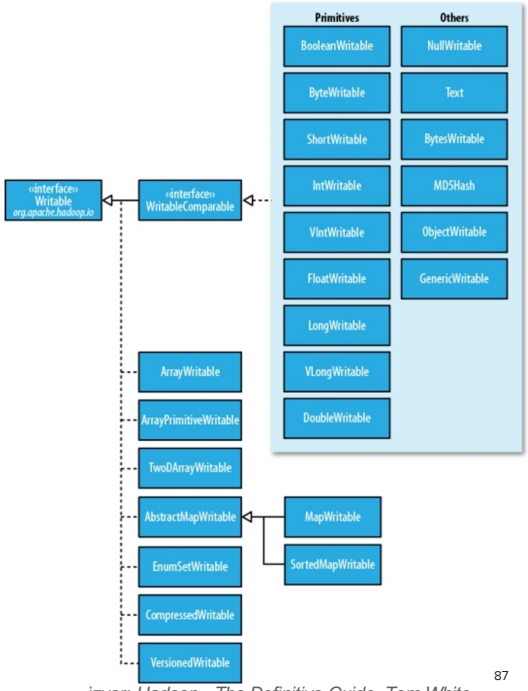

izvor: *Hadoop - The Definitive Guide, Tom White*

87

87

Hadoop I/O

- Radni okviri za serijalizaciju
  - iako MapReduce podržava Writeable implementaciju sa radnim okvirom **WritableSerialization**
    - nije neophodno koristiti Hadoop-ov sistem za serijalizaciju
    - moguće je koristiti bilo koji drugi radni okvir
      - **JavaSerialization** - podržava standardnu Java serijalizaciju objekata što omogućava korišćenje standardnih Java tipova podataka
        - ne zadovoljava poželjne karakteristike serijalizacionih formata
          - stoga nije često korišćena
      - **Apache Avro** - serijalizacioni format koji je nezavisan od programskog jezika
        - omogućava portabilnost između programskih jezika
        - moguće je serijalizovati podatke u binarni ili JSON oblik

88

88

Hadoop I/O

- **Strukture podataka na disku**
  - za neke primene potrebno je podatke organizovati u strukture podataka na disku
    - umesto čuvanja u nestrukturiranim datotekama
    - omogućava bolje skaliranje podataka
  - Hadoop podržava nekoliko tipova struktura podataka
    - **SequenceFile** - sekvencijalna datoteka
    - **MapFile** - indeks-sekvencijalna datoteka

89

89

Hadoop I/O

- Strukture podataka na disku - SequenceFile
  - svaki red u datoteci predstavlja jedan zapis
    - par ključ/vrednost
  - jedna od upotreba jeste smeštanje malih datoteka u veće sekvencijalno organizovane datoteke
    - na taj način se bolje koriste prednosti sistema Hadoop
  - spajanje i sortiranje sekvencijalno organizovanih datoteka
    - se najčešće radi pomoću MapReduce programa

90

90

Hadoop I/O

- Strukture podataka na disku - SequenceFile

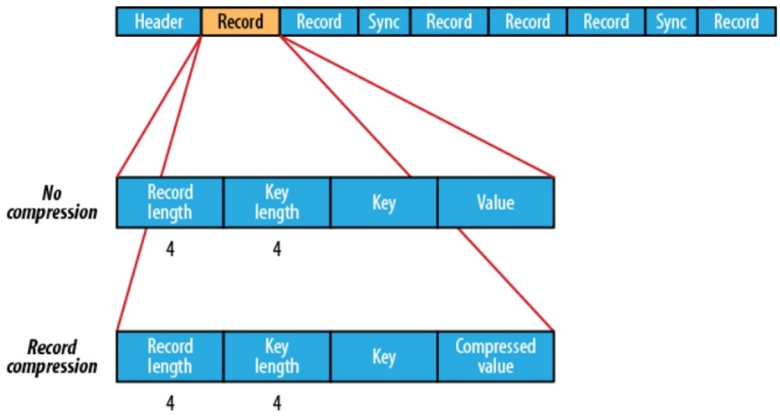

izvor: *Hadoop - The Definitive Guide, Tom White* 91

91

Hadoop I/O

- Strukture podataka na disku - SequenceFile sa kompresijom blokova

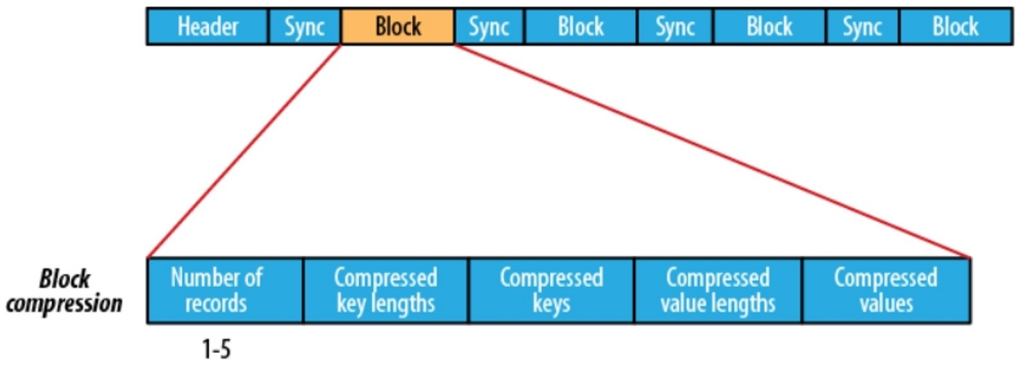

izvor: *Hadoop - The Definitive Guide, Tom White* 92

92

Hadoop I/O

- Strukture podataka na disku - MapFile
  - indeks-sekvencijalna datoteka
    - obuhvata po ključu sortirane slogove
    - sadrži indeks nad ključem da bi omogućila direktan pristup slogovima
  - postoje različite varijante
    - **SetFile** - sadrži skup ključeva koji implementiraju Writeable interfejs
      - ključevi moraju biti dodati u sortiranom redosledu
    - **ArrayFile** - ključ je integer a vrednost implementira Writeable interfejs
    - **BloomMapFile** - poseduje veoma brzu `get()` metodu
      - koristi *bloom* filter za utvrđivanje da li je ključ u datoteci ili ne
        - probabilistički filter
        - https://en.wikipedia.org/wiki/Bloom_filter

93

93

Distribuirana obrada podataka (MapReduce)

94

Obrada podataka - primer

- Analiza meteoroloških podataka
  - *National Climatic Data Center* (NCDC, http://www.ncdc.noaa.gov/)
    - svako merenje je tekstualna datoteka u kojoj je svaki red novi zapis o meteorološkim parametrima
      - organizovane po datumu i stanici na kojoj je merenje izvršeno
        - podaci su grupisani po godini zbog lakše obrade
    - postoji struktura koji podaci prate
      - sa mnogo opcionih delova

```
0057
332130       # USAF weather station identifier
99999        # WBAN weather station identifier
19500101     # observation date
0300         # observation time
4
+51317       # latitude (degrees x 1000)
+028783      # longitude (degrees x 1000)
FM-12
+0171        # elevation (meters)
99999
V020
320          # wind direction (degrees)
1            # quality code
N
0072
1
00450        # sky ceiling height (meters)
1            # quality code
CN
010000       # visibility distance (meters)
1            # quality code
N9
-0128        # air temperature (degrees Celsius x 10)
1            # quality code
-0139        # dew point temperature (degrees Celsius x 10)
1            # quality code
10268        # atmospheric pressure (hectopascals x 10)
1            # quality code
```

95

Obrada podataka - primer

- Analiza meteoroloških podataka - Unix alati
  - upit za pronalaženje najviše godišnje temperature za svaku godinu u skupu podataka
    - moguće izvršiti pomoću standardnih Unix programa i alata
      - na nedistribuiranom sistemu
    - sa porastom količine podataka raste i vreme izvršavanja skripte

```
#!/usr/bin/env bash
for year in all/*
do
       echo -ne `basename $year .gz`"\t"
       gunzip -c $year | \
              awk '{ temp = substr($0, 88, 5) + 0;
                     q = substr($0, 93, 1);
                     if (temp !=9999 && q ~ /[01459]/ &&
                           temp > max) max = temp }
              END { print max }'
done


## test run ##
% ./max_temperature.sh
1901 317
1902 244
1903 289
1904 256
1905 283
...
```

96

96

Obrada podataka - primer

- Analiza meteoroloških podataka - Unix alati
  - potreban mehanizam za paralelno izvršavanje skripte
    - idealno, podelili bismo skup podataka po godini i pokrenuli skriptu više puta
      - svaki od procesa bi se izvršavao paralelno (paralelna obrada)
  - postoje tri problema sa ovim pristupom
    - ujednačena podela inicijalnog skupa je teška
      - različite godine imaju različit broj merenja i samim tim različite količine podataka
      - vreme obrade podataka i opterećenje resursa zavisi od najveće datoteke
      - moguće deliti i po veličini podataka a ne po godini
    - objedinjavanje rezultata obrade može zahtevati dodatnu obradu
      - potrebna koordinacije procesa ukoliko ne delimo po godini već po veličini
    - još uvek smo ograničeni kapacitetima jednog računara
      - na kojem se izvršavaju procesi
  - korišćenje više računara otvara nove probleme
    - mahom u domenu koordinacije procesa i obezbeđivanja pouzdanosti

97

97

MapReduce

- MapReduce
  - predstavlja pristup pisanju programa za obradu podataka
    - jednostavan a ekspresivan pristup
    - ne zavisi od konkretnog programskog jezika
    - inherentno podržava paralelizam u izvršavanju napisanih programa
  - obrada podataka je implementirana kroz dva različita tipa operatora
    - **operatori *map* i *reduce***
    - ulazni i izlazni podaci su predstavljeni kroz parove ključ-vrednost
      - čiju semantiku i značenje bira sam programer
    - potpis funkcija *map* i *reduce*
      - `map: (K1, V1) → list(K2, V2)`
      - `reduce: (K2, list(V2)) → list(K3, V3)`

98

98

MapReduce - primer

- Analize meteoroloških podataka - MapReduce
  - ulaz predstavljaju redovi iz datoteka za koje je ključ redni broj reda
    - ključ nije relevantan za ovaj slučaj
  - operator *map* služi za izvlačenje relevantnih podataka
    - godina i temperatura
  - operator *map* služi i za uklanjanje nepotpunih podataka

```
#input data
(0,  0067011990999991950051507004...9999999N9+00001+99999999999...)
(106,0043011990999991950051512004...9999999N9+00221+99999999999...)
(212,0043011990999991950051518004...9999999N9-00111+99999999999...)
(318,0043012650999991949032412004...0500001N9+01111+99999999999...)
(424,0043012650999991949032418004...0500001N9+00781+99999999999...)

#output data
(1950, 0)
(1950, 22)
(1950, -11)
(1949, 111)
(1949, 78)
```

99

MapReduce - primer

- Analize meteoroloških podataka - MapReduce
  - MapReduce okruženje grupiše rezultate izvršenja operatora *map* po ključu
    - pre slanja operatoru *reduce*
  - operator *reduce* kao ulaz dobija listu temperatura za neku godinu
    - prolazeći kroz listu pronalazi najvišu temperaturu

```
#grouped data / reducer input
(1949, [111, 78])
(1950, [0, 22, -11])


#final output data / reducer output
(1949, 111)
(1950, 22)
```

100

MapReduce - primer

- Analize meteoroloških podataka - MapReduce
  - dijagram aktivnosti prethodno opisanog programa MapReduce

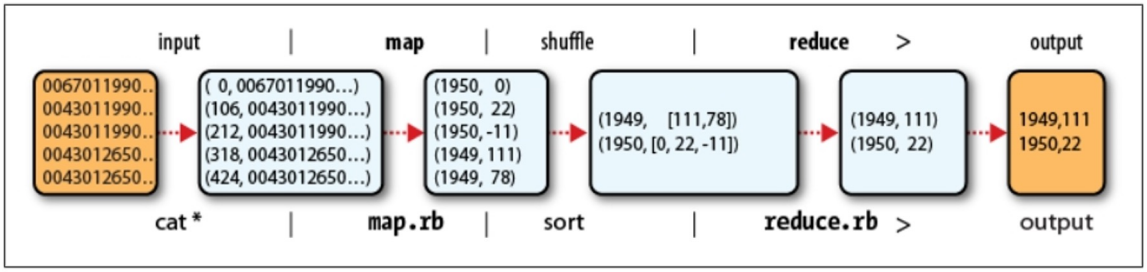

izvor: *Hadoop - The Definitive Guide, Tom White*

101

101

MapReduce

- MapReduce i programski jezici
  - paradigma je nezavisna od programskog jezika
  - podržana u više programskih jezika
    - Java, Python, Scala, itd.
  - Hadoop je implementiran u programskom jeziku Java
    - moguće koristiti bez značajnog povišenja kompleksnosti i u drugim programskim jezicima
      - postoji API nazvan Hadoop Streaming
        - koji omogućava pristup iz drugih programskih jezika
    - stoga preporuka da se i MapReduce piše u istom jeziku
      - smanjuje kompleksnost (iako neznatnu) izazvanu razlikama u programskim jezicima
      - obično je preporuka da se programi pišu u jezicima u kojima je napisan i radni okvir
        - npr. Hadoop - Java ili Spark - Scala

102

102

MapReduce - primer

- Analize meteoroloških podataka - MapReduce i Java (funkcije *map* i *reduce*)

```
import java.io.IOException;
import org.apache.hadoop.io.IntWritable;
import org.apache.hadoop.io.LongWritable;
import org.apache.hadoop.io.Text;
import org.apache.hadoop.mapreduce.Mapper;
public class MaxTemperatureMapper
    extends Mapper<LongWritable, Text, Text, IntWritable> {
  private static final int MISSING = 9999;
  @Override
  public void map(LongWritable key, Text value, Context context)
    throws IOException, InterruptedException {
    String line = value.toString();
    String year = line.substring(15, 19);
    int airTemperature;
    if (line.charAt(87) == '+') { // parseInt doesn't like leading plus
      airTemperature = Integer.parseInt(line.substring(88, 92));
    } else {
      airTemperature = Integer.parseInt(line.substring(87, 92));
    }
    String quality = line.substring(92, 93);
    if (airTemperature != MISSING && quality.matches("[01459]")) {
      context.write(new Text(year), new IntWritable(airTemperature));
    }
  }
}
```

```
import java.io.IOException;
import org.apache.hadoop.io.IntWritable;
import org.apache.hadoop.io.Text;
import org.apache.hadoop.mapreduce.Reducer;
public class MaxTemperatureReducer
    extends Reducer<Text, IntWritable, Text, IntWritable> {
  @Override
  public void reduce(Text key, Iterable<IntWritable> values,
      Context context) throws IOException, InterruptedException {
    int maxValue = Integer.MIN_VALUE;
    for (IntWritable value : values) {
      maxValue = Math.max(maxValue, value.get());
    }
    context.write(key, new IntWritable(maxValue));
  }
}
```


MapReduce - primer

- Analize meteoroloških podataka - MapReduce i Java (funkcija za pokretanje)

```
import org.apache.hadoop.fs.Path;
import org.apache.hadoop.io.IntWritable;
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 MaxTemperature {
  public static void main(String[] args) throws Exception {
    if (args.length != 2) {
      System.err.println("Usage: MaxTemperature <input path> <output
        path>");
      System.exit(-1);
    }
    Job job = new Job();
    job.setJarByClass(MaxTemperature.class);
    job.setJobName("Max temperature");
    FileInputFormat.addInputPath(job, new Path(args[0]));
    FileOutputFormat.setOutputPath(job, new Path(args[1]));
    job.setMapperClass(MaxTemperatureMapper.class);
    job.setReducerClass(MaxTemperatureReducer.class);
    job.setOutputKeyClass(Text.class);
    job.setOutputValueClass(IntWritable.class);
    System.exit(job.waitForCompletion(true) ? 0 : 1);
  }
}
```

Hadoop I/O

- Kompresija
  - primer pokretanja MapReduce programa čiji je rezultat kompresovan

```
import org.apache.hadoop.fs.Path;
import org.apache.hadoop.io.IntWritable;
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;
import org.apache.hadoop.io.compress.GzipCodec
public class MaxTemperatureWithCompression {
  public static void main(String[] args) throws Exception {
    if (args.length != 2) {
      System.err.println("Usage: MaxTemperatureWithCompression " +
        "<input path> <output path>");
      System.exit(-1);
    }
    Job job = new Job();
    job.setJarByClass(MaxTemperature.class);
    FileInputFormat.addInputPath(job, new Path(args[0]));
    FileOutputFormat.setOutputPath(job, new Path(args[1]));
    job.setOutputKeyClass(Text.class);
    job.setOutputValueClass(IntWritable.class);
    FileOutputFormat.setCompressOutput(job, true);
    FileOutputFormat.setOutputCompressorClass(job, GzipCodec.class);
    job.setMapperClass(MaxTemperatureMapper.class);
    job.setCombinerClass(MaxTemperatureReducer.class);
    job.setReducerClass(MaxTemperatureReducer.class);
    System.exit(job.waitForCompletion(true) ? 0 : 1);
  }
}
```


MapReduce

- MapReduce i RDBMS
  - paketna / pojedinačna obrada
  - nestrukturirani / strukturirani podaci
  - denormalizovani / normalizovani podaci

	Traditional RDBMS	MapReduce
Data size	Gigabytes	Petabytes
Access	Interactive and batch	Batch
Updates	Read and write many times	Write once, read many times
Structure	Static schema	Dynamic schema
Integrity	High	Low
Scaling	Nonlinear	Linear

izvor: *Hadoop - The Definitive Guide, Tom White*

MapReduce

- MapReduce - osnovni pojmovi
  - **posao** (engl. *job*)
    - osnovna jedinica obrade
    - sastoji se od ulaznih podataka, MapReduce programa i konfiguracije
  - **zadatak** (engl. *task*)
    - Hadoop deli svaki posao na zadatke
    - dva tipa zadatka: **zadatak *map*** i **zadatak *reduce***
      - implementiraju operacije *map* i *reduce*
  - **izvršni čvorovi** (engl. *execution nodes*)
    - čvorovi u distribuiranom sistemu koji kontrolišu izvršenje poslova
    - jedan čvor **upravljač poslovima** (engl. *jobtracker*)
      - upravlja izvršenjem svih poslova i raspoređuje zadatke na čvorove za upravljanje zadacima
    - više čvorova **upravljača zadacima** (engl. *tasktracker*)
      - izvršavaju prosleđene zadatke i šalju informacije o statusu izvršavanju (napretku)

107

107

MapReduce

- MapReduce - osnovni pojmovi
  - **paket** (engl. *input split / split*)
    - deo ulaznih podataka koji predstavlja osnovnu jedinicu obrade u zadacima
    - Hadoop kreira jedan zadatak za svaki paket koji je potrebno obraditi
      - radi paralelizacije obrade podataka
    - uvek je tačno definisane veličine (podrazumevano 64MB/128MB)
      - obično je jednaka veličini bloka u kojem su podaci uskladišteni (HDFS)
      - moguće je ručno podesiti veličinu paketa
      - premali paket - potrebno previše vremena za logistiku
      - preveliki paket - najsporiji računar prouzrokuje veliki zastoj u celokupnoj obradi
  - **slog** (engl. *record*)
    - deo paketa, pojedinačni zapis u paketu
    - nad svakim slogom u paketu se primenjuje *map* operacija

108

108

MapReduce

- MapReduce - osnovni pojmovi
  - **lokalizacija obrade podataka** (engl. *data locality optimization*)
    - Hadoop pokušava obraditi podatke u onim čvorovima u kojim su podaci skladišteni
      - ukoliko to nije moguće pribegava se izvršenju na drugim, dostupnim čvorovima
    - odnosi se na obradu u operaciji *map*
      - koja preuzima podatke iz distribuiranog sistema datoteka
    - tri mogućnosti izvršavanja zadataka
      - **lokalno izvršavanje zadataka** (engl. *data-local task execution*)
        - izvršavanje na čvoru na kojem se nalaze podaci
      - **izvršavanje unutar *rack*-a** (engl. *rack-local task execution*)
        - izvršavanje na čvoru koji se fizički nalazi unutar smeštajne jedinice za računare (*rack*-a)
      - **globalno izvršavanje** (engl. *off-rack task execution*)
        - izvršavanje na čvoru koji se nalazi unutar klastera ali nije u okviru istog *rack*-a

109

109

MapReduce

- MapReduce - osnovni pojmovi
  - a) lokalno izvršavanje zadataka
  - b) izvršavanje unutar *rack*-a
  - c) globalno izvršavanje
  - veličina paketa je obično jednaka veličini HDFS bloka
    - radi smanjenja saobraćaja i povišenja performansi obrade

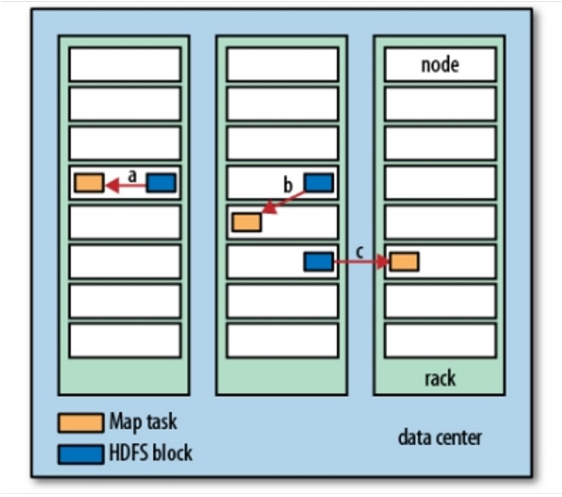

izvor: *Hadoop - The Definitive Guide, Tom White*

110

110

MapReduce

- MapReduce - osnovni pojmovi
  - lokalizacija obrade podataka
    - **ne odnosi se na obradu u zadatku *reduce***
      - pošto preuzima podatke koji su rezultat zadatka *map* a koji su smešteni lokalno u čvorovima u kojima se taj zadatak i izvršava
        - ne smeštaju se u distribuirani sistem datoteka
      - pošto se podaci preuzimaju od više zadataka *map*
        - koji se ne moraju izvršavati na istom čvoru
  - rezultati obrade podataka u okviru zadatka *reduce*
    - obično se smeštaju u distribuirani sistem datoteka
      - radi obezbeđenja pouzdanosti i redundanse podataka

111

111

MapReduce

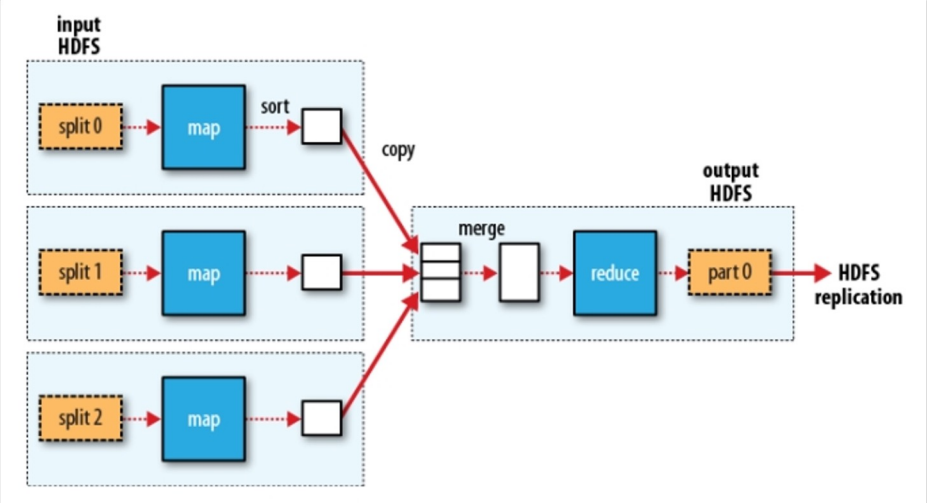

izvor: *Hadoop - The Definitive Guide, Tom White*

112

112

MapReduce

- MapReduce - osnovni pojmovi
  - broj zadataka *reduce* nije uslovljen veličinom ulaznog skupa podataka
    - već predstavlja parametar koji se posebno može podešavati
  - **particije** (engl. *partitions*)
    - skupovi podataka koji predstavljaju ulazne podatke za zadatak *reduce*
      - sačinjeni od izlaznih podataka iz zadatka *map*
    - može sadržavati više ključeva
      - ali svi slogovi koji pripadaju istom ključu moraju se naći u jednoj particiji
    - uobičajeno se koristi ugrađena funkcija za particionisanje
      - zasnovana na izračunavanju *hash* funkcije nad ključem
      - moguće implementirati i koristiti korisnički definisanu funkciju za particionisanje
  - **raspodela podataka** (engl. *shuffle*)
    - obuhvata razmenu podataka između čvorova sa zadatkom *map* i zadatkom *reduce*
    - može biti izuzetno kompleksna i imati veliki uticaj na performanse celokupnog sistema

113

113

MapReduce

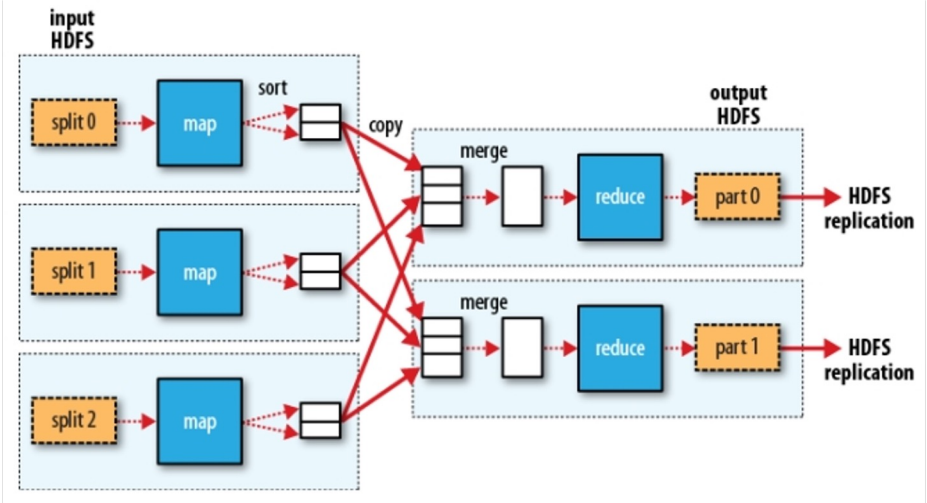

izvor: *Hadoop - The Definitive Guide, Tom White*

114

114

MapReduce

- MapReduce - osnovni pojmovi
  - postoje MapReduce programi bez zadatka *reduce*
    - ukoliko celokupna obrada podataka može biti izvršena paralelno
    - u okviru zadatka *map* izlazni podaci se snimaju u distribuirani sistem datoteka
    - npr. simulacije nad parametrima
      - ulaz: parametri za simulaciju
      - zadatak *map* obuhvata implementaciju simulacije
        - koja se izvršava veliki broj puta nad ulaznim parametrima
      - izlaz: rezultat simulacije
    - npr. učitavanje podataka iz različitih izvora podataka
      - ulaz: lista izvora podataka
      - po jedan zadatak *map* se može izvršiti za svaki izvor podataka
      - izlaz: dobavljeni podaci iz izvora podataka

115

115

MapReduce

- MapReduce programi bez zadatka *reduce*

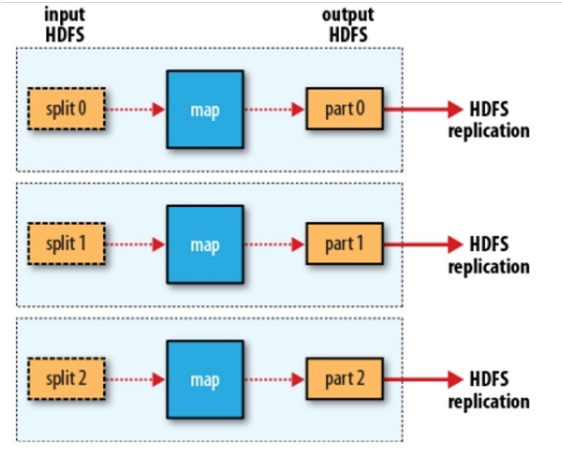

izvor: *Hadoop - The Definitive Guide, Tom White*

116

116

MapReduce

- MapReduce - osnovni pojmovi
  - unapređenje performansi uvođenjem paralelizacije ograničeno je propusnošću mrežne infrastrukture kojom su čvorovi povezani
    - teži se smanjenju obima podataka koji se razmenjuju između čvorova
      - npr. između čvorova sa zadatkom *map* i zadatkom *reduce*
  - **funkcija za kompakciju podataka** (engl. *combiner function*)
    - funkcija koja vrši optimizaciju količine podataka koja se razmenjuje preko mreže
      - predstavlja optimizaciju, pa Hadoop ne garantuje koliko će puta biti izvršena
      - neophodno je da bude idempotentna
        - da za isti ulaz uvek daje isti izlaz
      - ograničava broj funkcija koje je moguće iskoristiti
        - **komutativne i asocijativne funkcije** (često nazvane i **distributivne**)
        - npr. `max()` je moguće dok `mean()` nije
    - izvršava se nad podacima koji predstavljaju izlaz iz zadatka *map*
      - rezultat izvršenja predstavlja ulaz za zadatak *reduce*

117

117

MapReduce - primer

- Analize meteoroloških podataka - MapReduce
  - **funkcija za kompakciju podataka**
    - obuhvata kompakciju izlaza iz svakog zadatka *map*
      - ne menja funkciju *reduce* već samo smanjuje količinu podataka koja se šalje preko mreže
    - max(0, 20, 10, 25, 15)
      = max(max(0, 20, 10), max(25, 15))
      = max(20, 25)
      = 25

```
#split 1 / map 1 output
(1950, 0)
(1950, 20)
(1950, 10)

#split 2 / map 2 output
(1950, 25)
(1950, 15)

----------------------------
#reducer without combiner function
(1950, [0, 20, 10, 25, 15]) #input
(1950, 25)                  #output

----------------------------
#combiner outputs
(1950, 20)                  #for map1
(1950, 25)                  #for map2

#reducer with combiner function
(1950, [20, 25])            #input
(1950, 25)                  #output
```

118

118

MapReduce - primer

- Analize meteoroloških podataka - MapReduce i Java (funkcija za pokretanje)
  - implementacija funkcije za kompakciju podataka je identična implementaciji funkcije *reduce*

```
import org.apache.hadoop.fs.Path;
import org.apache.hadoop.io.IntWritable;
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 MaxTemperature {
  public static void main(String[] args) throws Exception {
    if (args.length != 2) {
      System.err.println("Usage: MaxTemperature <input path> <output
        path>");
      System.exit(-1);
    }
    Job job = new Job();
    job.setJarByClass(MaxTemperature.class);
    job.setJobName("Max temperature");
    FileInputFormat.addInputPath(job, new Path(args[0]));
    FileOutputFormat.setOutputPath(job, new Path(args[1]));
    job.setMapperClass(MaxTemperatureMapper.class);
    job.setCombinerClass(MaxTemperatureReducer.class);
    job.setReducerClass(MaxTemperatureReducer.class);
    job.setOutputKeyClass(Text.class);
    job.setOutputValueClass(IntWritable.class);
    System.exit(job.waitForCompletion(true) ? 0 : 1);
  }
}
```

119

119

MapReduce - verzije

- MapReduce 1
  - koristi servise *JobTracker* i *TaskTracker*
    - za upravljanje izvršavanjem poslova
    - nisu pogodni za skaliranje
      - jedan *JobTracker* je zadužen za pokretanje svih MapReduce poslova
  - zauzima resurse fiksne veličine za izvršenje poslova
    - resursi se dele na *map* resurse i *reduce* resurse
      - dodeljene samo odgovarajućim zadacima bez mogućnosti dinamičke izmene
- MapReduce 2
  - koristi YARN (engl. *Yet Another Resource maNager*) za upravljanje resursima
    - dinamička alokacija i upravljanje resursima (ne oslanja se na *JobTracker* i *TaskTracker*)
  - omogućava pokretanje i drugih programa osim MapReduce na Hadoop klasteru

120

120

MapReduce - izvršavanje

- Pokretanje MapReduce posla
  - pozivom metoda nad objektom `job`
    - `submit()` ili `waitForCompletion()`
  - potrebno je prethodno izvršiti konfiguraciju Hadoop klastera
    - nekolicina parametara iz konfiguracione datoteke utiče direktno i na izvršavanje MapReduce programa
      - npr. `mapreduce.framework.name property`
        - `local` - za poslove koji se izvršavaju u lokalu
        - `classic` - za poslove koji se izvršavaju u skladu sa verzijom MapReduce 1
        - `yarn` - za poslove koji se izvršavaju u skladu sa verzijom MapReduce 2
          - na YARN upravljaču resursima

121

121

MapReduce 1

- Istorijski prvi MapReduce radni okvir
  - složenije i manje dinamički kreirano okruženje
  - dovodi do pojave uskog grla izvršavanja zadataka

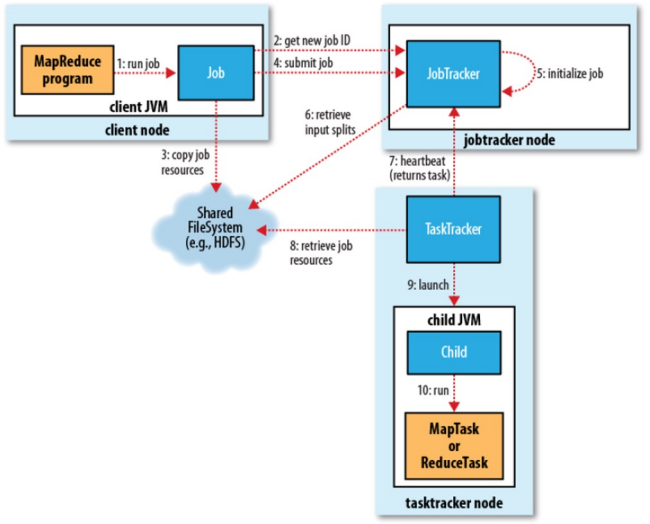

izvor: *Hadoop - The Definitive Guide, Tom White*

122

122

MapReduce 1

- MapReduce periodično vraćaju obaveštenje o trenutnom statusu obrade
  - interno se prati u kojoj se fazi trenutno obrada nalazi (*sort*, *shuffle*, *reduce*...)

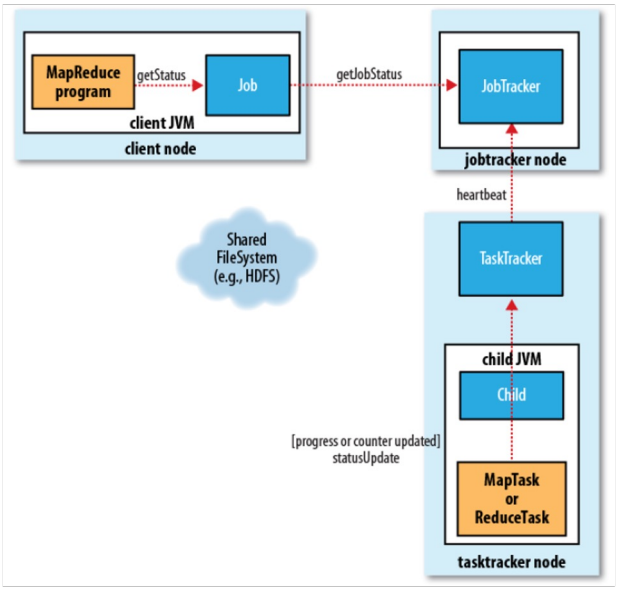

izvor: *Hadoop - The Definitive Guide, Tom White*

123

123

MapReduce 2

- YARN
  - napravljen u Yahoo! kao odgovor na mane i nemogućnost skaliranja zadataka u slučajevima velikog broja čvorova
  - deli zaduženja *JobTracker* procesa
    - umesto da jedan proces vodi računa o dodeli resursa i o praćenju napretka izvršavanja zadataka
    - postoje dva procesa
      - upravljač resursima (engl. *resource manager*)
      - upravljač aplikacijama (engl. *application manager*)
  - omogućava izvršavanje i drugih aplikacija na klasteru a ne samo MapReduce
    - npr. distribuirana konzola za pokretanje skriptova na više čvorova u klasteru, MPI aplikacija, itd.

124

124

MapReduce 2

- MapReduce 2 i YARN upravljač resursima

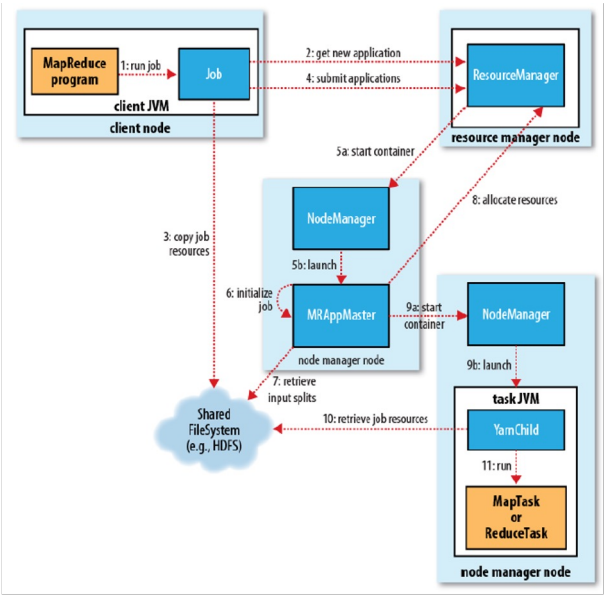

izvor: *Hadoop - The Definitive Guide, Tom White* 125

125

MapReduce 2

- MapReduce periodično vraćaju obaveštenje o trenutnom statusu obrade

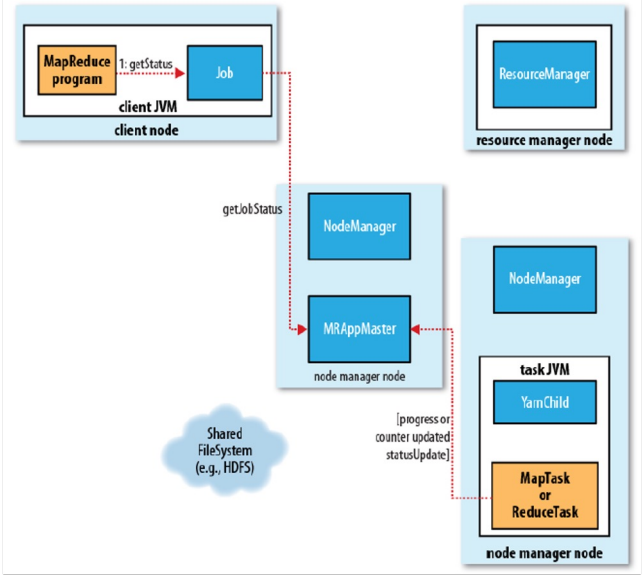

izvor: *Hadoop - The Definitive Guide, Tom White* 126

126

Raspoređivanje poslova

- Raspoređivanje poslova (engl. *job scheduling*)
  - u početku, raspoređivanje je bilo predodređeno vremenom kreiranja posla
    - FIFO raspoređivač
    - čak i sa kasnijim dodatkom prioriteta poslovima dugotrajni spori proces je blokirao prioritetnije poslove koji su nastali nakon što je on bio pokrenut
  - danas postoje još dva tipa raspoređivača
    - **ravnopravni raspoređivač** (engl. *fair scheduler*)
    - **raspoređivač zasnovan na kapacitetu** (engl. *capacity scheduler*)

127

127

Raspoređivanje poslova

- **Ravnopravni raspoređivač**
  - svaki korisnik koji kreira poslove u sistemu bi trebalo da dobije ravnomeran deo infrastrukture
    - ako se izvršava jedan posao od jednog korisnika, dobiće ceo klaster
    - ukoliko postoji više korisnika koji su pokrenuli poslove
      - svi će biti izvršeni sa odgovarajućim delom resursa
  - svi poslovi jednog korisnika smešteni su u kolekcije poslova
    - tako da svaka kolekcija poslova dobija odgovarajući deo resursa
      - korisnik sa više poslova neće dobiti više resursa
  - podržava dodelu resursa prioritetnijim resursima čak i u slučaju da je sporiji proces zauzeo dobar deo resursa klastera
    - delovi tog procesa biće zaustavljeni kako bi se oslobodili resursi

128

128

Raspoređivanje poslova

- **Raspoređivač zasnovan na kapacitetu**
  - umesto kolekcija poslova kreiranih za svakog korisnika postoji hijerarhija redova čekanja
    - svaki red čekanja ima dodeljeni kapacitet tj. deo resursa klastera
  - unutar svakog reda čekanja, poslovi su raspoređeni u FIFO strukturu

129

129

Raspodela i sortiranje podataka

- **Raspodela** (engl. *shuffle*) i **sortiranje** (engl. *sort*) podataka
  - MapReduce okvir garantuje da će ulaz u svaki *reducer* biti sortiran po ključu
  - **proces u okviru kojeg je implementirano sortiranje vrednosti koje predstavljaju izlaz iz koraka *map* i raspoređivanje tih vrednosti odgovarajućim koracima *reduce*, naziva se raspodela podataka**
    - **definisan radnim okvirom a ne od strane korisnika**
  - optimizacija MapReduce programa
    - da se što bolje iskoristi algoritam raspodele podataka

130

130

Raspodela podataka

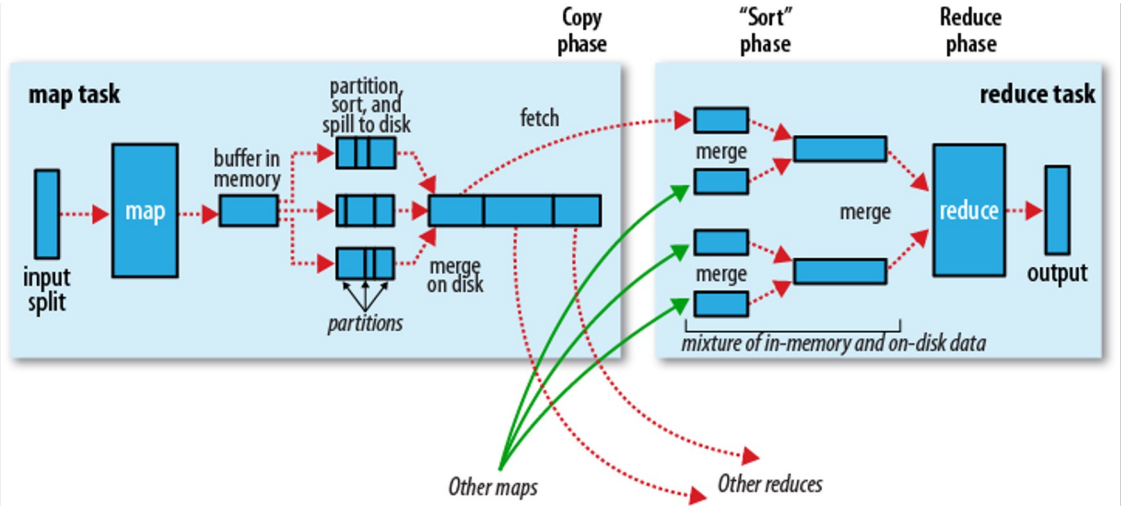

izvor: *Hadoop - The Definitive Guide, Tom White*

Raspodela podataka

- Raspodela podataka (u koraku *map*)
  - svaki *map* zadatak rezultate piše u cirkularni *buffer*
    - 100 MB prepodešena vrednost
  - kada se *buffer* napuni do podešene granice pozadinska nit će početi da snima istisnute podatke (engl. *spills*) na disk
    - ukoliko se *buffer* popuni pre nego što si svi istisnuti podaci snimljeni a novi podaci pristižu, zadatak *map* koji generiše podatke biće blokiran
  - pre svakog pisanja na disk
    - istisnuti podaci se particionišu u delove koje odgovaraju ciljnim *reducer*-ima
    - svaka particija se sortira u pozadinskom procesu
    - ukoliko postoji, primenjuje se *combiner*
      - za kompakciju torki i smanjenje saobraćaja preko mreže
  - rezultat particionisanja i sortiranja su datoteke na disku koje je potrebno proslediti *reducer*-ima

Sortiranje podataka

- Sortiranje podataka (u koraku *reduce*)
  - *reducer* "dovlači" particionisane podatke kada koraci *map* završe sa njihovim kreiranjem
    - koraci *map* obaveštavaju *JobTracker*-a kada su završili sa svojom obradom
    - moguće da različiti koraci *map* završe u različitim vremenskim trenucima
    - **faza kopiranja** (engl. *copy phase*) u *buffer reducer*-a
      - u radnu memoriju *reducer*-a za male datoteke
        - nakon što je odgovarajući broj datoteka kopiran u *buffer*, vrši se njihovo spajanje u veće, sortirane datoteke na disku *reducer*-a
      - ili direktno na disk *reducer*-a ako su datoteke velike
  - nakon što je završeno kopiranje svih datoteka iz koraka *map* vrši se spajanje
    - **faza sortiranja** (engl. *sort phase*)
      - bolji naziv je faza spajanja (engl. *merge phase*)
    - datoteke na disku se spajaju u iteracijama
      - u svakoj iteraciji se spaja predefinisan broj datoteka
      - održava se sortiranost paketa unutar datoteka

134

134

Sortiranje podataka

- Sortiranje podataka (u koraku *reduce*)
  - nakon spajanja datoteka sa paketima izvršava se funkcija *reduce*
    - **faza *reduce*** (engl. *reduce phase*)
    - umesto poslednje iteracije spajanja
      - da bi se minimizovao broj pisanja na disk

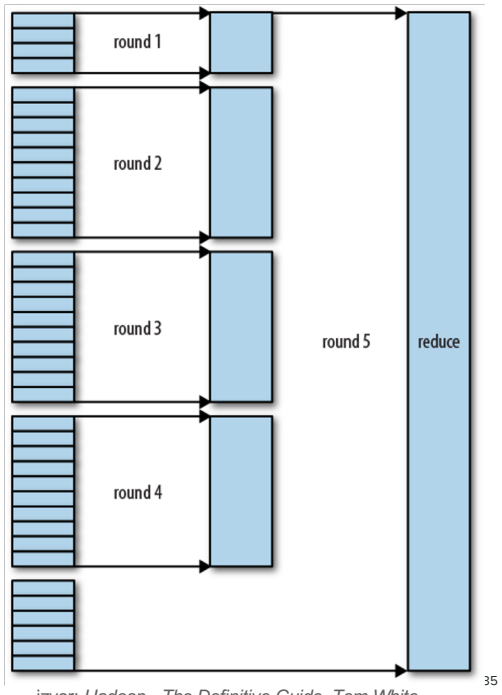

35

izvor: *Hadoop - The Definitive Guide, Tom White*

135

MapReduce - tipovi

- Tipovi MapReduce programa
  - postoje četiri osnovna, najčešće korišćena, tipa MapReduce programa
    - ulaz-map-reduce-izlaz
    - ulaz-map-izlaz
    - ulaz-višestruki map-reduce-izlaz
    - ulaz-map-combiner-reduce-izlaz

136

136

MapReduce - tipovi

- Tip *ulaz-map-reduce-izlaz*
  - najčešće korišćen za agregacije

Scenario	Računanje odnosa između pola radnika i plate
Map	ključ: pol, vrednost: plata
Reduce	grupiše po polu, izračunava sumu plata za svaki pol

137

137

MapReduce - tipovi

- Tip *ulaz-map-izlaz*
  - najčešće korišćen za promenu formata podataka

Scenario	Neki zaposleni imaju isti pol označen sa *F, Female, f, 0*

Map	ključ: ID zaposlenog
	vrednost: Pol koji predstavlja izlaz iz funkcije
	
	`if Gender is Female/ F/ f/ 0 then converted to F`
	`else if Gender is Male/M/m/1 then convert to M`

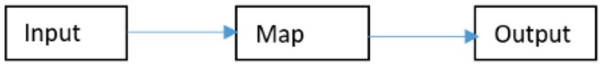

138

138

MapReduce - tipovi

- Tip *ulaz-višestruki map-reduce-izlaz*
  - najčešće korišćen za situacije kada imamo različite šeme ulaznih podataka

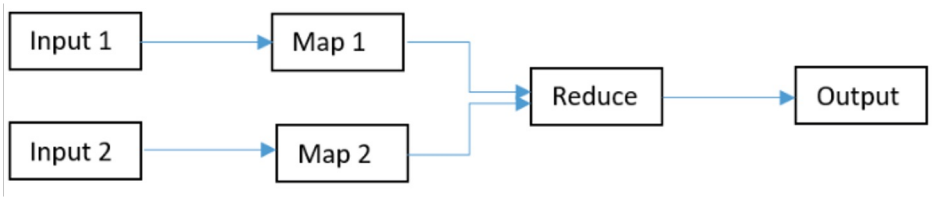

139

139

MapReduce - tipovi

- Tip *ulaz-višestruki map-reduce-izlaz*

Scenario	Ukupna plata za pol, fajlovi u različitim formatima datoteka 1: pol dat kao prefiks imenu: *Mr. Vladimir* datoteka 2: pol dat u posebnoj koloni: *Vladimir, Male*
Map	Map 1: parsira ime i izvlači prefiks, rezultat par (pol, plata) Map 2: direktno preuzimanje vrednosti, rezultat par (pol, plata)
Reduce	grupisanje po polu, sumiranje plata

140

140

MapReduce - tipovi

- Tip *ulaz-map-combiner-reduce-izlaz*
  - najčešće korišćen kada *reduce* funkciju nije moguće paralelizovati
    - smanjuje se opterećenje na toj funkciji

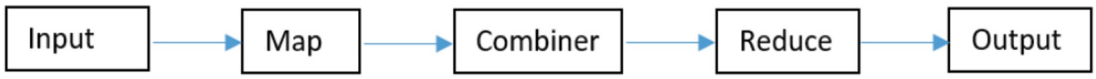

141

141

MapReduce - tipovi

- Tip *ulaz-map-combiner-reduce-izlaz*
  - Scenario: Ukupna plata za pol, radnici u različitim departmanima. Departmana ima 5. Ako je plata u okviru departmana preko 200k dodaj 20k, ako je preko 100k dodaj 10k

ulaz	map (paralelno)	combiner (paralelno)	reduce (nije paralelno)	izlaz
datoteka_dep1	Male<10,20,25,45,15,45,25,20> Female <10,30,20,25,35>	Male <250,20> Female <120,10>	Male < 250,20,155, 10,90,90,30> Female <120,10,175,10,135,10 ,110,10,130,10>	Male <645> Female <720>
datoteka_dep2	Male<15,30,40,25,45> Female <20,35,25,35,40>	Male <155,10> Female <175,10>		
datoteka_dep3	Male<10,20,20,40> Female <10,30,25,70>	Male <90,00> Female <135,10>		
datoteka_dep4	Male<45,25,20> Female <30,20,25,35>	Male <90,00> Female <110,10>		
datoteka_dep5	Male<10,20> Female <10,30,20,25,35>	Male <30,00> Female <130,10>		

142

142

MapReduce - osnovni šabloni i primeri

- Prebrojavanje i sumiranje
  - **problem**
    - snimljeni dokumenti sadrže skupove termina
    - potrebno je prebrojati broj pojava svakog termina u svim dokumentima
      - ili izvršiti bilo koju drugu funkciju koja zavisi od termina
  - **primena**
    - analiza logova, upiti nad podacima

143

143

MapReduce - osnovni šabloni i primeri

- Prebrojavanje i sumiranje - rešenje 1
  - najprostije rešenje
  - funkcija map šalje termin i broj 1 kao izlaz za svaki termin koji parsira
  - mana
    - preveliki broj brojača koji se prenosi preko mreže
  - rešenje
    - potrebno nekako agregirati podatke koji predstavljaju izlaz iz funkcije map

```
class Mapper
   method Map(docid id, doc d)
      for all term t in doc d do
         Emit(term t, count 1)

class Reducer
   method Reduce(term t, counts [c1, c2,...])
      sum = 0
      for all count c in [c1, c2,...] do
          sum = sum + c
      Emit(term t, count sum)
```

144

144

MapReduce - osnovni šabloni i primeri

- Prebrojavanje i sumiranje - rešenje 2
  - agregiraju se sve pojave istog termina u dokumentu
    - smanjuje se broj poslatih brojača preko mreže
- Prebrojavanje i sumiranje - rešenje 3
  - iskoristiti *combiner*
  - agregirati sve pojave istog termina u svim dokumentima procesiranim od strane istog *mapper*-a

```
class Mapper
   method Map(docid id, doc d)
      H = new AssociativeArray
      for all term t in doc d do
          H{t} = H{t} + 1
      for all term t in H do
         Emit(term t, count H{t})

---------------------------------
class Mapper
   method Map(docid id, doc d)
      for all term t in doc d do
         Emit(term t, count 1)

class Combiner
   method Combine(term t, [c1, c2,...])
      sum = 0
      for all count c in [c1, c2,...] do
          sum = sum + c
      Emit(term t, count sum)

class Reducer
   method Reduce(term t, counts [c1, c2,...])
      sum = 0
      for all count c in [c1, c2,...] do
          sum = sum + c
      Emit(term t, count sum)
```

145

145

MapReduce - osnovni šabloni i primeri

- Sakupljanje (engl. *collating*)
  - **problem**
    - snimljeni dokumenti sadrže skup torki
    - postoji funkcija nad pojedinačnim torkama
    - potrebno je snimiti sve torke koje daju istu vrednost funkcije u jednu datoteku
      - ili izvršiti neku analizu nad tako konstruisanom grupom torki
  - **primena**
    - **invertovani indeksi**, ETL

146

146

MapReduce - osnovni šabloni i primeri

- Sakupljanje (engl. *collating*)
  - **rešenje**
    - *mapper* izračunava funkciju za svaku torku koja se obrađuje
      - vrednost funkcije je ključ
      - torka je vrednost
    - *reducer* procesira grupisane torke i snima ih u dokument/analizira
  - TF/IDF
    - funkcija vraća ID dokumenta u kojem se torka nalazi
    - `{(DOC ID, Term), TF}`
    - `N / {Term, DF}`

```
class Mapper
   method Map(docid id, doc d)
      for all term t in doc d do
         Emit(function(t), term t)

class Reducer
   method Reduce(funct t, set [t1, t2,...])
      analize = analize([t1, t2,...])
      Emit(funct t, analize)
```

147

147

MapReduce - osnovni šabloni i primeri

- Filtriranje, parsiranje i validacija
  - **problem**
    - postoji potreba za
      - preuzimanjem torki koje zadovoljavaju neki uslov
      - transformacijom svake torke u novi oblik
  - **primena**
    - ETL, validacija podataka, upiti, analiza logova

148

148

MapReduce - osnovni šabloni i primeri

- Filtriranje, parsiranje i validacija
  - **rešenje**
    - koristiti samo funkciju *map* koja vraća torke (njihov transformisani oblik) koje zadovoljavaju uslov

```
class Mapper
   method Map(docid id, doc d)
      for all term t in doc d do
           if condition t is true then
          Emit(function(t), null)
```

149

149

MapReduce - osnovni šabloni i primeri

- Izvršavanje zadataka u distribuiranom okruženju
  - **problem**
    - postoji zadatak, zahtevan sa stanovišta potrebnog procesorskog vremena, koji je moguće dekomponovati na niz manjih zadataka i na kraju kombinovati rezultat
  - **primena**
    - simulacije u fizici i inženjerskim disciplinama, numeričke analize, analiza performansi
  - **rešenje**
    - svaki od podzadataka predstavljen je posebnom funkcijom *map*
      - ulazi su specifične, tražene vrednosti za svaki od zadataka
      - funkcija *map* preuzme ulaz, izvrši izračunavanje, vrati rezultat izvršenja
    - svi rezultati su objedinjeni u funkciji *reduce*

150

150

MapReduce - osnovni šabloni i primeri

- Izvršavanje zadataka u distribuiranom okruženju
  - **primer upotrebe**
    - simulator komunikacije preko računarske mreže
      - slučajno generisane podatke propušta preko modela mreže
      - potrebno je izračunati verovatnoću pojave greške u komunikaciji
    - svaka funkcija *map* (od ukupno N instanci) izvrši simulaciju nad 1/N ulaznih podataka
      - vraća broj uočenih grešaka u komunikaciji
    - funkcija *reduce* spaja sve izlaze funkcije *map*
      - npr. izračunava srednju vrednost broja grešaka

151

151

MapReduce - osnovni šabloni i primeri

- Sortiranje
  - **problem**
    - skup torki je potrebno sortirati ili procesirati u odgovarajućem redosledu
  - **primena**
    - ETL, analiza podataka
  - **rešenje**
    - jednostavno sortiranje je moguće uraditi tako što se kao izlaz iz mapera generiše
      - *ključ*: vrednost obeležja nad kojom se sortira
      - *vrednost*: torka
    - postoje tehnike koje dozvoljavaju sortiranje po vrednosti a ne samo po ključu
    - često je pogodnije održavati snimljene vrednosti u HDFS-u u sortiranom poretku

152

152

MapReduce - napredni šabloni i primeri

- Obrada grafova/iterativna obrada poruka
  - **problem**
    - potrebno je izračunati stanje čvora u grafu
      - na stanje čvora utiču osobine povezanih čvorova, tj. čvorova u okolini
      - stanje može predstavljati udaljenost između čvorova, indikator da postoji neki čvor u okolini koji zadovoljava određeni uslov itd.
  - **primena**
    - analiza grafova, indeksiranje web sadržaja

153

153

MapReduce - napredni šabloni i primeri

- Obrada grafova/iterativna obrada poruka
  - **rešenje**
    - konceptualno
      - svaki čvor poseduje listu ID-ova povezanih čvorova
      - MapReduce zadaci se izvršavaju iterativno
        - u svakoj iteraciji se šalje poruka susednom čvoru nakon koje on ažurira stanje
      - iteracije se završavaju nakon fiksnog broja koraka ili kada izmene stanja postanu zanemarljive
      - stanje čvora se brzo propagira kroz graf
    - tehnički
      - funkcija *map* šalje poruke (ID susednog čvora, poruka)
      - funkcija *reduce* prima grupisane poruke po ID-u čvora i izračunava novo stanje

154

154

MapReduce - osnovni šabloni i primeri

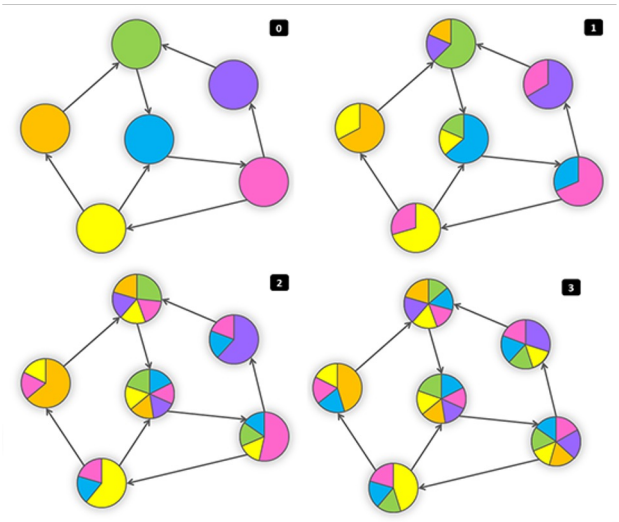


```
class Mapper
   method Map(id n, object N)
      Emit(id n, object N)
      for all id m in N.OutgoingRelations do
         Emit(id m, message getMessage(N))

class Reducer
   method Reduce(id m, [s1, s2,...])
      M = null
      messages = []
      for all s in [s1, s2,...] do
          if IsObject(s) then
             M = s
          else               // s is a message
             messages.add(s)
      M.State = calculateState(messages)
      Emit(id m, item M)
```

155

155

MapReduce - osnovni šabloni i primeri

- Obrada grafova/iterativna obrada poruka
  - **primer upotrebe 1 - propagacija dostupnosti kroz stablo kategorija**
    - kategorije proizvoda neke *online* prodavnice su organizovane u obliku stabla
      - od kategorija: muškarci, žene, deca
      - do kategorija: muške pantalone ...
    - kategorije na najnižim nivoima su dostupne ukoliko postoje artikli te kategorije na stanju
    - sve kategorije na višim nivoima su dostupne ako je dostupna makar jedna kategorija u njenom podstablu
    - potrebno je izračunati dostupnost kategorija višeg nivoa ako su poznate dostupnosti svih kategorija nižeg nivoa

156

156

MapReduce - osnovni šabloni i primeri

- Obrada grafova/iterativna obrada poruka
  - **primer upotrebe 1 - rešenje**

```
class N
   State in {True = 2, False = 1, null = 0},
     initialized 1 or 2 for end-of-line categories, 0 otherwise

method getMessage(object N)
   return N.State

method calculateState(state s, data [d1, d2,...])
   return max( [d1, d2,...] )
```

157

157

MapReduce - osnovni šabloni i primeri

- Obrada grafova/iterativna obrada poruka
  - **primer upotrebe 2 - pretraga prvi u širinu (BFS)**
    - potrebno je izračunati udaljenost od nekog čvora do svih drugih čvorova u grafu
  - **rešenje**
    - izvorni čvor šalje svim susedima 0, svaki od suseda preuzima poruku, uvećava brojač za jedan i šalje dalje susednim čvorovima

```
class N
   State is distance, initialized 0 for source node, INFINITY for all other nodes

method getMessage(N)
   return N.State + 1

method calculateState(state s, data [d1, d2,...])
   min( [d1, d2,...] )
```

158

158

MapReduce - osnovni šabloni i primeri

- Obrada grafova/iterativna obrada poruka
  - **primer upotrebe 3 - PageRank**
    - potrebno je izračunati relevantnost stranica koja je funkcija autoritativnosti drugih stranica koje imaju vezu ka njoj
  - **rešenje**
    - svodi se na propagaciju težina
      - težina čvora je prosečna težina povezanih čvorova

```
class N
    State is PageRank

method getMessage(object N)
    return N.State / N.OutgoingRelations.size()

method calculateState(state s, data [d1, d2,...])
    return ( sum([d1, d2,...]) )
```

159

159

MapReduce - napredni šabloni i primeri

- Brojanje jedinstvenih vrednosti
  - **problem**
    - neka svaka torka skupa ima polja F i G
    - potrebno je izračunati broj različitih vrednosti polja F za neku vrednost polja G
  - **primena**
    - analiza logova, prebrojavanje jedinstvenih korisnika

```
Record 1: F=1, G={a, b}
Record 2: F=2, G={a, d, e}
Record 3: F=1, G={b}
Record 4: F=3, G={a, b}

Result:
a -> 3   // F=1, F=2, F=3
b -> 2   // F=1, F=3
d -> 1   // F=2
e -> 1   // F=2
```

161

161

MapReduce - napredni šabloni i primeri

- Brojanje jedinstvenih vrednosti
  - **rešenje 1**
    - rešenje u dve faze
    - u prvoj fazi
      - funkcija *map* generiše broj 1 za svaki par vrednosti [G, F]
      - funkcija *reduce* izračunava ukupan broj pojavljivanja svakog od tih parova
      - osnovna svrha ove faze je da obezbedi jedinstvenost vrednosti polja F
    - u drugoj fazi
      - u funkciji *map* parovi su grupisani po vrednosti polja G
      - u funkciji *reduce* se izračunava ukupan broj vrednosti u svakoj grupi

162

162

MapReduce - napredni šabloni i primeri

```
---PHASE 1---
class Mapper
   method Map(null, record [value f, categories [g1, g2,...]])
      for all category g in [g1, g2,...]
         Emit(record [g, f], count 1)

class Reducer
   method Reduce(record [g, f], counts [n1, n2, ...])
      Emit(record [g, f], null )

---PHASE 2---
 class Mapper
   method Map(record [f, g], null)
      Emit(value g, count 1)

class Reducer
   method Reduce(value g, counts [n1, n2,...])
      Emit(value g, sum( [n1, n2,...] ) )
```

163

163

MapReduce - napredni šabloni i primeri

- Brojanje jedinstvenih vrednosti
  - **rešenje 2**
    - rešenje u jednoj fazi
      - ali ne skalira dobro kao prvo rešenje i primena mu je ograničena
        - u slučaju kada broj istih vrednosti polja F u okviru iste vrednosti polja G nije prevelik
        - u slučaju kada postoji mali i ograničen broj vrednosti polja G
    - funkcija *map* daje na izlazu parove vrednosti F i G
    - funkcija *reduce*
      - odstranjuje duple vrednosti polja F u istoj kategoriji (za istu vrednost polja G) i uvećava brojač u okviru svake kategorije
      - nakon kompletnog *reduce* koraka sumiraju se svi brojači generisani od strane *reducer*-a
    - moguće je koristiti funkcije *combine* umesto da se duplikati uklanjaju u *reduce* koraku

164

164

MapReduce - napredni šabloni i primeri

```
class Mapper
   method Map(null, record [value f, categories [g1, g2,...] )
      for all category g in [g1, g2,...]
          Emit(value f, category g)

class Reducer
   method Initialize
      H = new AssociativeArray : category -> count
   method Reduce(value f, categories [g1, g2,...])
      [g1', g2',..] = ExcludeDuplicates( [g1, g2,..] )
      for all category g in [g1', g2',...]
         H{g} = H{g} + 1
   method Close
      for all category g in H do
         Emit(category g, count H{g})
```

165

165

MapReduce - napredni šabloni i primeri

- Relacioni operatori
  - pomoću MapReduce programa moguće je implementirati sledeće relacione operatore
    - selekcija
    - projekcija
    - unija
    - presek
    - razlika
    - grupisanje i agregacija
    - spajanje

169

169

MapReduce - napredni šabloni i primeri

- Relacioni operatori - selekcija

```
---Selekcija---
class Mapper
   method Map(rowkey key, tuple t)
      if t satisfies the predicate
         Emit(tuple t, null)
```

- Relacioni operatori - projekcija
  - funkcija *reduce* eliminiše duplikate

```
---Projekcija---
class Mapper
   method Map(rowkey key, tuple t)
      // extract required fields to tuple g
      tuple g = project(t)
      Emit(tuple g, null)

class Reducer
   // n is an array of nulls
   method Reduce(tuple t, array n)
      Emit(tuple t, null)
```

170

170

MapReduce - napredni šabloni i primeri

- Relacioni operatori - unija
  - funkcija *reduce* eliminiše duplikate

```
---Unija---
class Mapper
   method Map(rowkey key, tuple t)
      Emit(tuple t, null)

class Reducer
   // n is an array of one or two nulls
   method Reduce(tuple t, array n)
      Emit(tuple t, null)
```

- Relacioni operatori - presek
  - funkcija *reduce* daje na izlazu samo slogove koji se pojavljuju u oba skupa

```
---Presek---
class Mapper
   method Map(rowkey key, tuple t)
      Emit(tuple t, null)

class Reducer
   // n is an array of one or two nulls
   method Reduce(tuple t, array n)
      if n.size() = 2
          Emit(tuple t, null)
```

171

171

MapReduce - napredni šabloni i primeri

- Relacioni operatori – razlika
  - r(R) – s(R)

```
---Razlika---
class Mapper
   method Map(rowkey key, tuple t)
      Emit(tuple t, string t.SetName)    // t.SetName is either 'R' or 'S'

class Reducer
   method Reduce(tuple t, array n)       // array n can be ['R'], ['S'], ['R', 'S'], or ['S', 'R']
      if n.size() = 1 and n[1] = 'R'
          Emit(tuple t, null)
```

172

172

MapReduce - napredni šabloni i primeri

- Grupisanje i agregacija
  - funkcija map iz svake torke izdvaja obeležja po kojima se vrši grupisanje i obeležja po kojima se vrši agregacija
  - funkcija reduce izračunava agregat
  - za neke specifične funkcije možda je potrebno uraditi algoritam u dva koraka
    - npr. kako bi se filtrirali duplikati

```
class Mapper
   method Map(null, tuple [value GroupBy, value AggregateBy, value ...])
      Emit(value GroupBy, value AggregateBy)
class Reducer
   method Reduce(value GroupBy, [v1, v2,...])
      Emit(value GroupBy, aggregate( [v1, v2,...] ) )  // aggregate() : sum(), max(),...
```

173

173

MapReduce - napredni šabloni i primeri

- Spoj sa reparticionisanjem
  - engl. *repartition join, reduce join, sort-merge join*
  - spajaju se dva skupa torki po ključu k
  - funkcija *map*
    - označava svaku torku sa oznakom iz kojeg skupa je preuzeta
    - na izlazu ima vrednosti gde je ključ k po kojem se spaja, a vrednost označena torka
  - funkcija *reduce*
    - puni dve kolekcije torkama, za svaku oznaku skupa po jedna kolekcija
    - kreira dekartov proizvod torki jednog skupa sa torkama drugog skupa po ključu k
  - **mane**:
    - funkcija *map* na izlazu ima sve moguće torke
      - uključujući i torke za ključeve koji ne postoje u drugom skupu
    - funkcija *reduce* mora da drži sve torke jednog ključa u memoriji
      - ako ne može sve da stane u memoriju mora biti u mogućnosti da privremeno skladišti torke na disku

174

174

MapReduce - napredni šabloni i primeri

```
class Mapper
   method Map(null, tuple [join_key k, value v1, value v2,...])
      Emit(join_key k, tagged_tuple [set_name tag, values [v1, v2, ...] ] )

class Reducer
   method Reduce(join_key k, tagged_tuples [t1, t2,...])
      H = new AssociativeArray : set_name -> values
      for all tagged_tuple t in [t1, t2,...]     // separate values into 2 arrays
         H{t.tag}.add(t.values)
      for all values r in H{'R'}                 // produce a cross-join of the two arrays
         for all values l in H{'L'}
            Emit(null, [k r l] )
```

175

175

MapReduce - napredni šabloni i primeri

- Spoj sa pomoćnom rasutom strukturom
  - engl. *hash join*, *map join*, *replicated join*
  - spajaju se dva skupa torki po ključu k
    - kod kojih je jedan skup znatno manji od drugog
  - funkcija map
    - uzima vrednosti manjeg skupa i kreira mapu vrednosti gde je ključ k ključ u mapi a vrednost torka iz tog manjeg skupa
    - prolazi kroz torke većeg skupa i vrši spajanje sa postojećim elementima u mapi
  - **prednost**: nema potrebe za slanjem većeg skupa preko mreže niti potrebe za sortiranjem

176

176

MapReduce - napredni šabloni i primeri

```
class Mapper
   method Initialize
      H = new AssociativeArray : join_key -> tuple from R
      R = loadR()
      for all [ join_key k, tuple [r1, r2,...] ] in R
         H{k} = H{k}.append( [r1, r2,...] )

   method Map(join_key k, tuple l)
      for all tuple r in H{k}
         Emit(null, tuple [k r l] )
```

177

177

Apache Spark (paketna obrada)

178

Apache Spark

- Apache Spark je radni okvir otvorenog kôda
  - za paketnu obradu podataka
  - za obradu podataka u realnom vremenu
  - koji vrši izračunavanja **u radnoj memoriji** računara koji pripadaju klasteru
- Osobine alata Apache Spark
  - **brzo procesiranje podataka** - zasnovano na čuvanju podataka u radnoj memoriji kao i na strukturama podataka optimizovanim za ovakvu vrstu obrade
    - značajno brži od Hadoop MapReduce
  - **fleksibilnost** - podržani su programski jezici Java, Scala, R i Python i veliki broj primitiva za upravljanje podacima
  - **podrška za više paradigmi obrade podataka**
  - **podrška za različite distribuirane sisteme** - kompatibilnost sa Hadoop-om i Mesos-om
    - postojanje sopstvene infrastrukture

179

179

Apache Spark - upotreba

- Tipični scenario upotrebe Apache Spark-a
  - učitavanje podataka (engl. *ingestion*)
    - iz različitih izvora
  - prečišćavanje podataka (engl. *data quality*)
    - obezbeđenje kvaliteta podataka koji se obrađuju
  - obrada podataka (engl. *transformation*)
  - objava rezultata obrade (engl. *load/publish*)
    - upis rezultata obrade podataka u skladište podataka

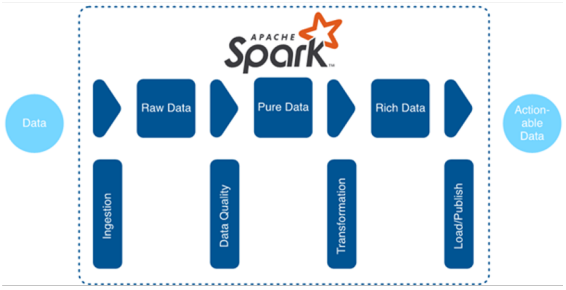

izvor: https://livebook.manning.com/book/spark-in-action-second-edition/chapter-1/v-13/43

180

180

Apache Spark - upotreba

- Tipične primene radnog okvira Apache Spark
  - mašinsko učenje
    - upotrebom komponente Apache MLlib pruža mogućnost skaliranja distribuiranih algoritama mašinskog učenja
  - *fog computing*
    - u IoT sistemima, izdvajanje procesne moći iz *cloud*-a u klastere bliže izvoru podataka
      - sračunati podaci se potom često skladište u *cloud*-u
  - detekcija događaja
    - identifikacija šablona i događaja sa ciljem detekcije anomalija, identifikacija rizika i obaveštavanja korisnika
  - interaktivna analiza podataka
    - izvršavanje *ad-hoc* upita bez redukcije osnovnog skupa podataka

181

181

Apache Spark - arhitektura

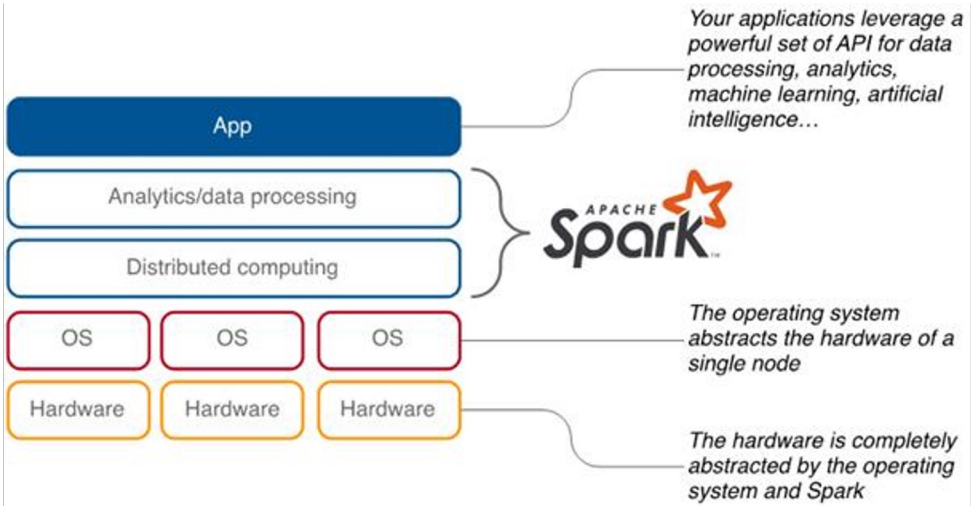

izvor: https://livebook.manning.com/book/spark-in-action-second-edition/chapter-1/v-13/43

182

182

Apache Spark - arhitektura

- Osnovni elementi arhitekture
  - Spark Core
  - Spark SQL
  - Spark Streaming
  - Spark MLlib
  - Spark GraphX
  - Spark R

izvor: https://www.edureka.co/blog/spark-architecture/

183

183

Apache Spark - arhitektura

- Spark Core
  - osnovni izvršni sistem za paralelnu i distribuiranu obradu velike količine podataka
  - predstavlja osnovu za sve ostale module
  - obuhvata i distribuirane skupove podataka otporne na otkaze
    - engl. *Resilient Distributed Datasets* (RDD)
    - particionisani skupovi podataka
    - struktura nad kojom se vrši obrada u Spark-u

184

184

Apache Spark - arhitektura

- Spark SQL
  - omogućava pisanje SQL upita radi obrade podataka
    - direktno naleže na Spark Core komponentu
    - koristi i podatke organizovane u obliku okvira podataka
      - engl. *DataFrame*
      - pandan tabele iz relacione baze podataka u Spark SQL-u
      - poseduje mogućnost definisanja šeme podataka
        - svaka kolona ima ime i tip
    - poseduje ugrađeni optimizator upita
    - omogućava pristup putem standardnih aplikativnih mehanizama
      - moguće se konektovati preko JDBC ili ODBC
    - interno se svodi na RDD i DAG

185

185

Apache Spark - arhitektura

- Spark Streaming
  - omogućava obradu podataka u realnom vremenu
    - visoke propusne moći
    - visoke tolerancije na greške
  - obuhvata podatke iz toka podataka u paketima male veličine
    - posmatra ih kao RDD
    - mikropaketna obrada podataka
- Spark GraphX
  - komponenta za distribuiranu obradu podataka organizovanih putem strukture tipa grafa
    - omogućava obradu grafova
    - apstrakcija sistema Pregel
      - za distribuiranu obradu grafova
    - proširenje RDD podrškom za formiranje grafova

186

186

Apache Spark - arhitektura

- Spark MLlib
  - omogućava implementaciju algoritama mašinskog učenja nad podacima
    - distribuirani radni okvir
- Spark R
  - omogućava integraciju programskog jezika R sa Apache Spark sistemom

187

187

Apache Spark - RDD

- Problem sa iterativnim *map-reduce* programima
  - sporo deljenje memorije
  - upis na disk nakon svakog *map-reduce* koraka
  - previše (za krajnji rezultat) nepotrebnih I/O operacija

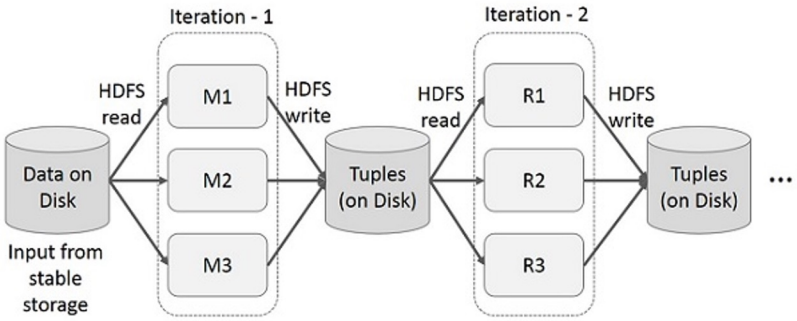

188

Apache Spark - RDD

- Distribuirani skup podataka otporan na otkaze
  - engl. *Resilient Distributed Datasets* (RDD)
  - podaci su distribuirani po čvorovima klastera
  - otporan na otkaze usled particionisanja i replikacije podataka
    - mogućnost ponovnog kreiranja podataka nakon otkaza
  - nepromenljiv skup podataka
    - nije moguće menjati stanje nakon kreiranja
  - skladišten u radnoj memoriji tokom obrade

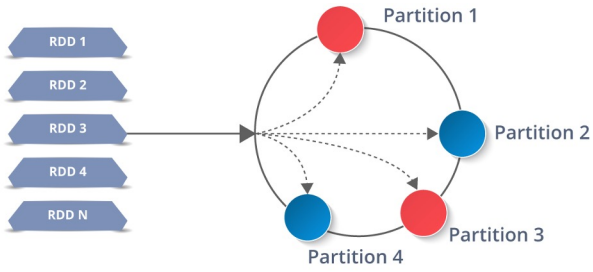

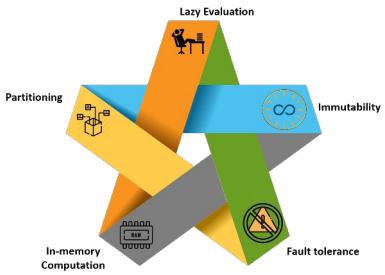

izvori: https://www.edureka.co/blog/spark-architecture/ i https://intellipaat.com/blog/tutorial/spark-tutorial/programming-with-rdds/

189

189

Apache Spark - RDD

- Distribuirani skup podataka otporan na otkaze
  - Eliminacija velikog broja I/O poziva značajno povećava brzinu izvršavanja iterativnih *map-reduce* programa

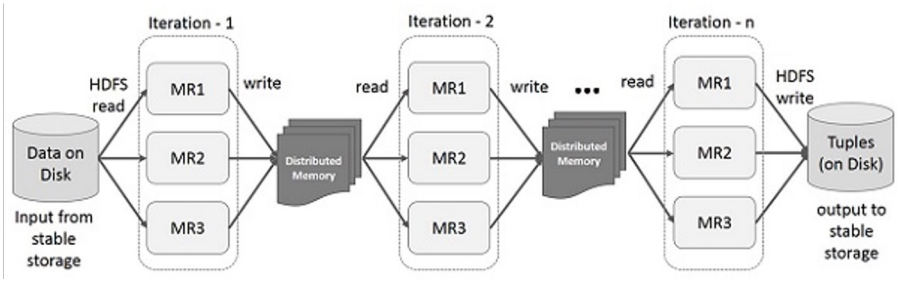

190

Apache Spark - RDD

- Distribuirani skup podataka otporan na otkaze
  - omogućava ponovno iskorišćenje međurezultata obrade
    - njihovim snimanjem u radnoj memoriji ili na disku
  - moguće je podešavati particionisanje radi optimizacije skladištenja podataka
  - poseduje veze ka RDD od kojih je nastao
    - primenom niza transformacija
    - pogodno za oporavak skupa podataka u slučaju otkaza
  - dva načina kreiranja RDD-a
    - paralelizacijom kolekcije podataka iz programa
    - referenciranjem strukture sa podacima u eksternom skladištu
      - HDFS, HBase, itd.
  - particije su atomičke jedinice obrade podataka
    - Spark automatski izvršava zadatke nad particijama RDD koji je predmet iste

191

191

Apache Spark - RDD

- Distribuirani skup podataka otporan na otkaze
  - podržava operacije
    - **transformacije** (engl. *transformation*)
      - kreiranje novih RDD
      - odloženo izvršavanje transformacija nad podacima
        - sve tražene transformacije se snimaju i izvršavaju tek kada su podaci potrebni u obradi
    - **obrade** / **akcije** (engl. *action*) podataka
      - sračunavanja nad podacima radi kreiranja rezultata koji se prikazuju korisniku

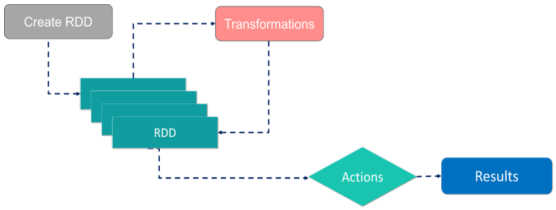

izvor: https://www.edureka.co/blog/spark-architecture/

192

192

Apache Spark - DAG

- Usmereni aciklični graf operacija
  - engl. *directed acyclic graph* (DAG)
  - predstavlja niz međusobno povezanih operacija nad podacima
  - predstavlja internu reprezentaciju programa za obradu podataka
    - i osnovu za distribuiranje i raspodelu RDD i zadataka u klasteru
  - za razliku od MapReduce modela podržava postojanje više od dve faze obrade

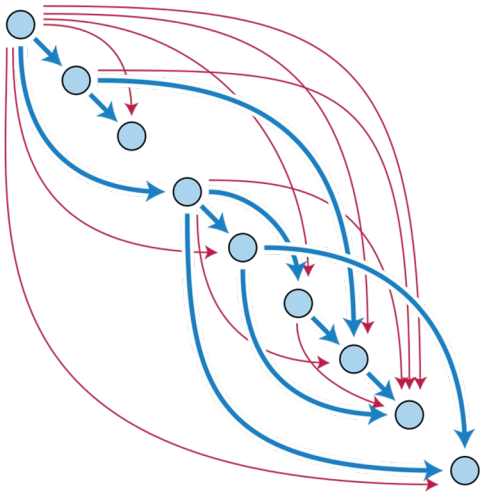

izvor: https://blog.k2datascience.com/batch-processing-apache-spark-a67016008167

193

193

Apache Spark - DAG

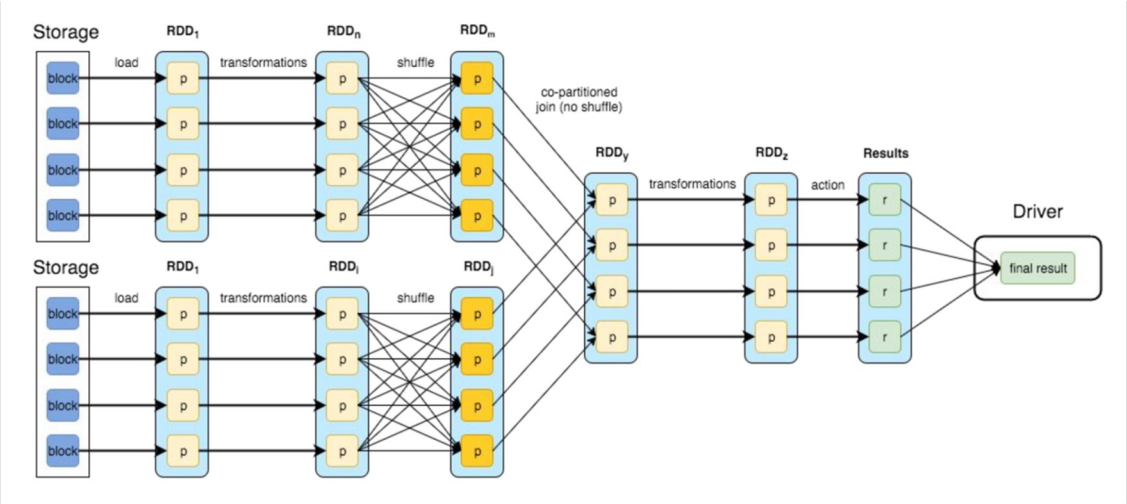

izvor: https://blog.k2datascience.com/batch-processing-apache-spark-a67016008167

194

194

Apache Spark - RDD

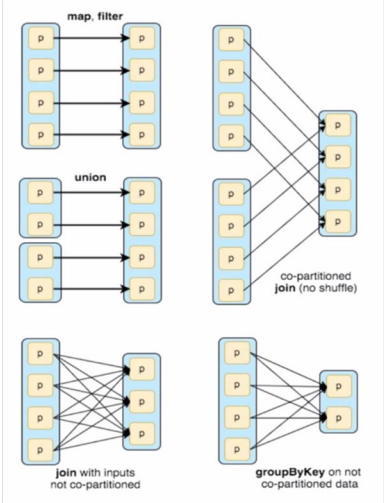

izvor: https://blog.k2datascience.com/batch-processing-apache-spark-a67016008167

195

195

Apache Spark - RDD

- Tipovi međuzavisnosti RDD
  - **direktna zavisnost** (engl. *narrow, pipelineable*)
    - posledica direktnih/uskih transformacija nad podacima
    - svaka particija roditeljskog RDD-a je korišćena u najviše jednoj particiji potomka
    - dozvoljava izvršenje kompletnog stabla particija na jednom čvoru u klasteru
    - oporavak od gubitka particije potomka je jednostavniji
      - usled izračunavanja samo nedostajućih predaka
  - **proširena zavisnost** (engl. *wide, shuffle*)
    - posledica proširenih/širokih transformacija nad podacima
    - više particija potomaka zavisi od jedne particije roditeljskog RDD-a
    - zahteva prebacivanje svih roditeljskih particija prilikom promene čvora u klasteru
    - kompletno ponovno izračunavanje na osnovu svih roditeljskih particija je potrebno u slučaju gubitka particije potomka

196

196

Apache Spark - RDD

- Identifikacija faza izvršavanja
  - na osnovu zavisnosti sa prethodnim RDD-ovima
    - krenuvši od poslednjeg RDD-a istoj fazi pripadaju svi RDD sa kojima je u direktnoj zavisnosti
- Ograničenja RDD
  - nepostojanje ugrađenog optimizatora operacija sa RDD
    - sva optimizacija prepuštena programeru
  - obrada strukturiranih podataka
    - RDD nema mehanizme da prepozna šemu ulaznog skupa podataka
  - performanse
    - RDD su JVM objekti -> preterana upotreba GC-a i Java serijalizacije
  - skladištenje
    - u slučaju da RDD ne može stati u radnu memoriju, sledi smeštanje jednog dela na disk

197

197

Apache Spark - RDD

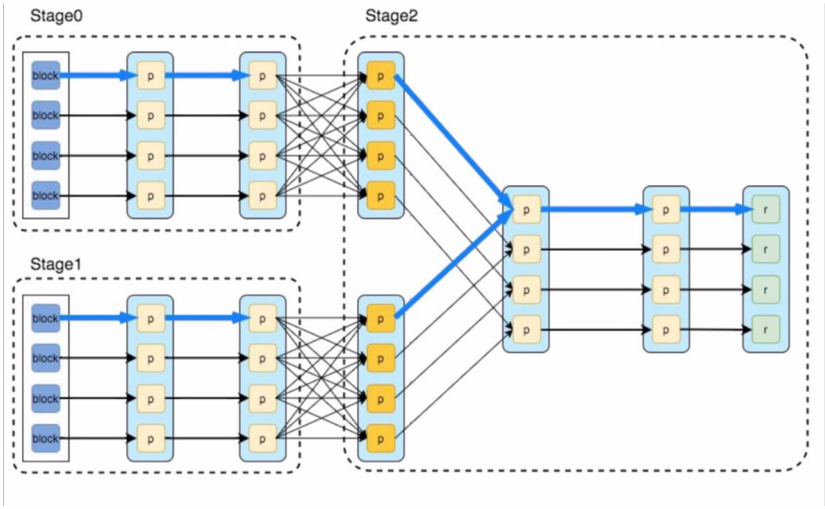

izvor: https://blog.k2datascience.com/batch-processing-apache-spark-a67016008167

198

198

Apache Spark - Dataframe

- Tabelarno organizovan skup podataka
  - engl. *Dataframe*
  - oslanja se na RDD i od njega nasleđuje
    - nepromenljivost
    - distribuirano izvršavanje u radnoj memoriji
    - otpornost na otkaze
  - poboljšanja u odnosu na RDD
    - efikasnije upravljanje memorijom (engl. *Custom Memory Management*)
    - optimizacija upita
  - daje se prednost *DataFrame*-u u odnosu na RDD prilikom obrade **strukturiranih podataka**

199

199

Apache Spark - Dataset

- Spark skup podataka
  - engl. *Spark dataset*
  - predstavljaju proširenja tabelarno organizovanog skupa podataka i RDD
  - pružaju objektno orijentisani interfejs
    - rad sa klasama i objektima
    - kolekcija JVM objekata

200

200

Apache Spark - RDD, Dataframe, Dataset

	RDD	***Dataframe***	***Dataset***
šta je?	API niskog nivoa apstrakcije	API visokog nivoa apstrakcije	Kombinacija RDD i *Dataframe*
optimizacija	Ne podržava	Optimizuje izvršavanje upita	Optimizuje izvršavanje upita
predstava podataka	Particionisani i distribuirani podaci	Kolekcija redova i imenovanih kolona	Kombinacija RDD i *Dataframe*
prednosti	Jednostavnost API-ja	Postojanje šeme distribuiranih podataka	Unapređeno korišćenje memorije
nepromenljivost podataka i interoperabilnost	RDD uvezuje podatke i omogućava oporavak od greške	Nakon transformacije u tabelarni oblik, nije moguće rekonstruisati originalni objekat	Moguće je rekonstruisati originalni RDD iz skupa podataka
performanse	Ograničene zbog serijalizacije u Javi i GC-a	Značajna unapređenja u odnosu na RDD	Operacije se izvode nad serijalizovanim podacima

201

201

Apache Spark - arhitektura

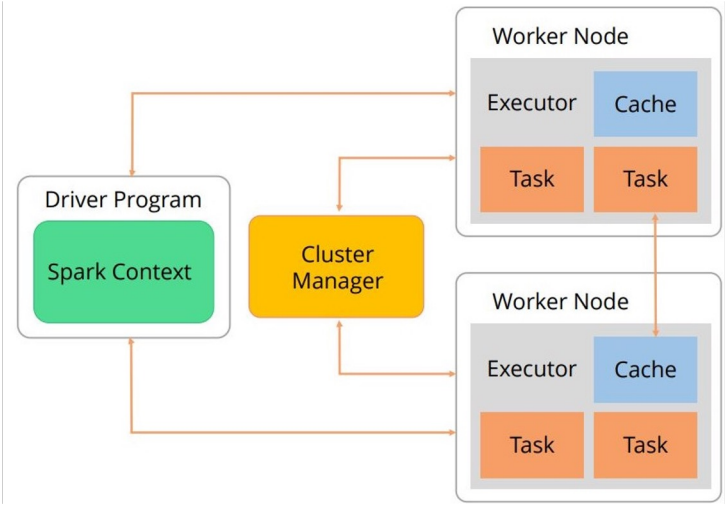

izvor: https://www.simplilearn.com/basics-of-apache-spark-tutorial

202

202

Apache Spark - arhitektura

- Glavni čvor (engl. *master node*)
  - sadrži drajver koji upravlja izvršavanjem aplikacije
    - omogućava kreiranje konteksta (engl. *Spark Context*)
    - zajedno sa kontekstom rastavlja traženi posao na zadatke
- Upravljač klasterom (engl. *cluster manager*)
  - upravlja distribucijom zadataka i RDD-a u klasteru
- Radni čvorovi (engl. *worker node*)
  - izvršavaju zadatke koji su im dodeljeni
    - nad particionisanim RDD
  - vraćaju rezultate nadležnom kontekstu

203

203

Apache Spark - arhitektura

- Izvršavanje poslova
  - **korak 1**: konverzija klijentskog programa u usmereni aciklični graf operacija
    - takođe optimizuje operacije koje je potrebno izvršiti
  - **korak 2**: kreiranje fizičkog plana izvršavanja usmerenog acikličnog grafa operacija
    - sa identifikacijom čvorova u klasteru koji učestvuju u obradi
    - podela posla na manje jedinice - zadatke
  - **korak 3**: identifikacija i zauzimanje potrebnih resursa u klasteru i slanje zadataka na izvršenje
    - drajver upravlja ovim procesom
  - **korak 4**: nadgledanje izvršenja zadataka i preuzimanje rezultata obrade

204

204

Apache Spark - arhitektura

- Otpornost na otkaze
  - svaki RDD poseduje celokupnu istoriju transformacija
    - koje su izvršene nad prethodnim RDD u cilju kreiranja novog
    - počevši od trenutka akvizicije podataka

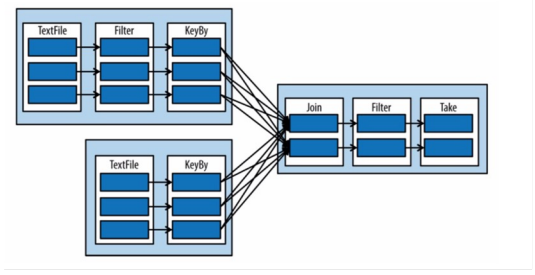

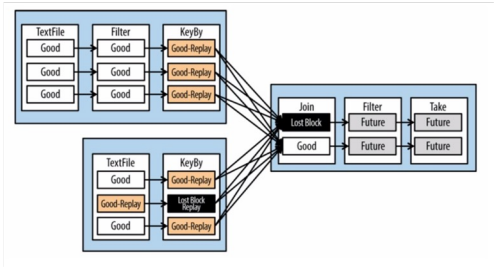

izvor: https://blog.k2datascience.com/batch-processing-apache-spark-a67016008167

205

205

Apache Spark - arhitektura

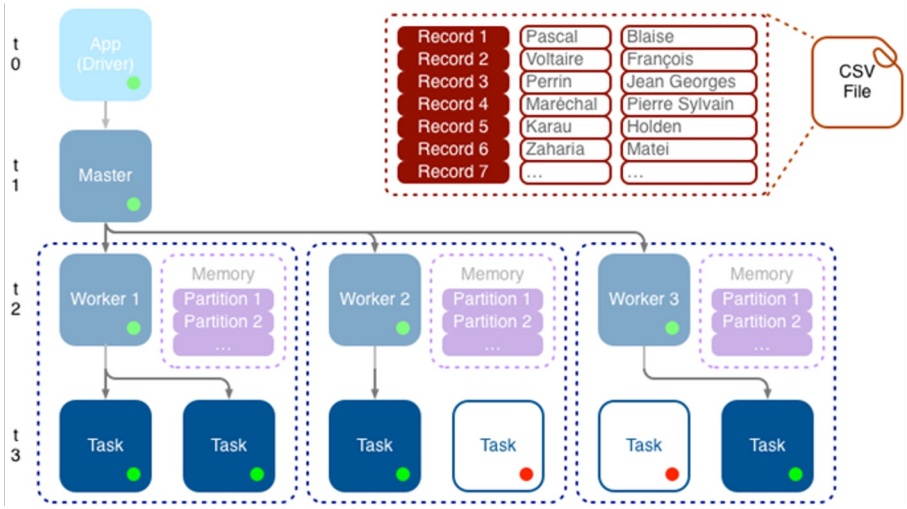

izvor: https://livebook.manning.com/book/spark-in-action-second-edition/chapter-2/v-13/64

Apache Spark - arhitektura

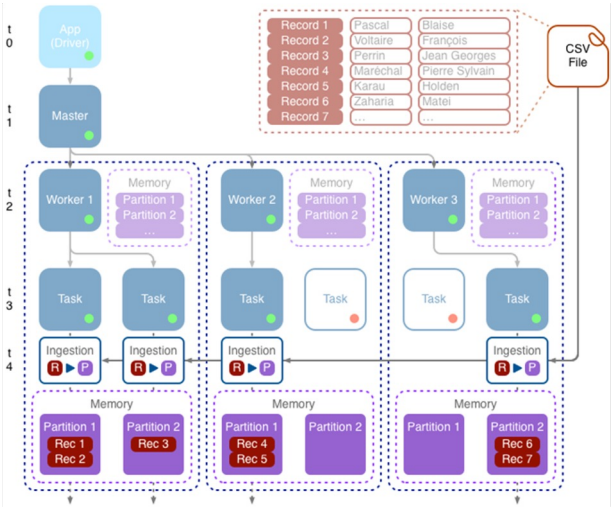

izvor: https://livebook.manning.com/book/spark-in-action-second-edition/chapter-2/v-13/64

Apache Spark - arhitektura

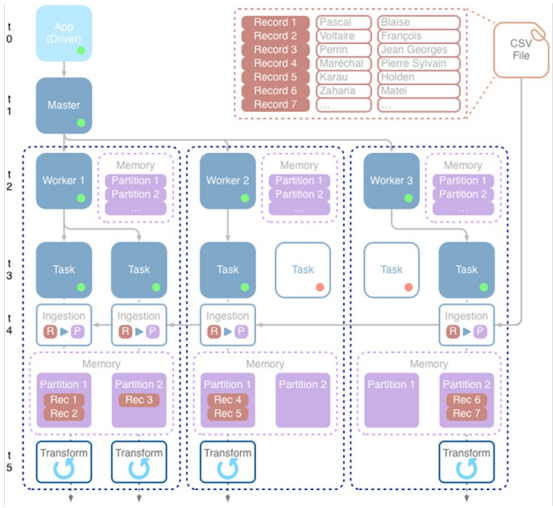

izvor: https://livebook.manning.com/book/spark-in-action-second-edition/chapter-2/v-13/64

208

208

Apache Spark - arhitektura

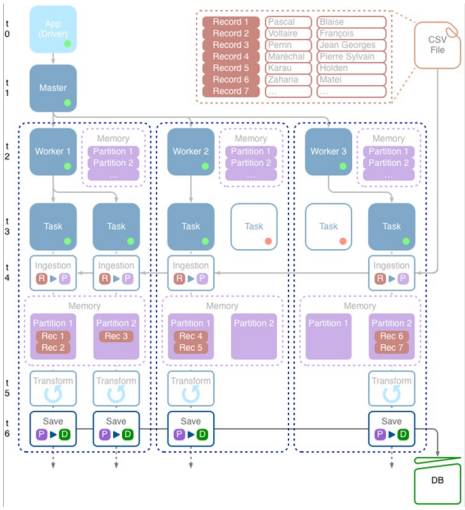

izvor: https://livebook.manning.com/book/spark-in-action-second-edition/chapter-2/v-13/64

209

209

Apache Spark - primer RDD

- Primer u programskom jeziku Java
  - prebrojati pojavljivanje reči u tekstualnom dokumentu

```
JavaRDD<String> textFile = sc.textFile("hdfs://...");

JavaPairRDD<String, Integer> counts = textFile
    .flatMap(s -> Arrays.asList(s.split(" ")).iterator())
    .mapToPair(word -> new Tuple2<>(word, 1))
    .reduceByKey((a, b) -> a + b);

counts.saveAsTextFile("hdfs://...");
```

210

210

Apache Spark - primer Dataframe

- Primer u programskom jeziku Java
  - identifikovati sve logove sa greškom u log datoteci

```
// Creates a DataFrame having a single column named "line"
JavaRDD<String> textFile = sc.textFile("hdfs://...");
JavaRDD<Row> rowRDD = textFile.map(RowFactory::create);
List<StructField> fields = Arrays.asList(
  DataTypes.createStructField("line", DataTypes.StringType, true));
StructType schema = DataTypes.createStructType(fields);
DataFrame df = sqlContext.createDataFrame(rowRDD, schema);

DataFrame errors = df.filter(col("line").like("%ERROR%"));
// Counts all the errors
errors.count();
// Counts errors mentioning MySQL
errors.filter(col("line").like("%MySQL%")).count();
// Fetches the MySQL errors as an array of strings
errors.filter(col("line").like("%MySQL%")).collect();
```

211

211

Pomoćni alati

212

Apache Pig

- Apache Pig
  - podiže nivo apstrakcije za obradu velikih skupova podataka
    - usled previše niskog nivoa na kojem se implementiraju map i reduce koraci
  - poseduje ekspresivnije operatore na višem nivou apstrakcije nego u MapReduce programima
  - namenjen istraživanju podataka u paketnoj obradi podataka
    - često korišćen usled prevelike kompleksnosti i dugog vremena potrebnog da se MapReduce program implementira
  - sastavljen iz dva dela
    - *Pig Latin* - jezik u kojem se implementiraju algoritmi obrade podataka
      - proširiv korisnički definisanim funkcijama
    - izvršno okruženje za *Pig Latin*
      - lokalno okruženje - za izvršavanje na lokalnoj mašini
      - distribuirano izvršavanje - za izvršavanje na Hadoop klasteru

213

Apache Pig

- Apache Pig
  - *Pig Latin* programi
    - opisuju tokove podataka
      - koje alat Pig prevodi u izvršive MapReduce programe koje potom i izvršava u sopstvenom izvršnom okruženju
    - predstavljaju sekvencu operacija (transformacija) koje se primenjuju na ulazne podatke u cilju dobijanja izlaznih podataka u odgovarajućem obliku
    - moguće ih je izvršiti samo nad delom svih podataka
      - i na taj način uočiti potencijalne greške pre nego što se krene sa obradom celog skupa podataka
    - generisani izvršni kôd nije optimalan kao ručno napisan MapReduce kôd
      - sa svakom novom verzijom, razlika je sve manja

214

214

Apache Pig

- Apache Pig i RSUBP
  - upitni jezik
    - Pig Latin je programski jezik za opis tokova podataka
    - SQL je deklarativni programski jezik
  - šema podataka
    - kod alata Pig, šema je opciona
  - strukture podataka
    - alat Pig podržava kompleksne strukture podataka, RDBMS ne
  - transakcije i indeksi
    - RSUBP podržava indekse i transakcije, alat Pig ne

215

215

Apache Pig - primer

- Analize meteoroloških podataka - Apache Pig
  - najveća izmerena temperatura

```
-- max_temp.pig: Finds the maximum temperature by year
records = LOAD 'input/ncdc/micro-tab/sample.txt'
          AS (year:chararray, temperature:int, quality:int);
filtered_records = FILTER records BY temperature != 9999 AND
          (quality == 0 OR quality == 1 OR quality == 4 OR quality == 5 OR quality == 9);
grouped_records = GROUP filtered_records BY year;
max_temp = FOREACH grouped_records GENERATE group,
          MAX(filtered_records.temperature);
DUMP max_temp;
```

216

216

Apache Hive

- Apache Hive
  - radni okvir koji treba da omogući funkcionalnosti tradicionalnih skladišta podataka nad Hadoop-om
    - omogućava korišćenje izraza koji liče na SQL
  - mešavina alata Pig i tradicionalnih RDBMS
    - sličnost sa alatom Pig:
      - koristi HDFS kao mehanizam za skladištenje podatka
      - ne podržava brze upite koji koriste indeksne strukture i transakcije
    - sličnost sa RDBMS
      - svi podaci se smeštaju u tabele i postoji jasno definisana šema
      - HiveQL je zasnovan na SQL-u

217

217

Apache Hive

- Apache Hive i RSUBP
  - upitni jezik
    - napravljen na osnovu SQL-92 standarda
      - ali ne podržava apsolutno sve operacije
  - šema podataka
    - RSUBP zahteva da podaci odgovaraju šemi prilikom učitavanja (engl. *schema on load*)
    - Hive zahteva da podaci odgovaraju šemi prilikom čitanja (engl. *schema on read*)
  - strukture podataka
    - alat Hive podržava kompleksne strukture podataka, RDBMS ne
  - ažuriranja, transakcije i indeksi
    - Hive ne podržava modifikaciju i brisanje postojećih podataka
    - Hive podržava samo kompaktne i *bitmap* indekse
    - zaključavanje je moguće na nivou particije i tabele

218

218

Apache Hive - primer

- Analize meteoroloških podataka - Apache Hive
  - najveća izmerena temperatura

```
CREATE TABLE records (year STRING, temperature INT, quality INT)
ROW FORMAT DELIMITED
FIELDS TERMINATED BY '\t';

LOAD DATA LOCAL INPATH 'input/ncdc/micro-tab/sample.txt'
OVERWRITE INTO TABLE records;

SELECT year, MAX(temperature)
FROM records
WHERE temperature != 9999
AND (quality = 0 OR quality = 1 OR quality = 4 OR quality = 5 OR quality = 9)
GROUP BY year;
```

219

219

Apache HBase

- Apache HBase
  - distribuirana, kolonski orijentisana baza podataka
    - koja koristi HDFS kao skladište podataka
  - koristi se kada je u okviru Hadoop rešenja potrebno u realnom vremenu dozvoliti **čitanje i pisanje slučajno odabranog sloga**
  - linearno skalira
    - dodavanjem novih čvorova u klaster
  - za razliku od RSUBP
    - podržava distribuirano skladištenje veoma velikih, retko popunjenih tabela
    - na svima dostupnom hardveru

220

220

Apache HBase

- Apache HBase i RSUBP
  - HBase
    - ne podržava indekse
    - omogućava automatsko particionisanje tabela
    - automatsko linearno skaliranje
    - radi na svima dostupnom hardveru
    - omogućava paketnu obradu
      - u potpunosti paralelnu
      - izvršavanjem MapReduce programa nad skladištem

221

221

Apache Zookeeper

- Apache Zookeeper
  - distribuirani sistem za koordinaciju servisa u Hadoop okruženju
  - sastoji se od skupa alata za upravljanje parcijalnim otkazima
  - osobine:
    - jednostavnost
      - pojednostavljen sistem datoteka koji pruža osnovne usluge rada sa datotekama
    - ekspresivnost
      - poseduje primitive za kreiranje velikog broja struktura podataka i protokola
      - npr. distribuirani redovi ...
    - visoka dostupnost
    - omogućava komunikaciju slabo spregnutih modula
      - moduli ne moraju da budu svesni jedni drugih
    - implementiran u vidu biblioteke

Literatura

- Tom White: Hadoop - The Definitive Guide, O'Reilly
- Mark Grover, Ted Malaska, Jonathan Seidman, Gwen Shapira: Hadoop Application Architectures, O'Reilly
- Ilya Katsov, MapReduce patterns, Online: https://highlyscalable.wordpress.com/2012/02/01/mapreduce-patterns/
- Matei Zaharia, Bill Chambers, Spark: The Definitive Guide, O'Reilly
- Ty Shaikh, Batch Processing — Apache Spark, Online: https://blog.k2datascience.com/batch-processing-apache-spark-a67016008167