

UVOD U

APACHE Spark

Petar Zečević



SV Group d.o.o.

- ▶ Prvi IBM Business Partner Premier Level (od 14.3. 2003.)
- ▶ Kontinuirana priznanja IBM CEMA (od 2000. god.)
- ▶ Gazela za 2007 i 2008.
- ▶ ISO 9001:2002 od 2007.
- ▶ ISO 9001:2008 od 2010.
- ▶ VMware Enterprise Solution Partner
- ▶ RedHat i Microsoft partner



SV Group d.o.o.

► Financijska industrija:

- Zagrebačka banka
- Privredna banka Zagreb
- Hypo Alpe Adria Bank
- Hrvatska poštanska banka
- Erste bank
- Generali osiguranje, Unija , Prva stambena štedionica
- Slatinska banka, Credo banka, Centar banka, BKS

 Zagrebačka banka
UniCredit Group

 PBZ

 HYPO GROUP
ALPE ADRIA

 HPB
HRVATSKA POŠTANSKA BANKA



 ERSTE BANK



 GENERALI
GROUP

 BKS Bank

 UNIQA
Otpisujte nove prenove.

 KVARNER
VIENNA INSURANCE GROUP

► Državne institucije

- HZMO
- MUP
- Ministarstvo financija
- APIS IT, FINA
- Regos, AKD


Hrvatski zavod za mirovinsko osiguranje


REPUBLIKA HRVATSKA
MINISTARSTVO FINANCIJA


RH
MUP


akd
AGENCIJA ZA
KOMERCIJALNU
DJELATNOST

 Regos

 NPIS IT d.o.o.

 Fina

► Distribucija

- Agrokor/mStart
- Konzum, Multipluscard
- Tisak

 AGROKOR

 mStart

 TISAK

 MultiPlusCard

► Industrija

- INA


INDUSTRija NAFTE, d.d.

 RECRO

 SIEMENS

 Teched
CONSULTING SERVICES

 s&t

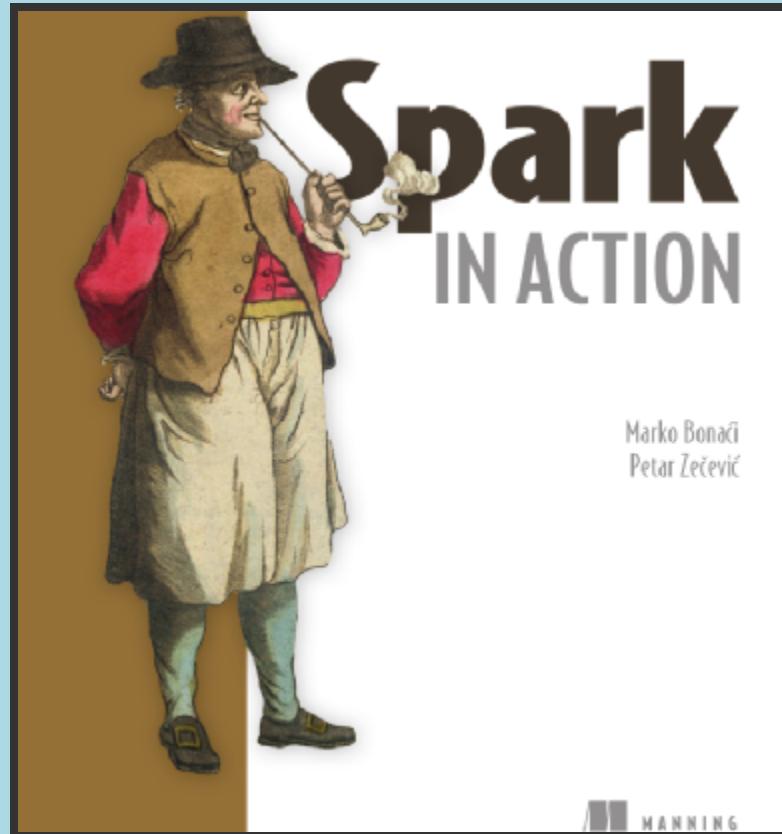
 SV GROUP

► HR IT tvrtke

 IBM

 COMBIS

POPUST OD 50%!



<http://www.manning.com/bonaci/>

APACHE SPARK ZAGREB MEETUP GRUPA



<http://www.meetup.com/Apache-Spark-Zagreb-Meetup/>

MALA ANKETA

- Prvi put čujem za Spark
- Čuo sam za Spark, ali nisam ga koristio
- Instalirao sam Spark i pokretao jobove
- Spremam se koristiti Spark u produkciji
- Već ga koristim u produkciji

UVOD U APACHE SPARK

- Malo povijesti
- U čemu je problem?
- O Hadoopu
- Što donosi Spark?
- Runtime arhitektura
- Spark komponente
- Demo
- Pitanja i rasprava

MALO POVIJESTI

POVIJEST SPARKA

- Nastao 2009. godine u AMPLabu Berkley-a
- 2010. godine postao open source



- Strelovit rast:
- Danas ima više od 400 commitera



- Matei Zaharia

i  databricks™

SPARK DANAS

- Uključen u najveće Hadoop distribucije:



- Dvije godišnje konferencije:
The logo for Spark Summit 2015. It features the word "Spark" in a large, bold, black sans-serif font. An orange five-pointed star is positioned above the letter "k". Below "Spark", the word "Summit" is written in a smaller, black sans-serif font, followed by "2015" in a blue sans-serif font.
- Tečajevi i certifikacije
- spark-packages.org - trenutno 55 paketa
- Polako zamjenjuje Hadoop kao sinonim za BigData

ZAŠTO SPARK?

KAKO EFIKASNO OBRADITI GOLEME KOLIČINE PODATAKA?

-     ne stanu u RDBMS
- Ogroman rast broja korisnika (Facebook 8 k/s, Twitter 6 k/s, LinkedIn 2 k/s)
- Većina korisnika nije pasivna
- NASA, genetski algoritmi, industrijski senzori, simulacije...
- NASA generira 700 TB/s



HDFS - nastao kao implementacija Google FS-a (2003)

- Običan desktop (commodity) hardware
- Svaki podatak repliciran na 3 mesta (default)

MapReduce

- Kako paralelizirati obradu podataka
- Program se šalje k podacima (program je manji)
- Oporavak od grešaka

YARN (MapReduce 2)

- Generalizacija resource managementa

SLABOSTI HADOOPA

- Rigidan programski model
- Zadaci prikladni za funkcionalno programiranje
- Pisanje na disk je nužno, kao i sortiranje
- Ne može se koristiti za realtime (lambda arhitektura)
- Low-level framework

HADOOP ECOSYSTEM

APACHE
HBASE



HYPERTABLE INC



cloudera®
IMPALA

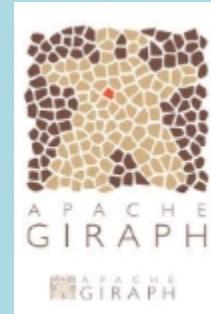


STORM

kafka



OOZIE



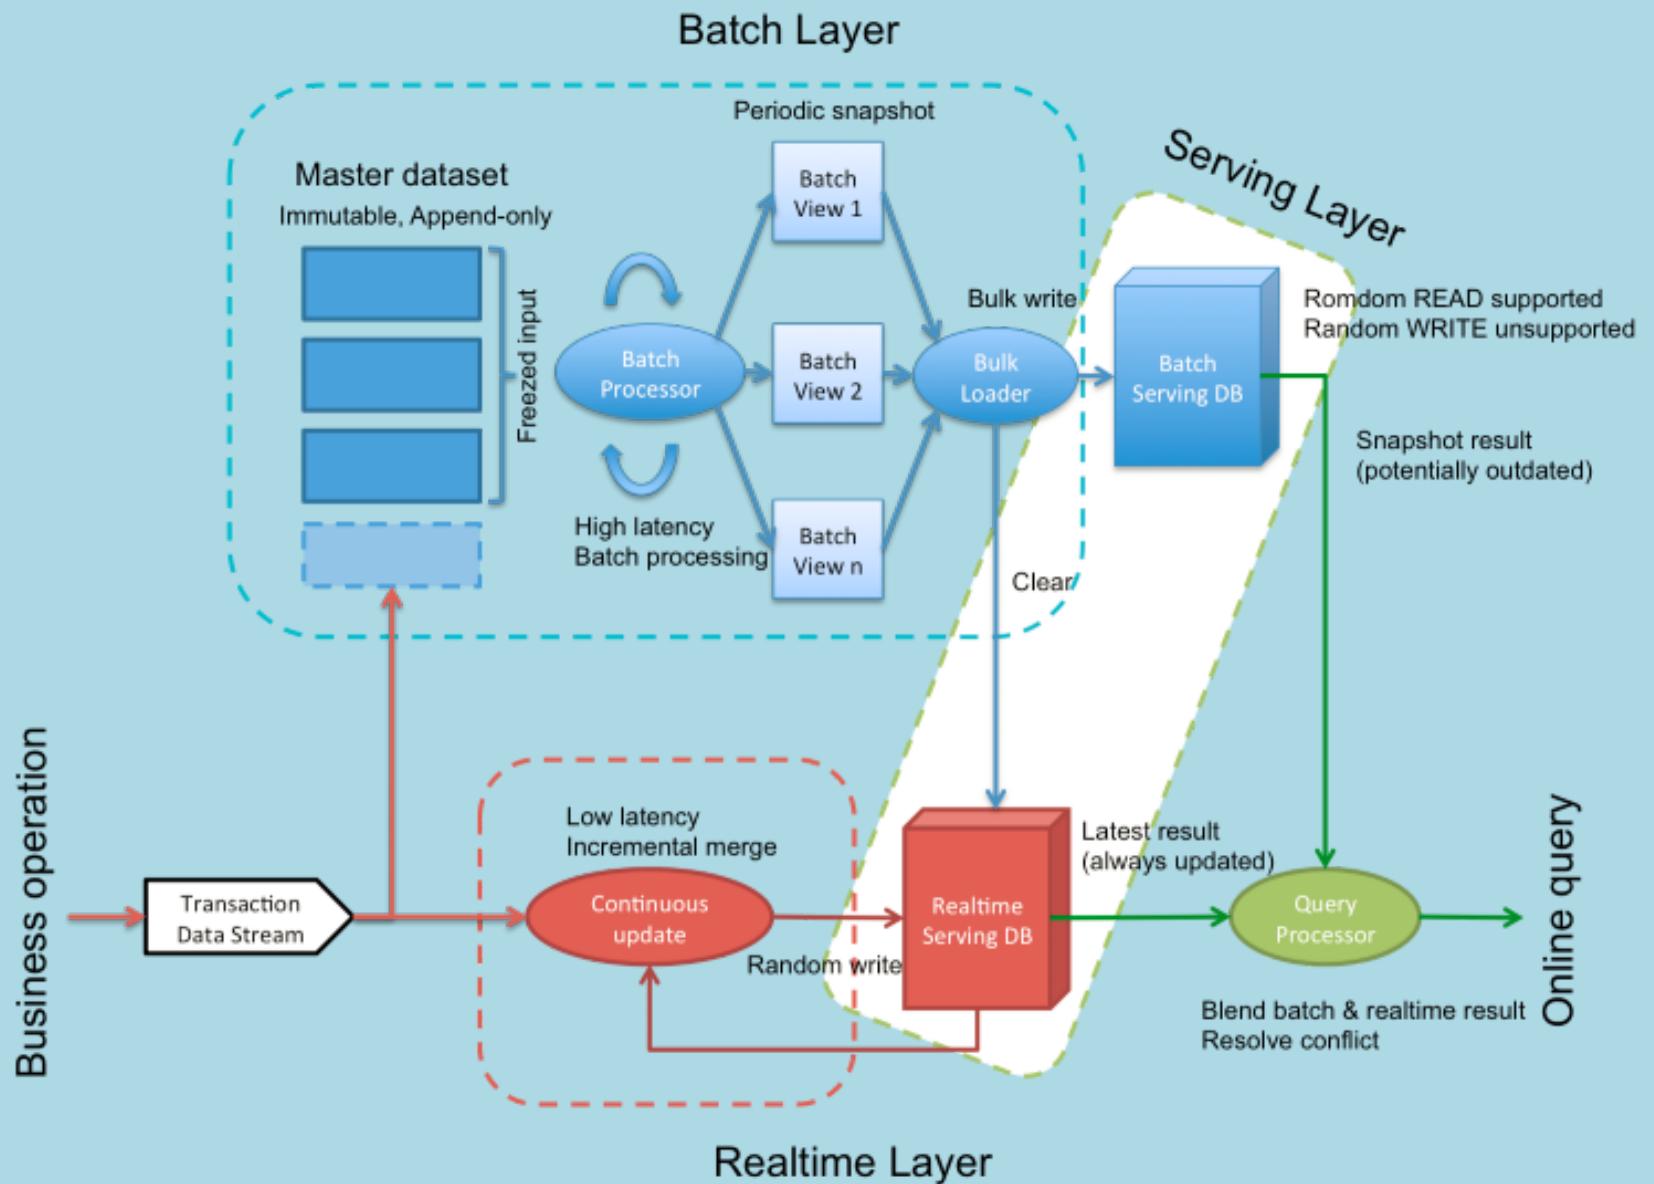
mahout

Apache Ambari
<http://incubator.apache.org/ambari>

LAMBDA ARHITEKTURA

JavaCro'15

Kako imati ažurnu sliku podataka?



ŠTO DONOSI SPARK?

APACHE SPARK

- Može se koristiti i za **batch i realtime** obradu podataka
- Često nije potrebno spremati međupodatke na disk
- Podatke uglavnom **drži u memoriji** - i do **100x** brži od Hadoop M/R-a
- Pisan u **Scali**, podržava **Python i Javu**
- Izvršava se na Standalone, YARN ili Mesos clusteru
- **Jedinstvena platforma** za različite vrste algoritama
- Brži razvoj kroz **Scala i Python shell**
- Pisanje distribuiranih programa **slično pisanju lokalnih**

HADOOP M/R WORD COUNT - MAIN

```
public static void main(String[] args) throws Exception {  
    JobConf conf = new JobConf(WordCount.class);  
    conf.setJobName("Hadoop wordcount");  
  
    conf.setOutputKeyClass(Text.class);  
    conf.setOutputValueClass(IntWritable.class);  
    conf.setMapperClass(Map.class);  
    conf.setCombinerClass(Reduce.class);  
    conf.setReducerClass(Reduce.class);  
  
    conf.setInputFormat(TextInputFormat.class);  
    conf.setOutputFormat(TextOutputFormat.class);  
    FileInputFormat.setInputPaths(conf, new Path(args[0]));  
    FileOutputFormat.setOutputPath(conf, new Path(args[1]));  
  
    JobClient.runJob(conf);  
}
```

HADOOP M/R WORD COUNT - MAPPER

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

    public void map(LongWritable key, Text value,
        OutputCollector<Text, IntWritable> output, Reporter reporter) throws
    {
        String line = value.toString();
        StringTokenizer tokenizer = new StringTokenizer(line);
        while (tokenizer.hasMoreTokens()) {
            word.set(tokenizer.nextToken());
            output.collect(word, one);
        }
    }
}
```

HADOOP M/R WORD COUNT - REDUCER

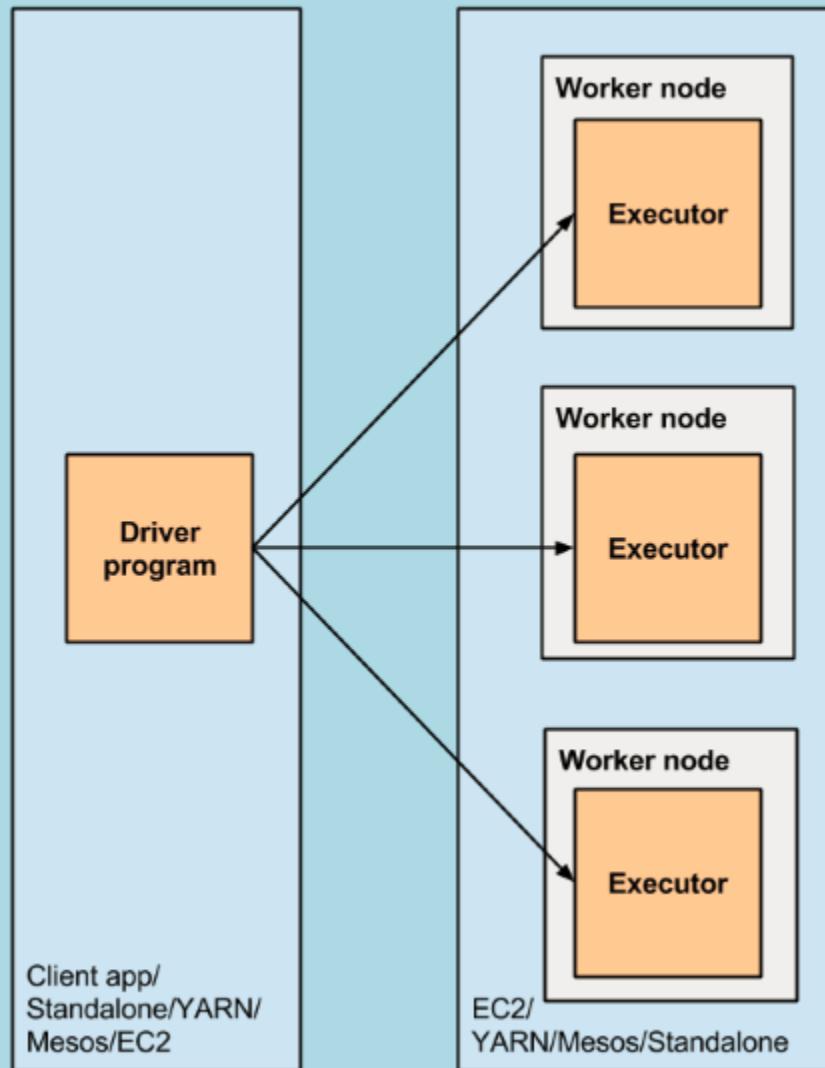
```
public static class Reduce extends MapReduceBase
    implements Reducer<Text, IntWritable, Text, IntWritable>
{
    public void reduce(Text key, Iterator<IntWritable> values,
                      OutputCollector<Text, IntWritable> output, Reporter reporter) throws
    {
        int sum = 0;
        while (values.hasNext()) {
            sum += values.next().get();
        }
        output.collect(key, new IntWritable(sum));
    }
}
```

SPARK WORD COUNT IN SCALA

```
val conf = new SparkConf().setAppName("Spark wordcount")
val sc = new SparkContext(conf)
val file = sc.textFile("hdfs://...")
val counts = file.flatMap(line => line.split(" "))
    .map(word => (word, 1))
    .reduceByKey(_ + _)
counts.saveAsTextFile("hdfs://...")
```

SPARK KOMPONENTE

RUNTIME TOPOLOGIJA



SPARK CORE

- RDD - Resilient Distributed Dataset
- Spark Web UI
- Spark shell
- Učitavanje i spremanje datoteka
- Serijalizacija i deserijalizacija taskova
- Broadcast varijable i akumulatori

SPARK CORE

Detaljnije o RDDovima

- Lista particija
- Funkcija za izračun podataka unutar particija
- Transformacije - pretvaraju jedan RDD u drugi
 - map, reduce, filter, zip, pipe
 - mapByKey, reduceByKey, mapPartitions, subtract, union, ...
- Akcije - vraćaju neki rezultat
 - collect, count, foreach
 - first, take, aggregate, stats, ...
- Dependencies na druge RDD-ove
- Keširanje

SPARK SQL

- Obrada strukturiranih podataka
- Učitavanje i spremanje JSON, Parquet datoteka
- Schema inference
- Razumije SQL naredbe
- Spremanje podataka o tablicama u Hive Metastore
- Thrift JDBC server

SPARK STREAMING

- Spark API primijenjen na realtime obrade
- "Exactly once" semantika out of the box
- Čita podatke s TCPIP porta, HDFS-a, S3, Kafka, ZeroMQ, Flume-a, ...

SPARK STREAMING



SPARK STREAMING - EXAMPLE

```
import org.apache.spark._  
import org.apache.spark.streaming._  
import org.apache.spark.streaming.StreamingContext.  
val conf = new SparkConf().setMaster("local[2]").setAppName("NetworkWordCount")  
val ssc = new StreamingContext(conf, Seconds(1))  
  
val lines = ssc.socketTextStream("localhost", 9999)  
val words = lines.flatMap(_.split(" "))  
  
val pairs = words.map(word => (word, 1))  
val wordCounts = pairs.reduceByKey(_ + _)  
  
ssc.start()  
ssc.awaitTermination()
```

SPARK GRAPHX

- Mnogi problemi se mogu rješavati pomoću grafova - socijalne mreže, GPS mape, napredovanje bolesti itd.
- Graf algoritmi uz ostale funkcionalnosti Sparka
- Vertices (vrhovi), edges (grane) i vezani user-defined objekti
- Implementacija Pregela - slanje poruka kroz graf
- Algoritmi: Page rank, shortest path, connected components, triangle counting ...

SPARK MLLIB

- Linearna algebra (vektori, matrice)
- Klasifikacija i regresija
 - Linearne metode
 - Logistička regresija
 - Support Vector Machines
 - Linearna regresija (Linear least squares)
 - Decision trees
 - Naive Bayes (klasifikacija dokumenata)
- k-means clustering
- Collaborative filtering (alternating least squares)
- Redukcija dimenzija



SPARK CORE - DEMO

```
spark-shell --master yarn-client --num-executors 3 --executor-memory 2G

val licrdd = sc.textFile("hdfs:///tmp/LICENSE.txt", 6)
val trimmed = licrdd.map(x => x.trim)
val noempty = trimmed.filter(x => x != "")
val split = noempty.flatMap(x => x.split(" ")).filter(_ != "")
val pairs = split.map(x => (x, 1))
val sums = pairs.reduceByKey(_ + _)
val sorted = sums.sortBy(_.value, false)
sorted.top(10)
```

SPARK SQL - DEMO

```
import org.apache.spark.sql.hive.HiveContext
val sqlContext = new HiveContext(sc)
import sqlContext._
val json = sqlContext.jsonFile("hdfs://tmp/test.json")
json.schema
json.registerTempTable("myusers")
val sel = sqlContext.sql("select * from myusers")
val countries = sel.map(row => row.getString(0))
val countriesd = sqlContext.sql("select distinct country from myusers")
val franceusers = sqlContext.sql("select last_name, first_name from myusers")
```

SPARK MLLIB - DEMO

```
import org.apache.spark.mllib.classification.NaiveBayes
import org.apache.spark.mllib.linalg.Vectors
import org.apache.spark.mllib.regression.LabeledPoint
val data = sc.textFile("hdfs:///tmp/numberdata.txt", 6)
val parsedData = data.map( line => {
    val parts = line.split(',')
    LabeledPoint(parts(0).toDouble, Vectors.dense(parts.slice(1, parts.length)))
})
val model = NaiveBayes.train(parsedData, lambda=1.0)
val testitem = ""
valtestdata = sc.parallelize(List(testitem))
val mapped = testdata.map(line => Vectors.dense(line.split(",")).map(_.toDouble))
model.predict(mapped).collect()
```

SPARK MLLIB - DEMO

Sliku  pretvorimo u niz 0 i 1:

```
val testitem = "1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,  
1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,  
1,1,1,1,1,1,1,1,1,0,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,0,0,  
1,1,1,1,1,1,1,1,1,0,0,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,0,  
1,1,1,1,1,1,1,1,1,1,0,0,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,0,  
1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,  
1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,  
1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,  
1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,  
1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,  
1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,  
1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,  
1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,  
1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1"
```

Rezultat predikcije:

```
model.predict(mapped).collect()  
res0: Array[Double] = Array(1.0)
```

PITANJA, KOMENTARI?