

Distribuirano Programiranje

Java Spark

Aleksandar Kartelj

Ukratko

1. Paralelna paradigma koristi konkurentna izračunavanja u cilju ubrzavanja i najčešće ima deljenu memoriju među jedinicama izračunavanja.
 - Da bi deljena memorija imala smisla (da bi bila dovoljno brza), fizičke udaljenosti među jedinicama izračunavanja (procesorima) moraju biti male što znači da su one obično smeštene na jednom mestu (klasteri, mejnfrejmovi...)
2. Distribuirana paradigma koristi fizički "razbacane" jedinice izračunavanja i te jedinice nemaju deljenu memoriju u klasičnom smislu.
 - Jedinice (čvorovi, eng. nodes) su nezavisnije i izbegava se komunikacija osim kada se radi nekakvo sazimanje podataka.
 - Jedinice su u distribuiranoj paradigmi obično računari, a ne procesori kao što je to slučaj kod paralelne.

Ukratko nastavak

- Model izračunavanja koji ćemo primenjivati je vid paralelizma nad podacima (Data parallelism) se može svesti na dve faze:
 1. Svaki čvor primenjuje istu operaciju nad podskupom sveukupnih podataka
(ovo liči na map funkciju višeg reda u Haskell-u)
 2. Nakon što je operacija mapiranja primenjena radi se sažimanje rezultata među čvorovima
(ovo liči na fold/reduce funkciju višeg reda u Haskell-u)

Neretko se ceo koncept ovakvog izračunavanja naziva **map-reduce**.

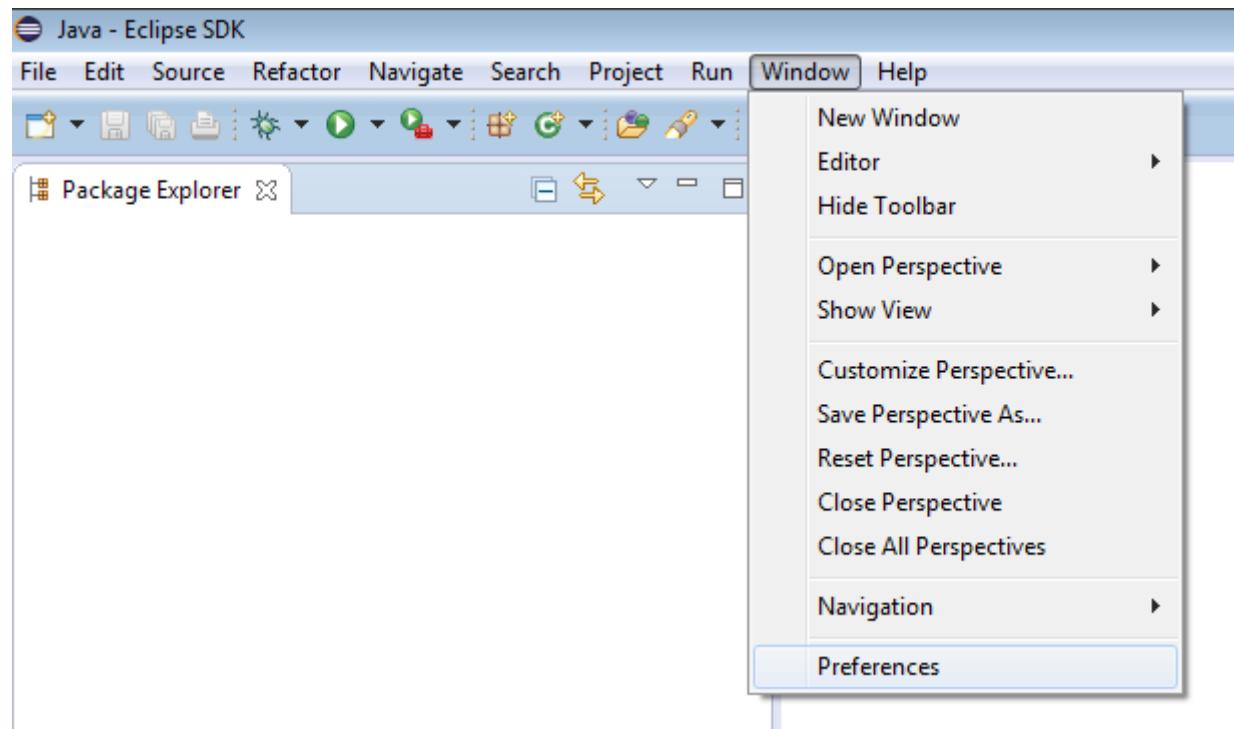
Radna platforma

- Radi se pod Java Spark platformom
- Moguća su dva režima izvršavanja:
 1. Lokalni u kojem jezgra procesora glume čvorove
 2. Pravi distribuirani u kojem se radi na mnogo većem broju čvorova:
(zahteva povezivanje sa HDFS (Hadoop Distributed File System))
- Od ostalih stvari poželjna je Maven podrška za Eclipse
- Rad sa Lambda izrazima koji su podržani počev od Java verzije 8
- Cilj prvog tročasa je da svima proradi platforma!!!

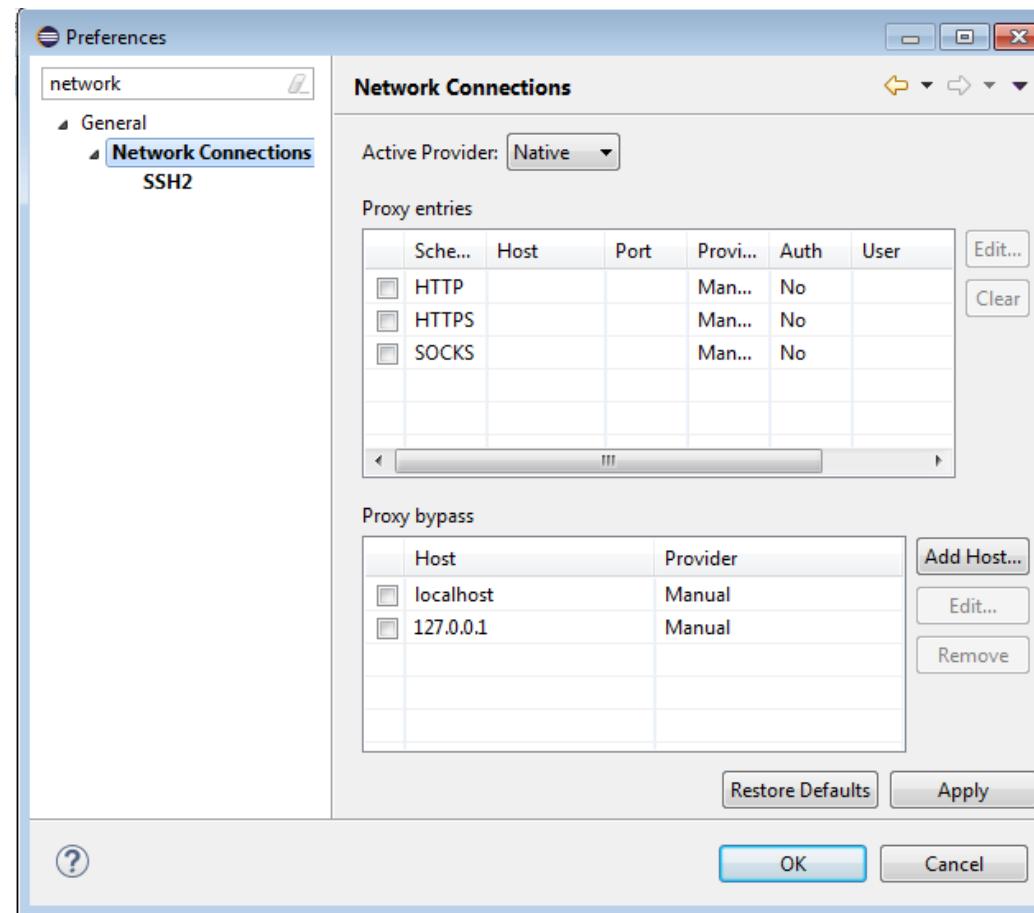
„Bolno“ podešavanje svega na fakultetskim računarima

- Da bismo podesili razvojno okruženje u Eclipse alatu potrebno je da prođemo kroz niz koraka:
 1. Eclipse podešavanje proxy-ja
 2. Pravljenje maven projekta
 - A. Pravljenje settting.xml ako ne postoji
 - B. Postavljanje proxy-ja u settings.xml-u
 - C. Postavljanje autoupdate podešavanja za maven
 - D. Pravljenje projekta čarobnjak (wizard)
 3. Dodavanje podrške za Spark u maven projekat
 - A. Podešavanje verzije Jave
 4. Izvršavanje jednostavnog programa u lokalnom okruženju
- Korak 1) i 2B) mogu biti preskočeni u slučaju da se ne radi na fakultetskim računarima odnosno ako ne postoji proxy. Korak 2A) može biti preskočen ako postoji settings.xml u maven repozitorijumu. 3A) može biti preskočeno ako je već podešana verzija 8 Jave.

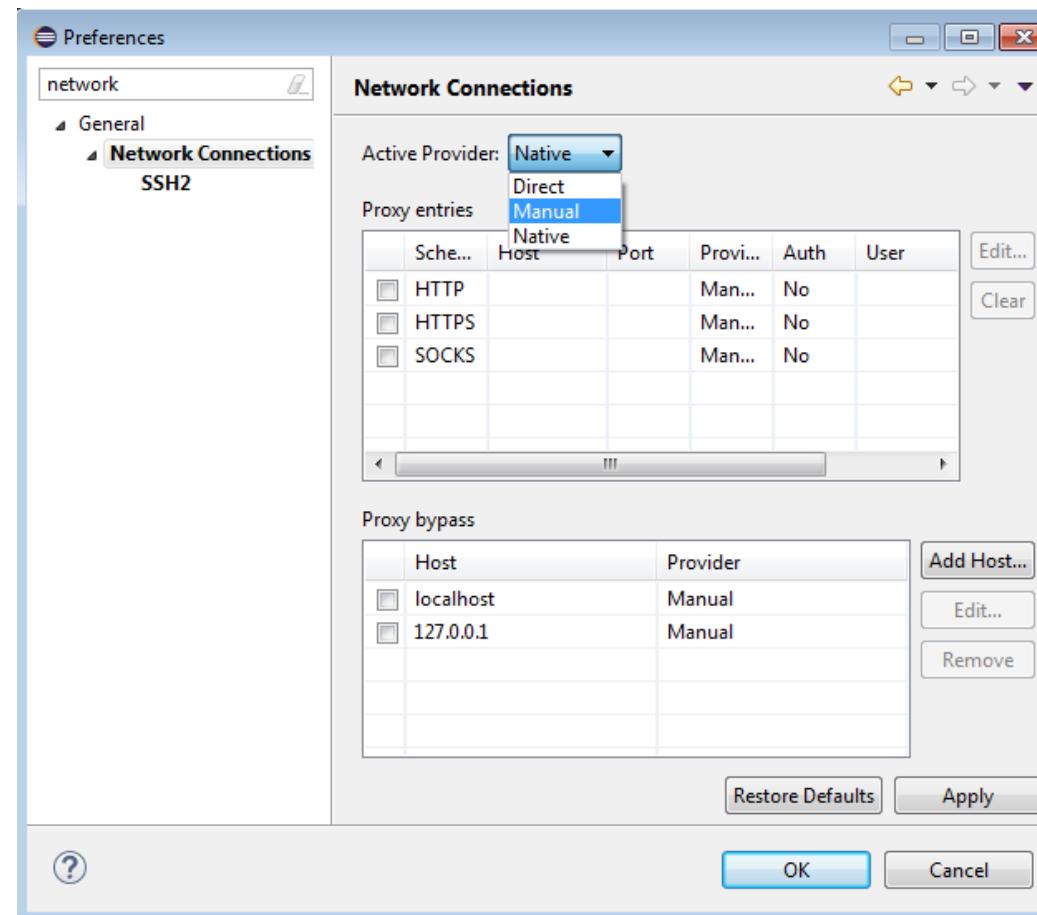
1. Eclipse podešavanje proxy-ja



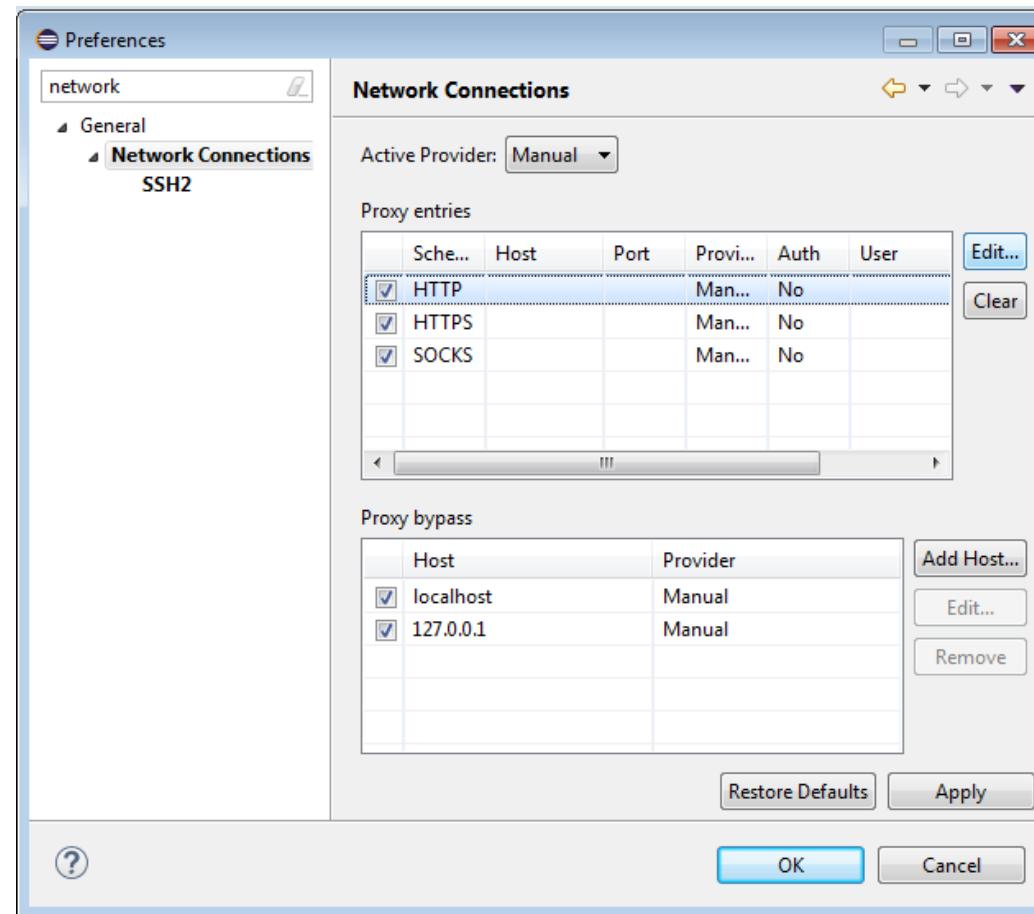
1. Eclipse podešavanje proxy-ja



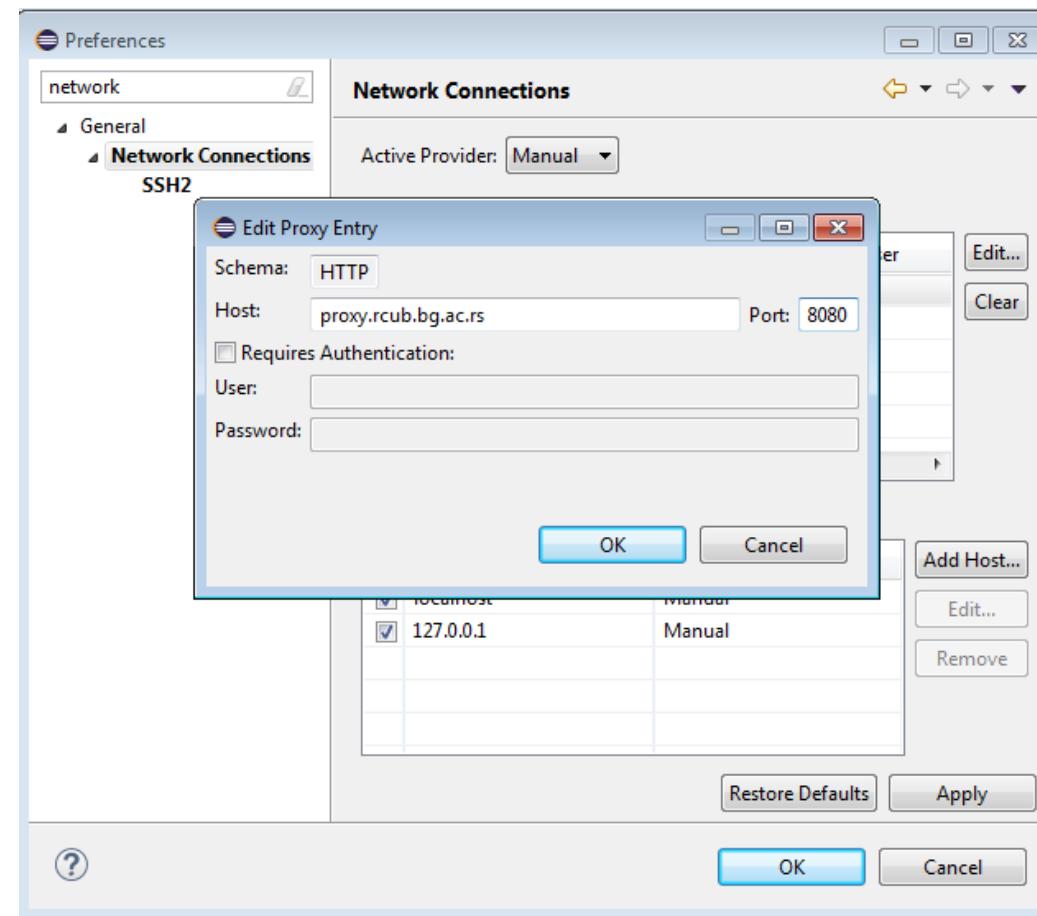
1. Eclipse podešavanje proxy-ja



1. Eclipse podešavanje proxy-ja



1. Eclipse podešavanje proxy-ja

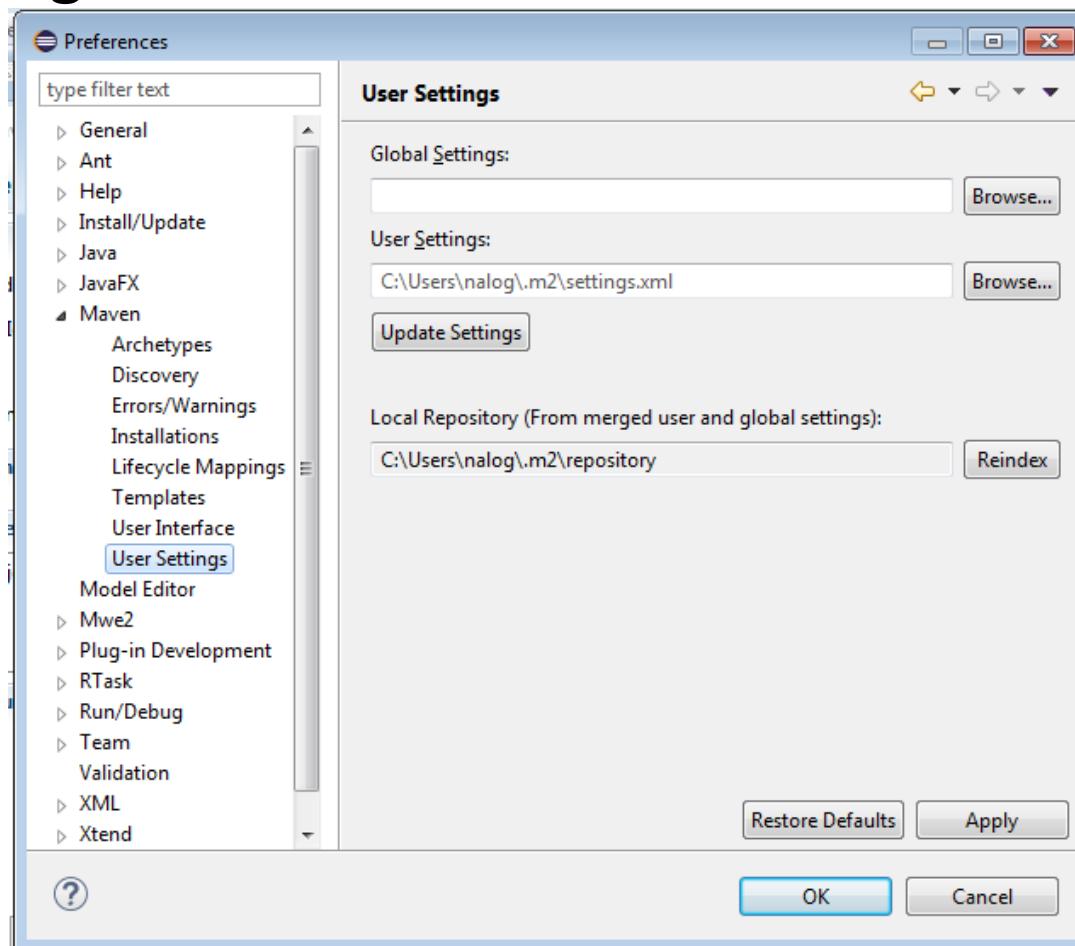


2. Pravljenje maven projekta

- Šta je Maven?
- Maven je alat koji se koristi pri razvoju aplikacija u cilju lakše integracije sa već postojećim bibliotekama klase.
- Za nas su najbitnije sledeće funkcionalnosti:
 1. Pravljenje gotovih šabloni aplikacija
 2. Ubacivanje potrebnih biblioteka za rad sa Spark-om i svih njihovih zavisnosti jednostavnim konfigurisanjem pom.xml datoteke

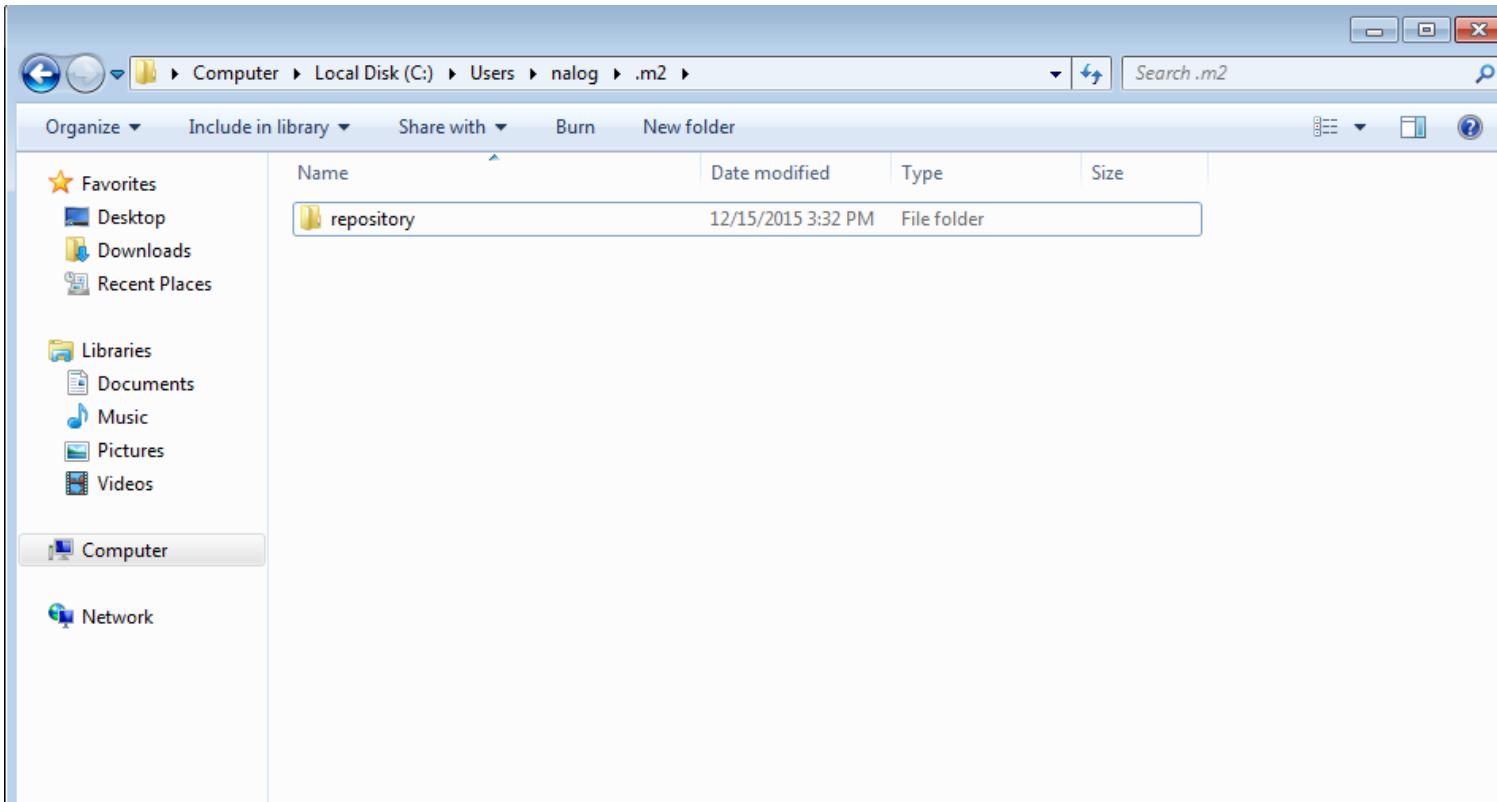
2A. Pravljenje maven projekta – Pravljenje settings.xml datoteke

- Lokacija settings.xml datoteke se vidi na slici.



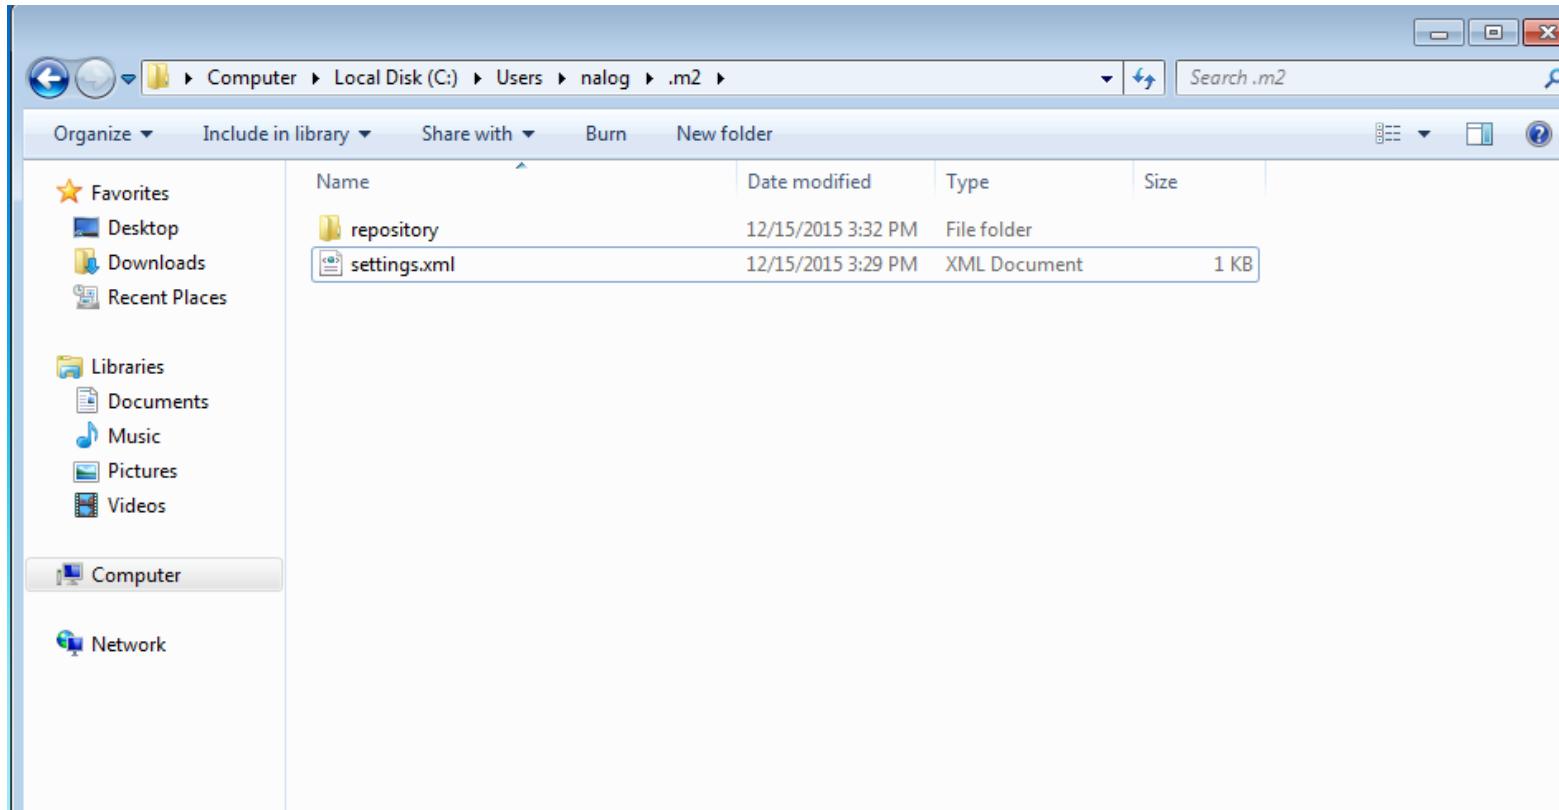
2A. Pravljenje maven projekta – Pravljenje settings.xml datoteka

- Ovo se radi samo ukoliko u korisničkom home direktorijumu ne postoji settings.xml u suprotnom preskočite 1A deo.



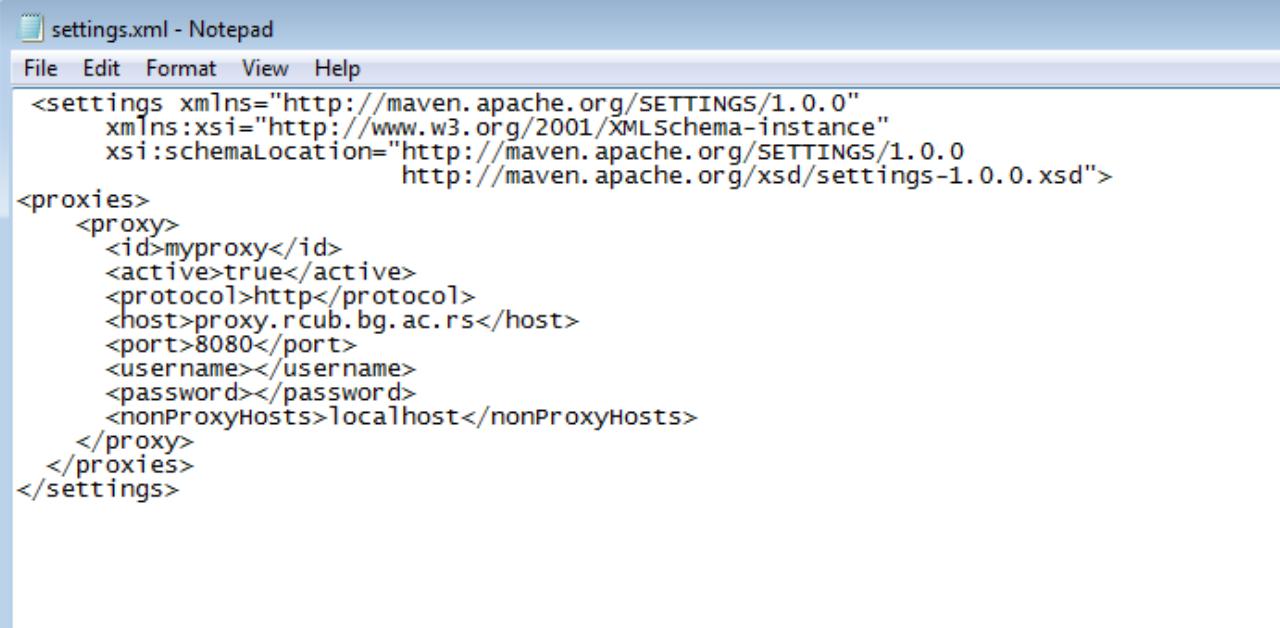
2A. Pravljenje maven projekta – Pravljenje settings.xml datoteka

- Napravite datoteku sa nazivom settings.xml kao na slici u .m2 direktorijumu.



2A. Pravljenje maven projekta – Pravljenje settings.xml datoteka

- Otvorite ga tekstualnim editorom i dodajte sadržaj kao ispod samo bez proxies segmenta. Dakle samo otvoreni i zatvoreni settings tagovi.
- Ovako podešen settings.xml možete preuzeti [odavde](#).

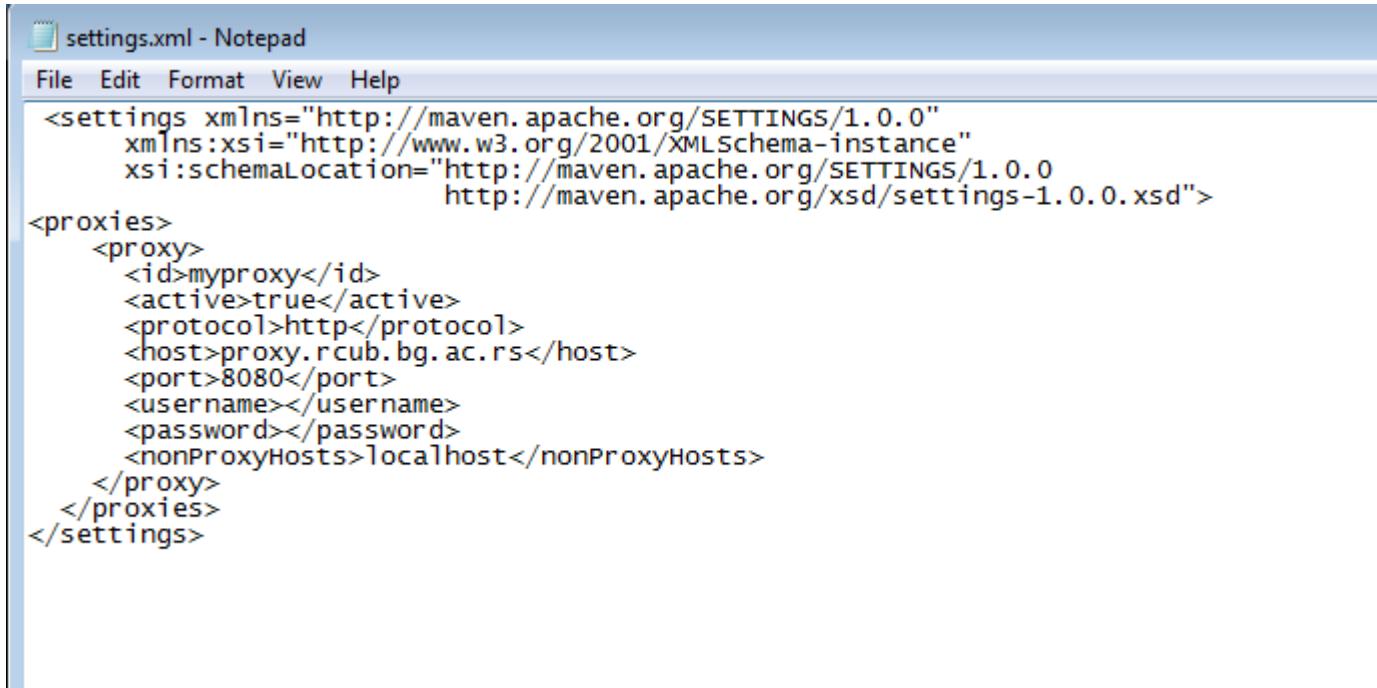


The screenshot shows a Windows Notepad window titled "settings.xml - Notepad". The menu bar includes File, Edit, Format, View, and Help. The XML code is displayed in the main pane:

```
<settings xmlns="http://maven.apache.org/SETTINGS/1.0.0"
          xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
          xsi:schemaLocation="http://maven.apache.org/SETTINGS/1.0.0
                               http://maven.apache.org/xsd/settings-1.0.0.xsd">
  <proxies>
    <proxy>
      <id>myproxy</id>
      <active>true</active>
      <protocol>http</protocol>
      <host>proxy.rcub.bg.ac.rs</host>
      <port>8080</port>
      <username></username>
      <password></password>
      <nonProxyHosts>localhost</nonProxyHosts>
    </proxy>
  </proxies>
</settings>
```

2B. Pravljenje maven projekta – Postavljanje proxy-ja u settings.xml-u

- Ako na Internet idete preko proxy-ja onda dodajte sav sadržaj koji je na slici. Naravno, umesto proxy-ja sa slike upišite adekvatne informacije.

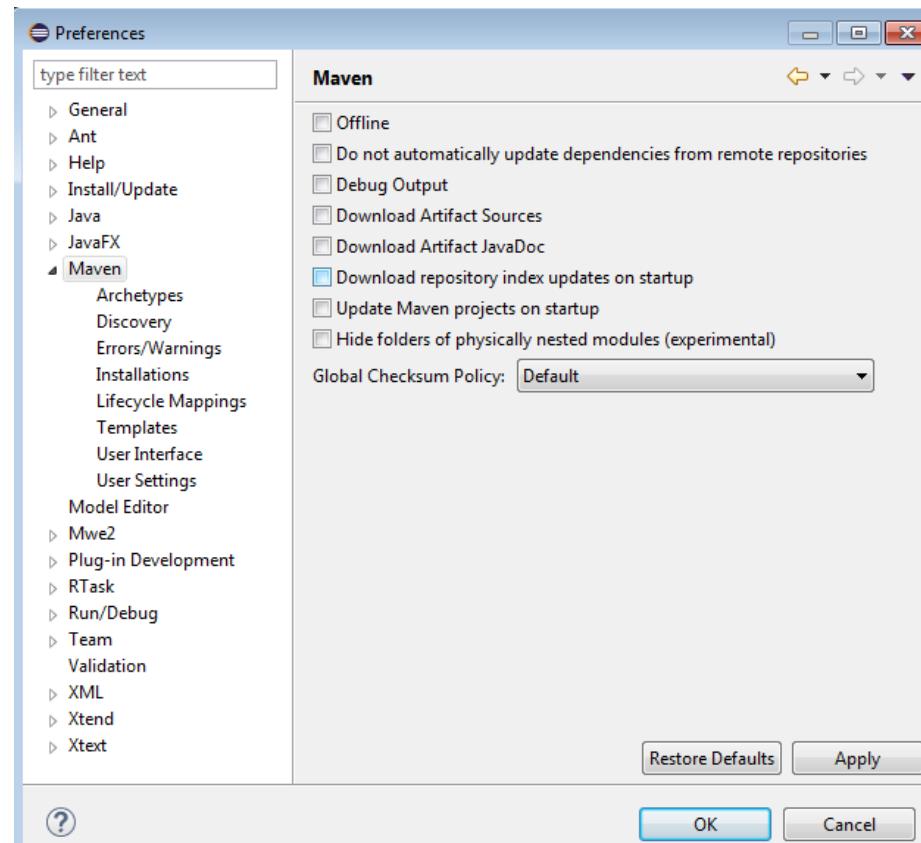


The screenshot shows a Windows Notepad window titled "settings.xml - Notepad". The menu bar includes File, Edit, Format, View, and Help. The XML code in the main pane is as follows:

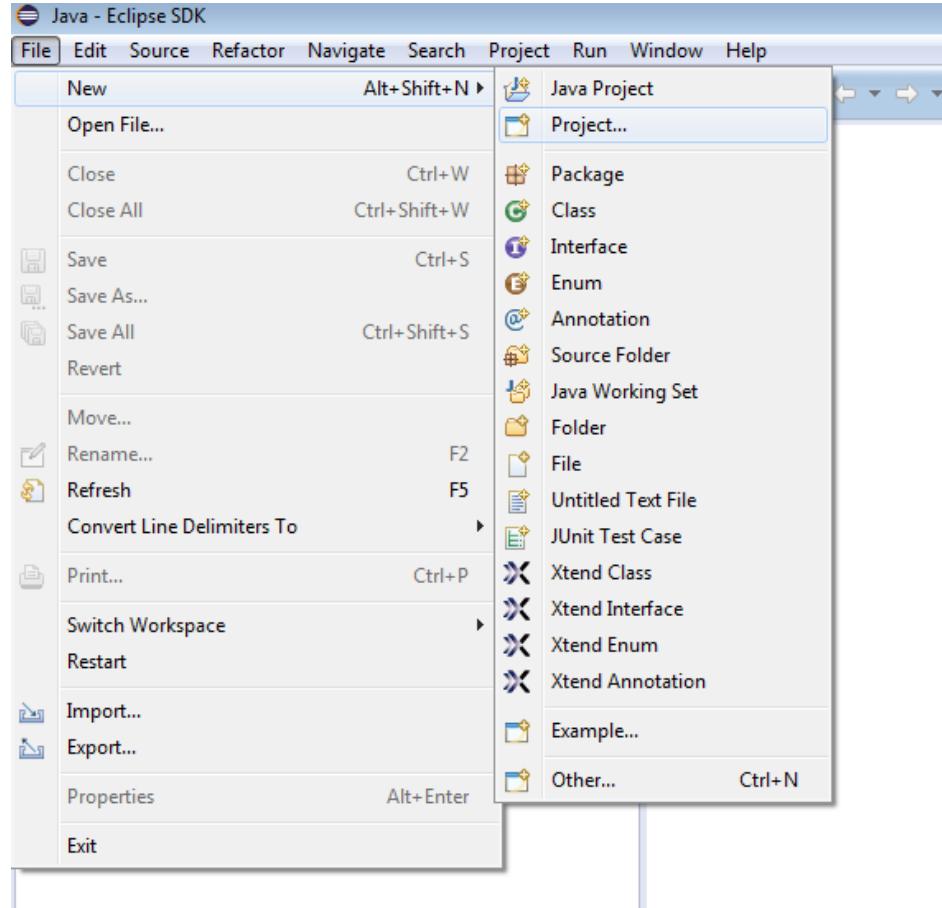
```
<settings xmlns="http://maven.apache.org/SETTINGS/1.0.0"
          xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
          xsi:schemaLocation="http://maven.apache.org/SETTINGS/1.0.0
                               http://maven.apache.org/xsd/settings-1.0.0.xsd">
  <proxies>
    <proxy>
      <id>myproxy</id>
      <active>true</active>
      <protocol>http</protocol>
      <host>proxy.rcub.bg.ac.rs</host>
      <port>8080</port>
      <username></username>
      <password></password>
      <nonProxyHosts>localhost</nonProxyHosts>
    </proxy>
  </proxies>
</settings>
```

2C. Pravljenje maven projekta – Postavljanje autoupdate za maven

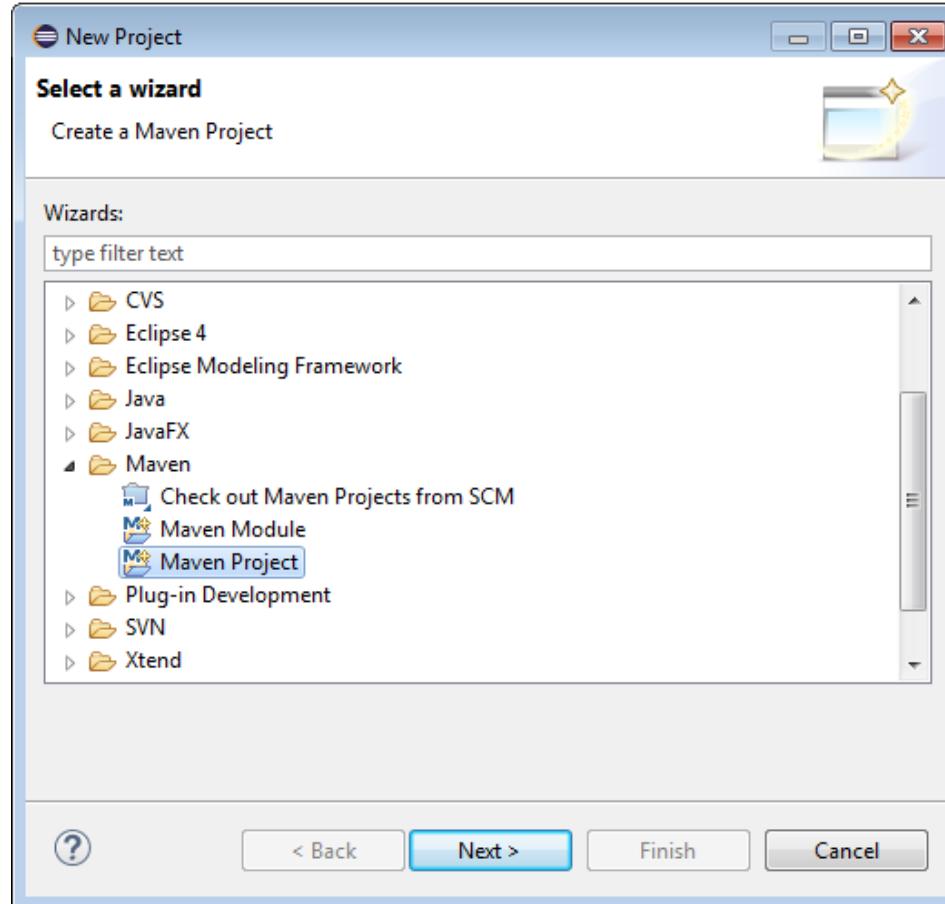
- Maven podešavanja u Window->Preferences treba da izgledaju ovako:



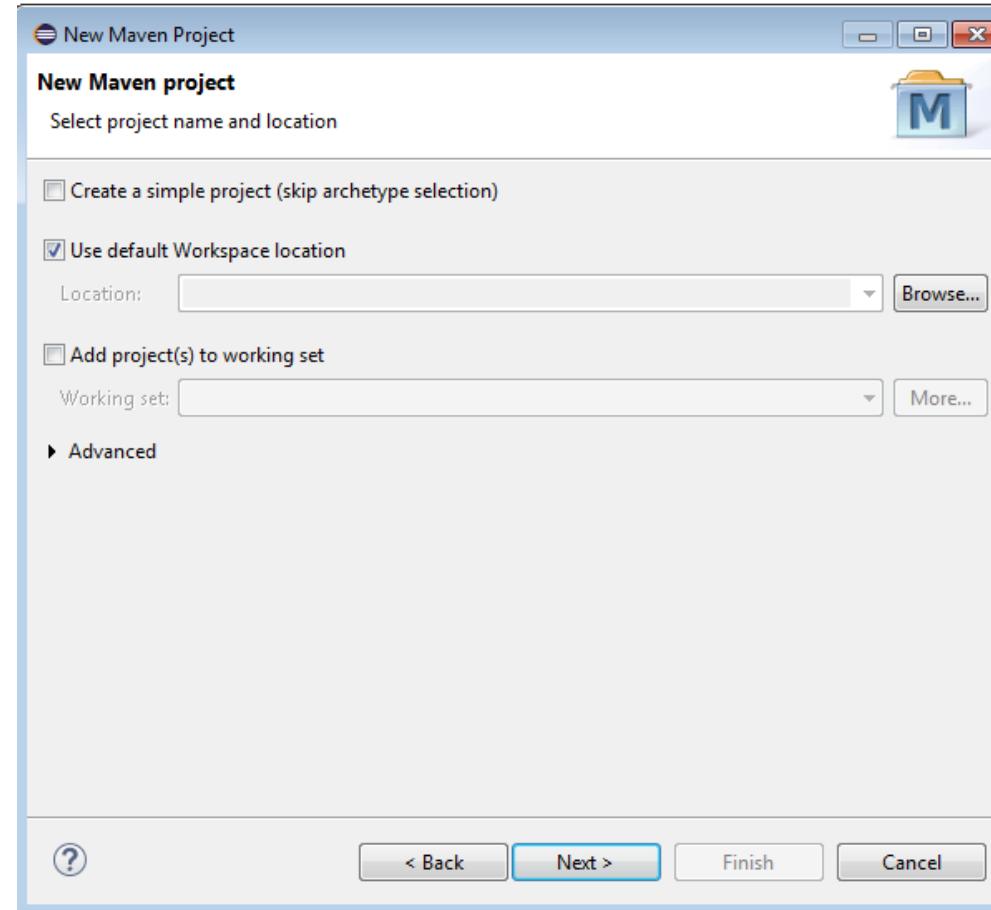
2D. Pravljenje maven projekta – čarobnjak (wizard)



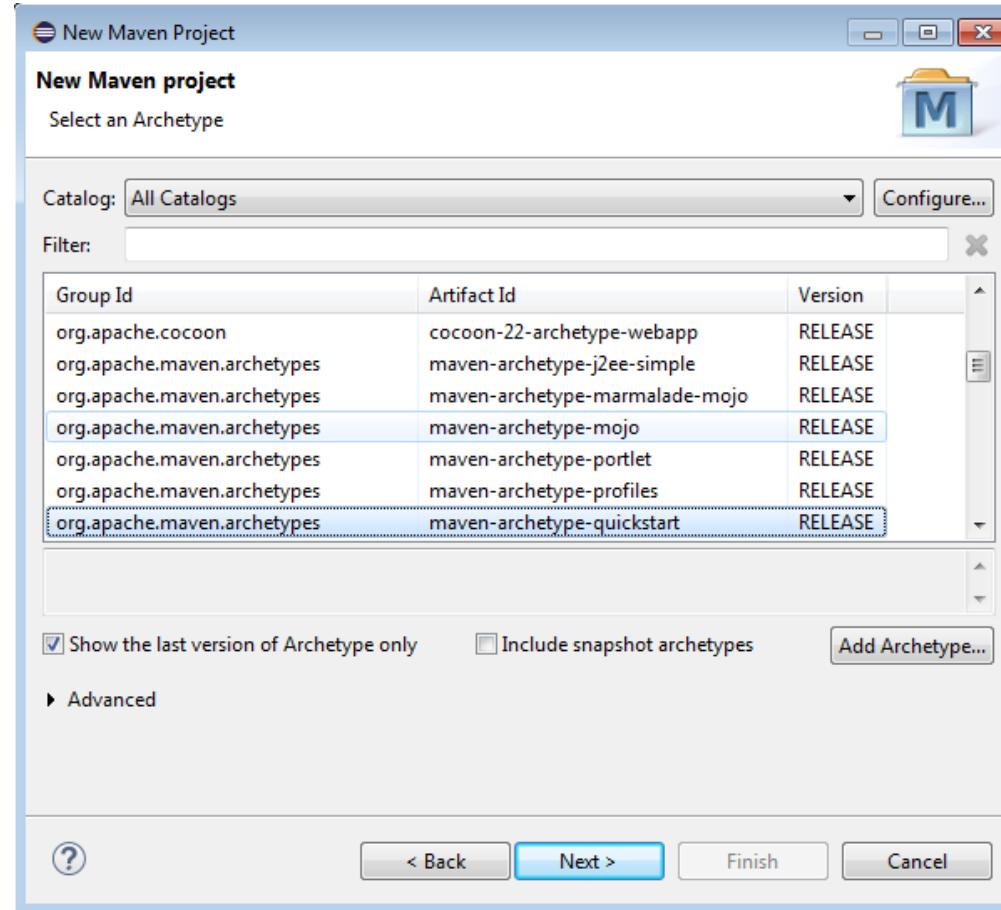
2D. Pravljenje maven projekta – čarobnjak (wizard)



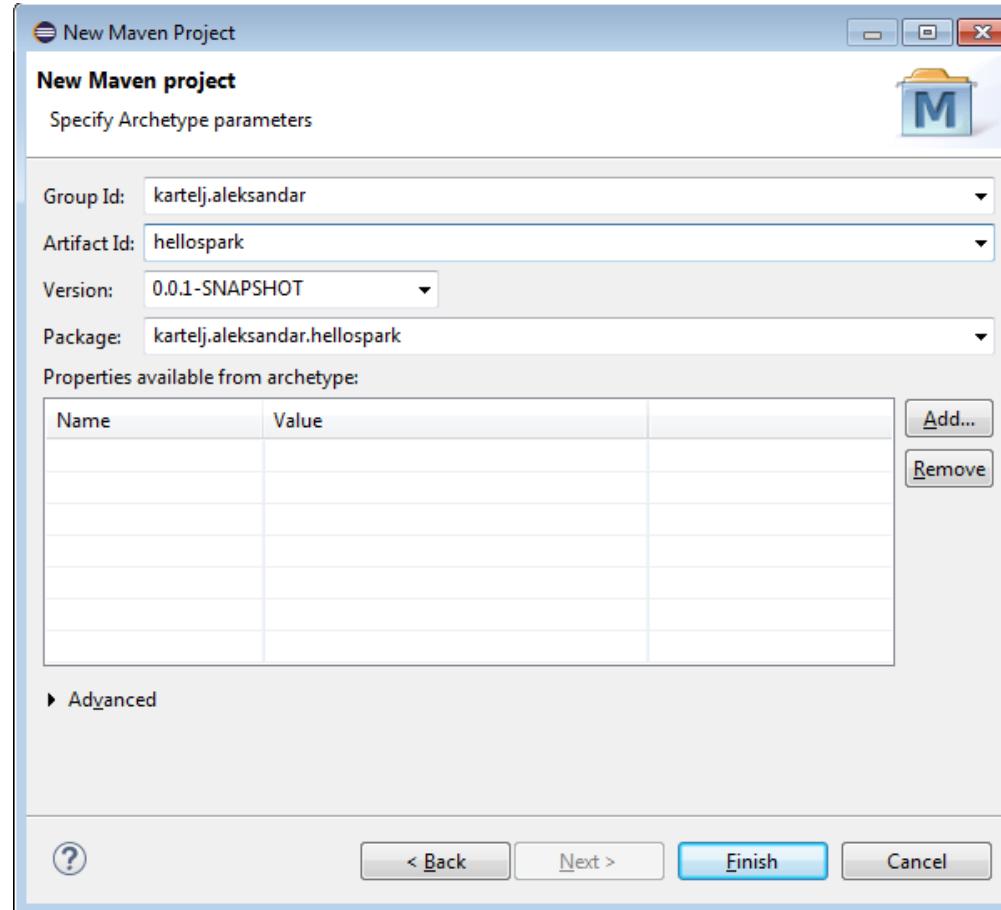
2D. Pravljenje maven projekta – čarobnjak (wizard)



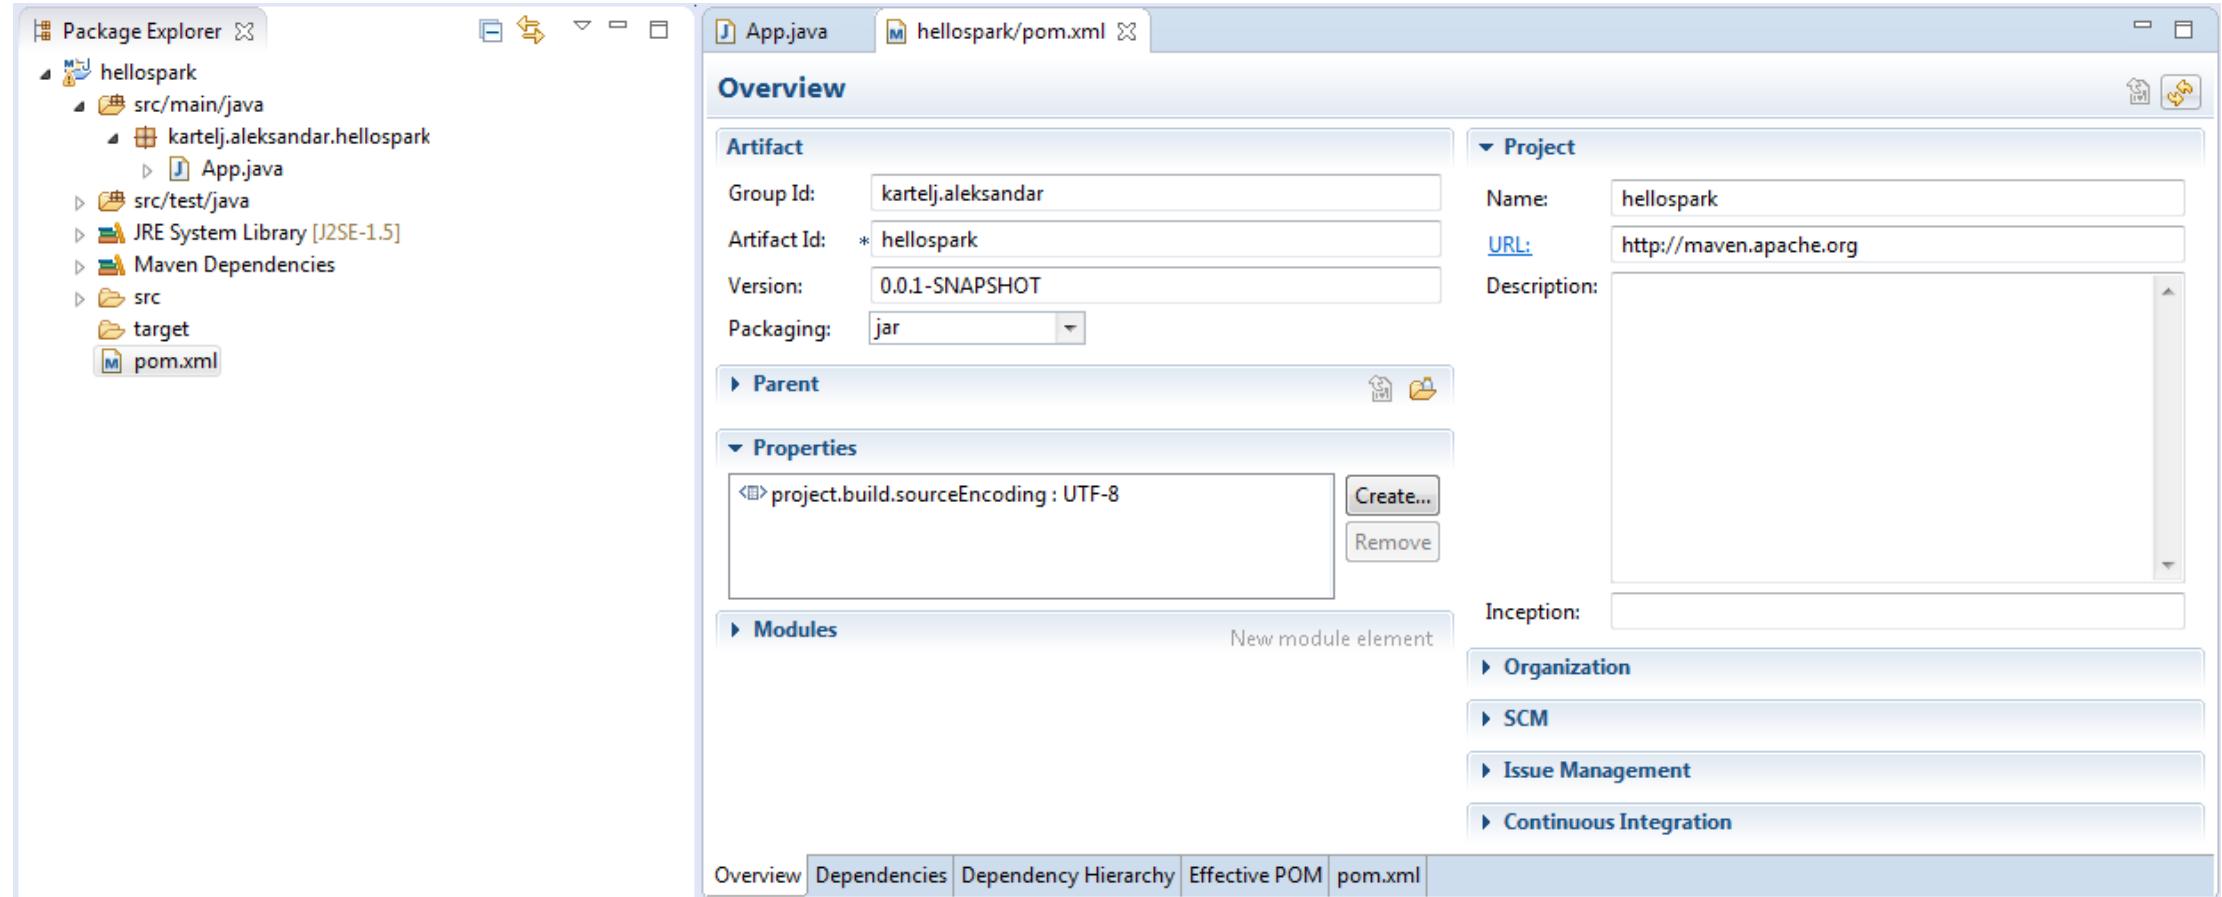
2D. Pravljenje maven projekta – čarobnjak (wizard)



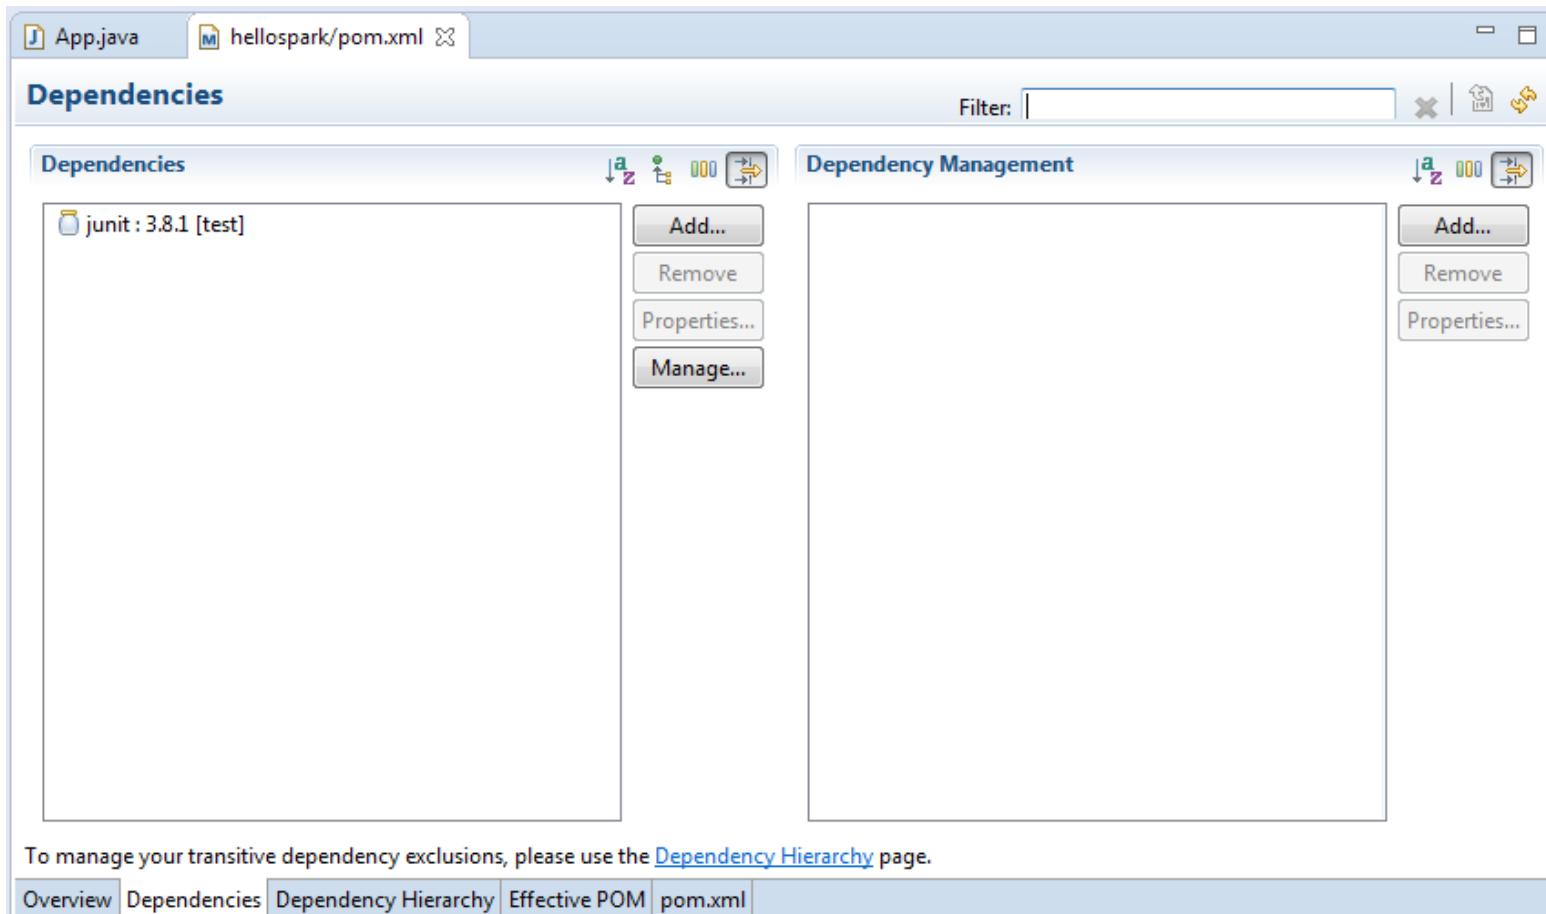
2D. Pravljenje maven projekta – čarobnjak (wizard)



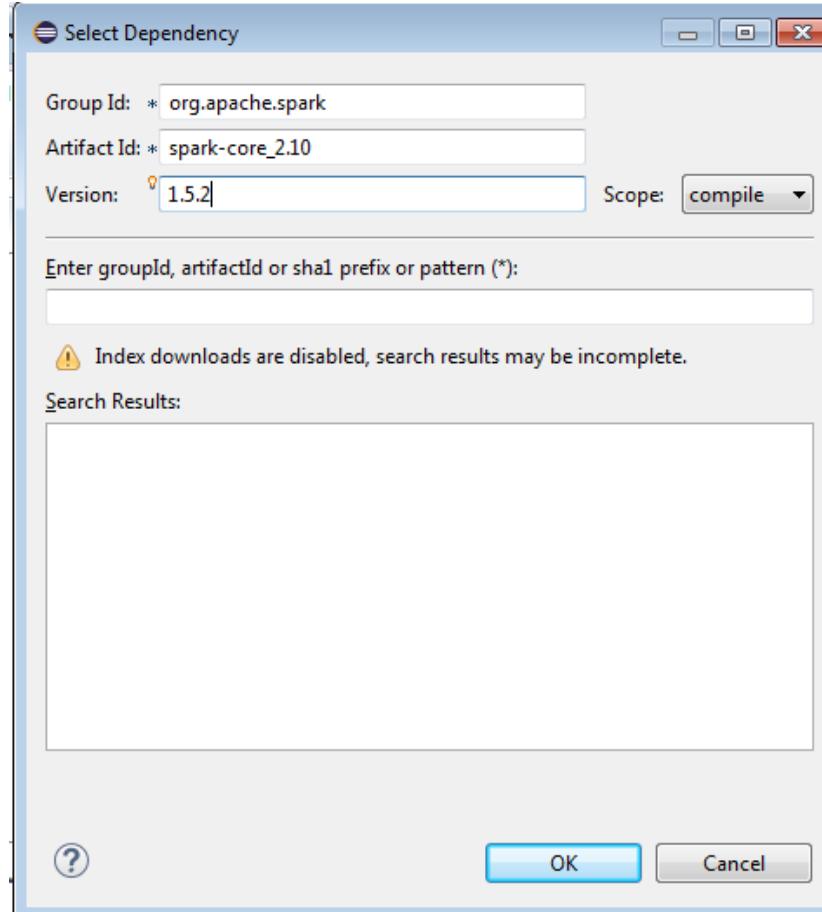
2D. Pravljenje maven projekta – Izgled projekta nakon pravljenja



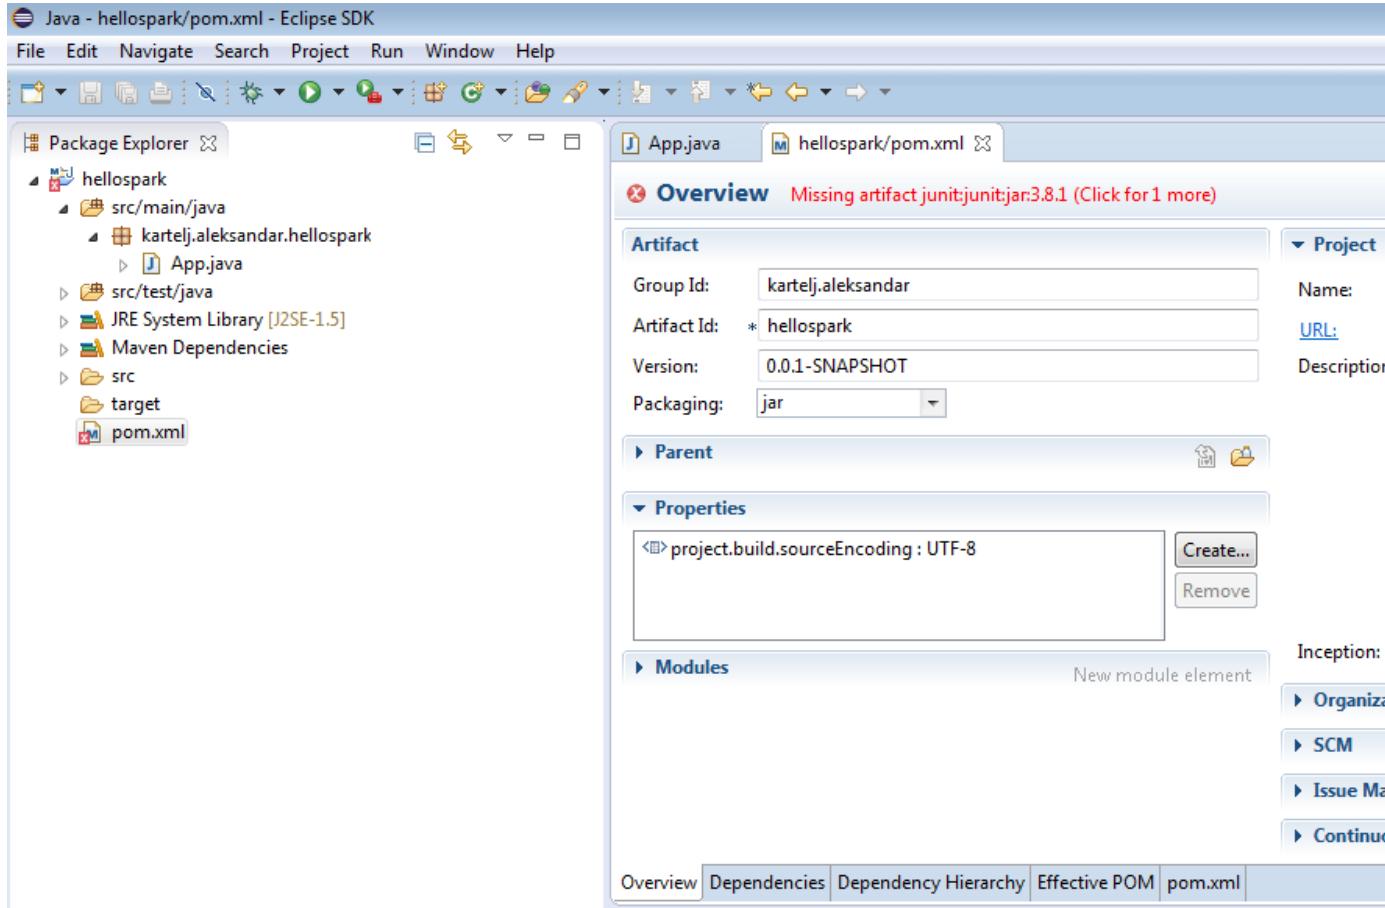
3. Dodavanje podrške za Spark u maven projekat



3. Dodavanje podrške za Spark u maven projekat

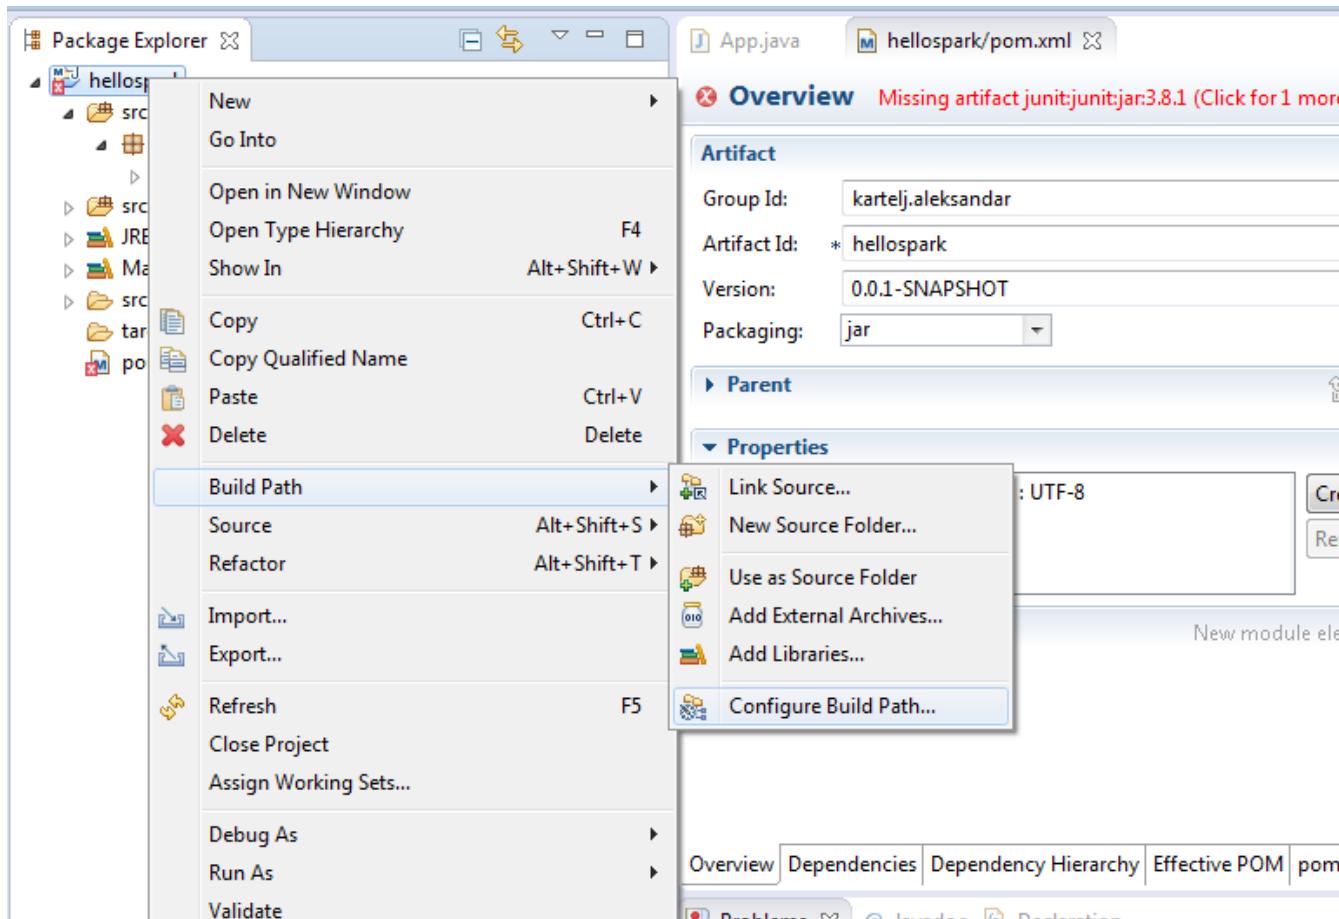


3. Dodavanje podrške za Spark u maven projekat

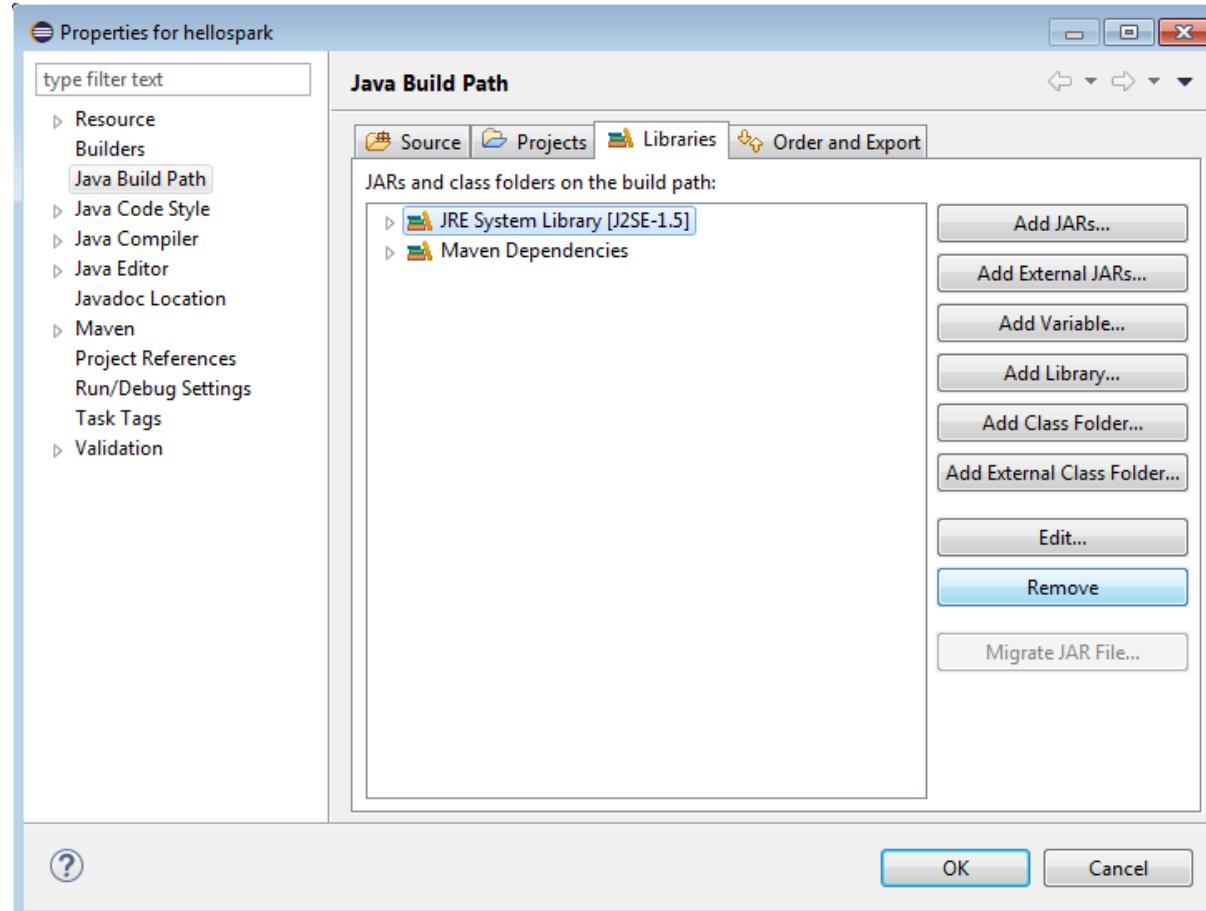


Crveni zbog pogrešne verzije Jave. Postavljen J2SE-1.5 a treba verzija 8.

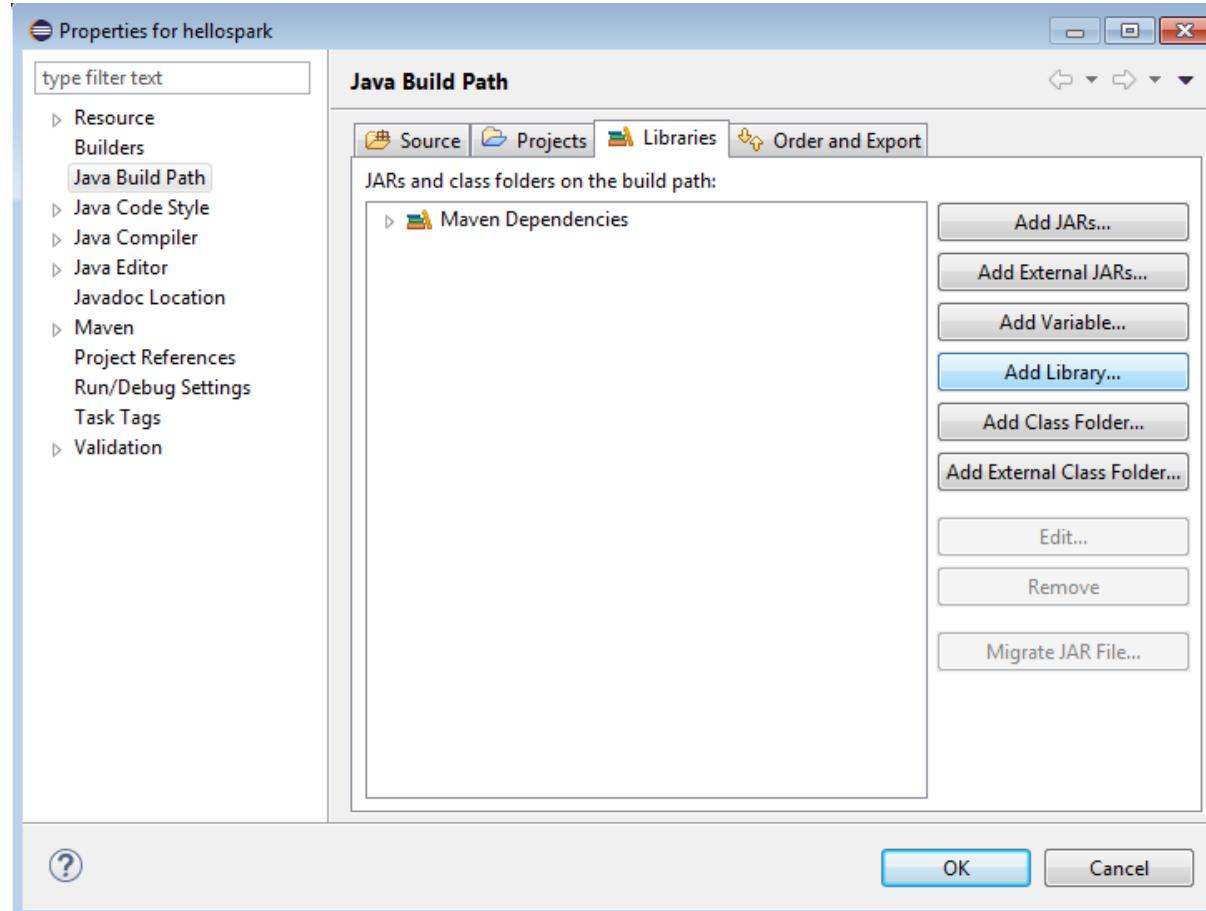
3A. Dodavanje podrške za Spark u maven projekat – Podešavanje Java 8 verzije



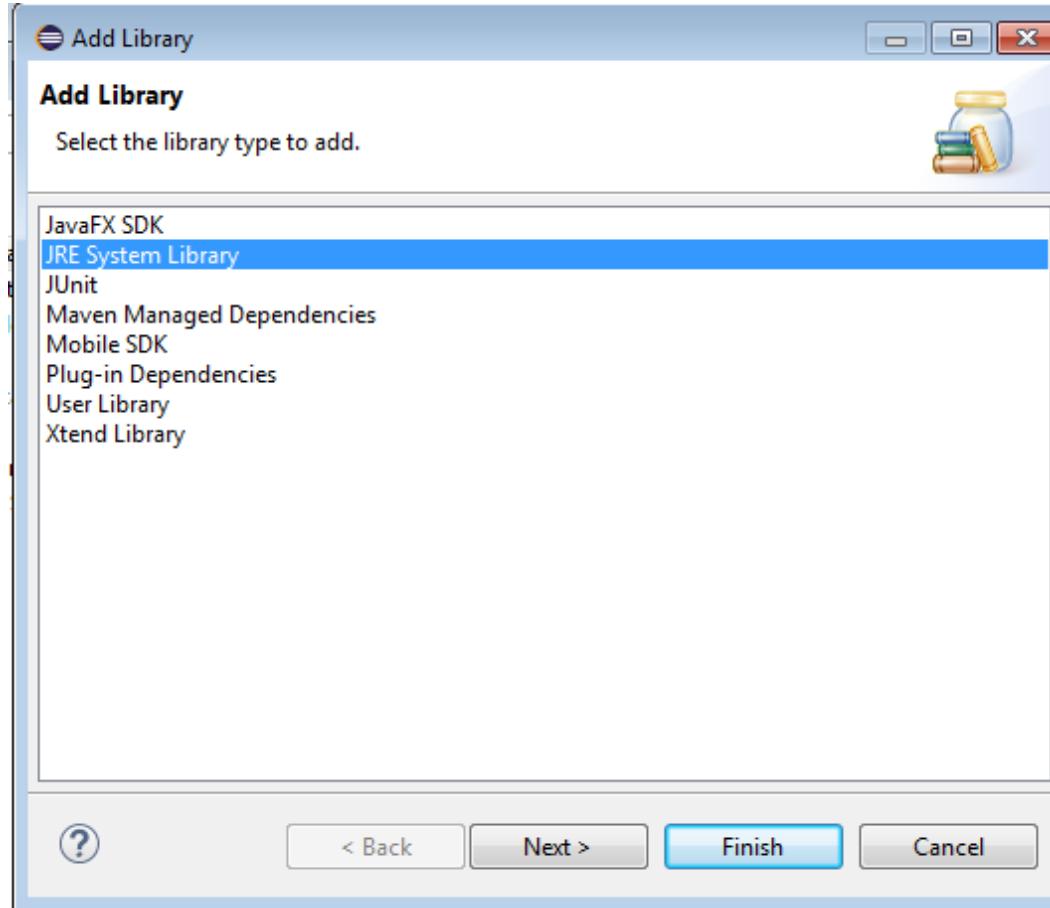
3A. Dodavanje podrške za Spark u maven projekat – Podešavanje Java 8 verzije



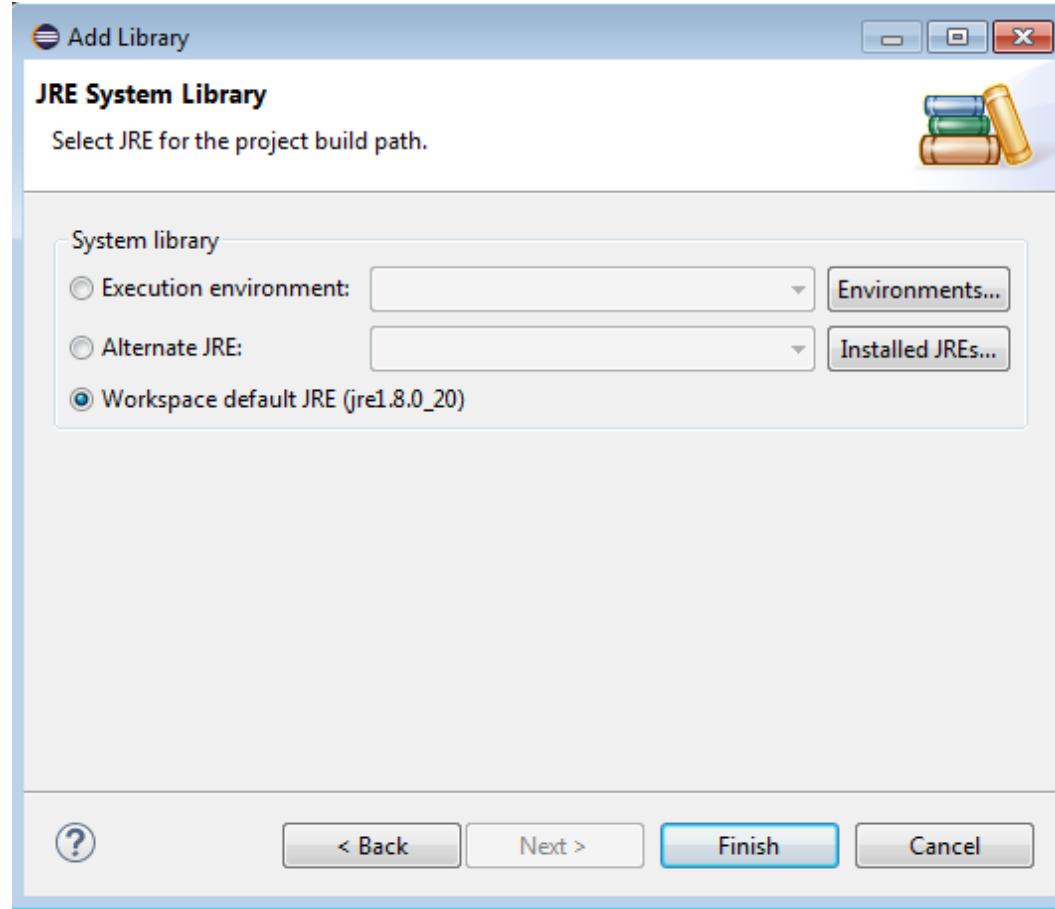
3A. Dodavanje podrške za Spark u maven projekat – Podešavanje Java 8 verzije



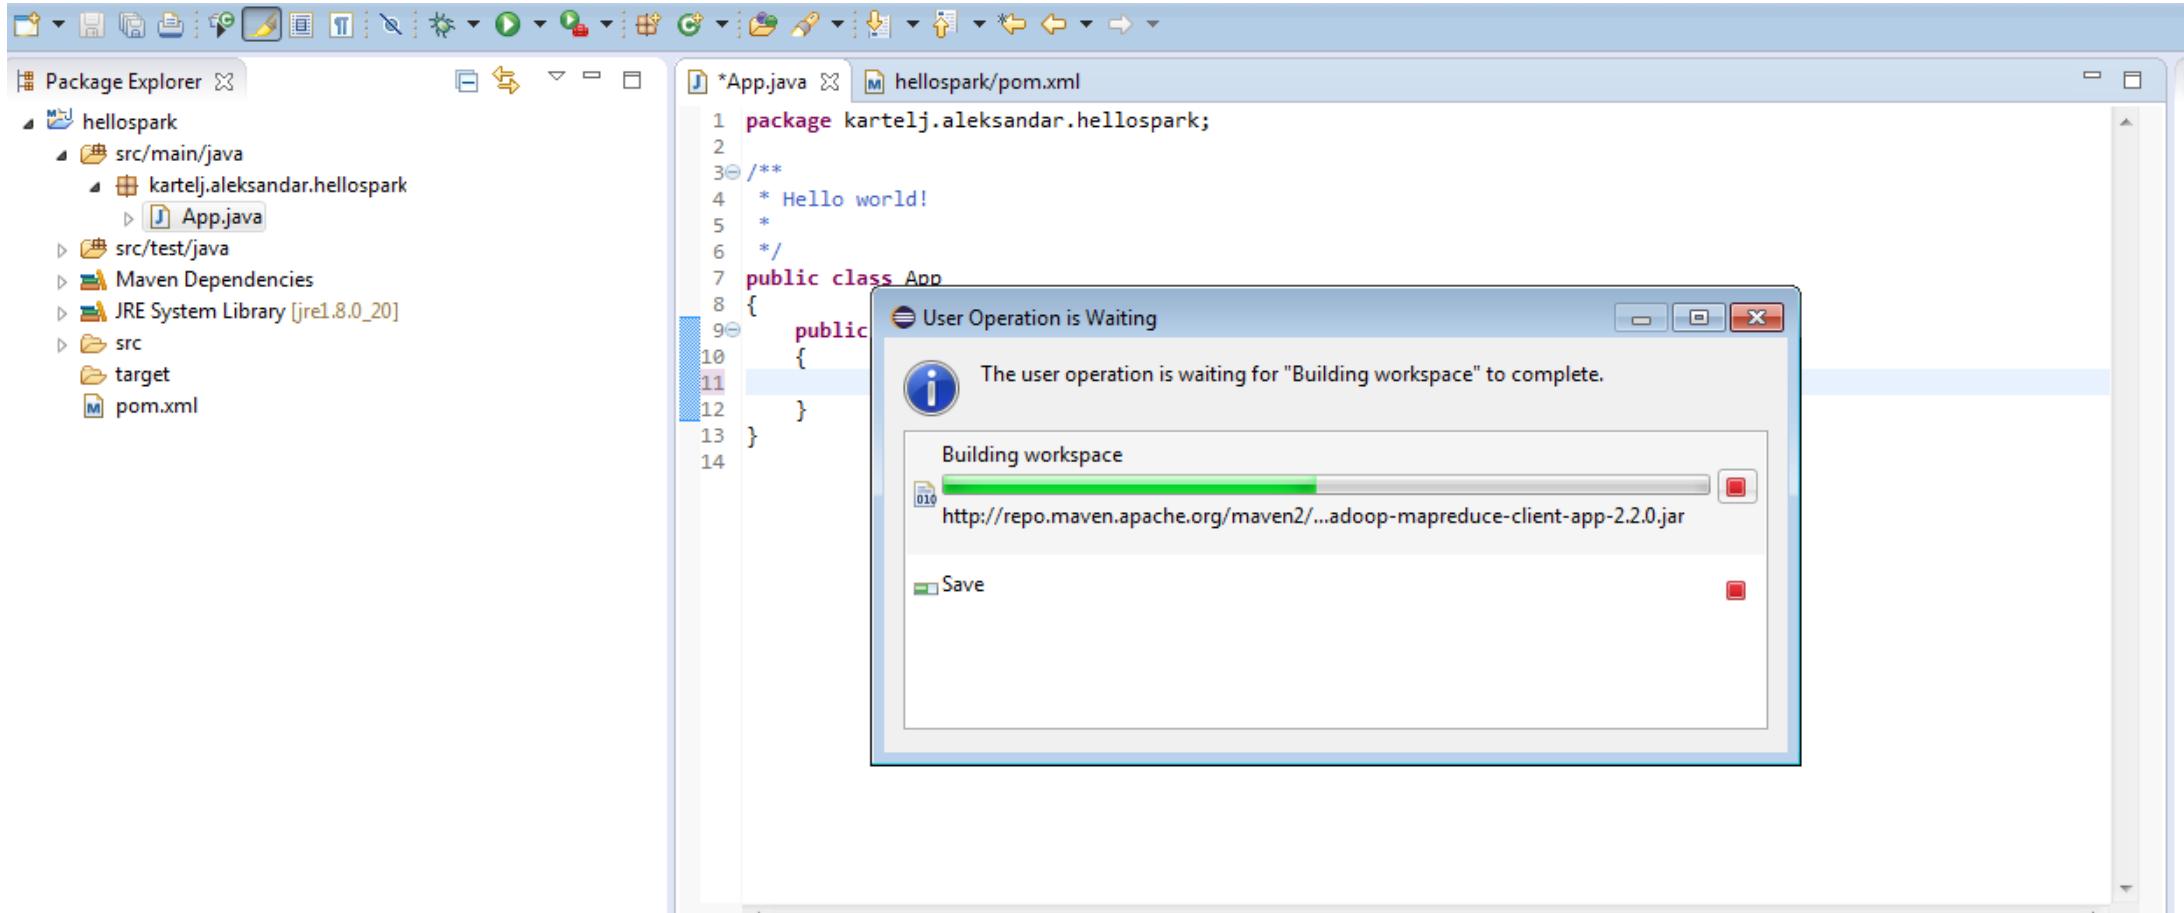
3A. Dodavanje podrške za Spark u maven projekat – Podešavanje Java 8 verzije



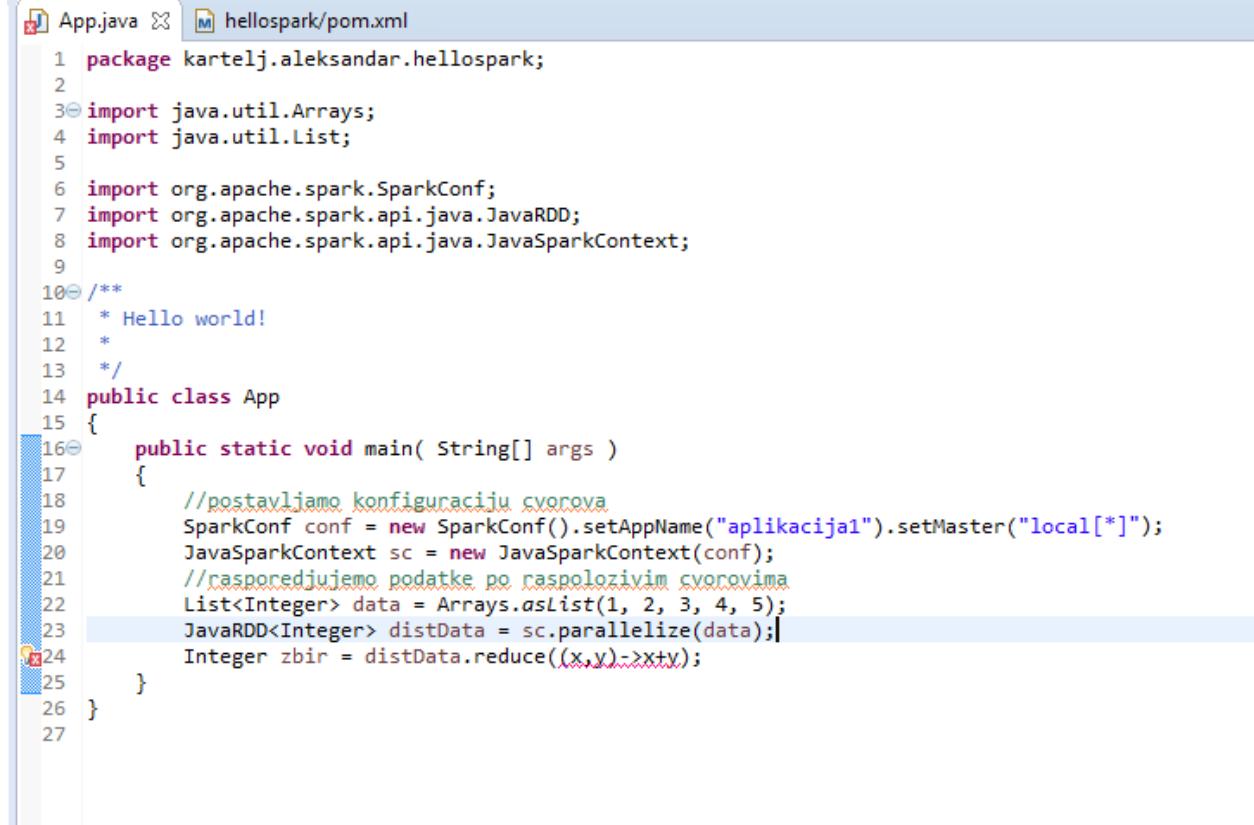
3A. Dodavanje podrške za Spark u maven projekat – Podešavanje Java 8 verzije



4. Izvršavanje jednostavnog programa u lokalnom okruženju



4. Izvršavanje jednostavnog programa u lokalnom okruženju



The screenshot shows a Java code editor with two tabs: 'App.java' and 'hellospark/pom.xml'. The code in 'App.java' is as follows:

```
1 package kartelj.aleksandar.hellospark;
2
3 import java.util.Arrays;
4 import java.util.List;
5
6 import org.apache.spark.SparkConf;
7 import org.apache.spark.api.java.JavaRDD;
8 import org.apache.spark.api.java.JavaSparkContext;
9
10 /**
11  * Hello world!
12  *
13 */
14 public class App
15 {
16     public static void main( String[] args )
17     {
18         //postavljamo konfiguraciju cvorova
19         SparkConf conf = new SparkConf().setAppName("aplikacija1").setMaster("local[*]");
20         JavaSparkContext sc = new JavaSparkContext(conf);
21         //rasporedjujemo podatke po raspolozivim cvorovima
22         List<Integer> data = Arrays.asList(1, 2, 3, 4, 5);
23         JavaRDD<Integer> distData = sc.parallelize(data);
24         Integer zbir = distData.reduce((x,y)->x+y);
25     }
26 }
27
```

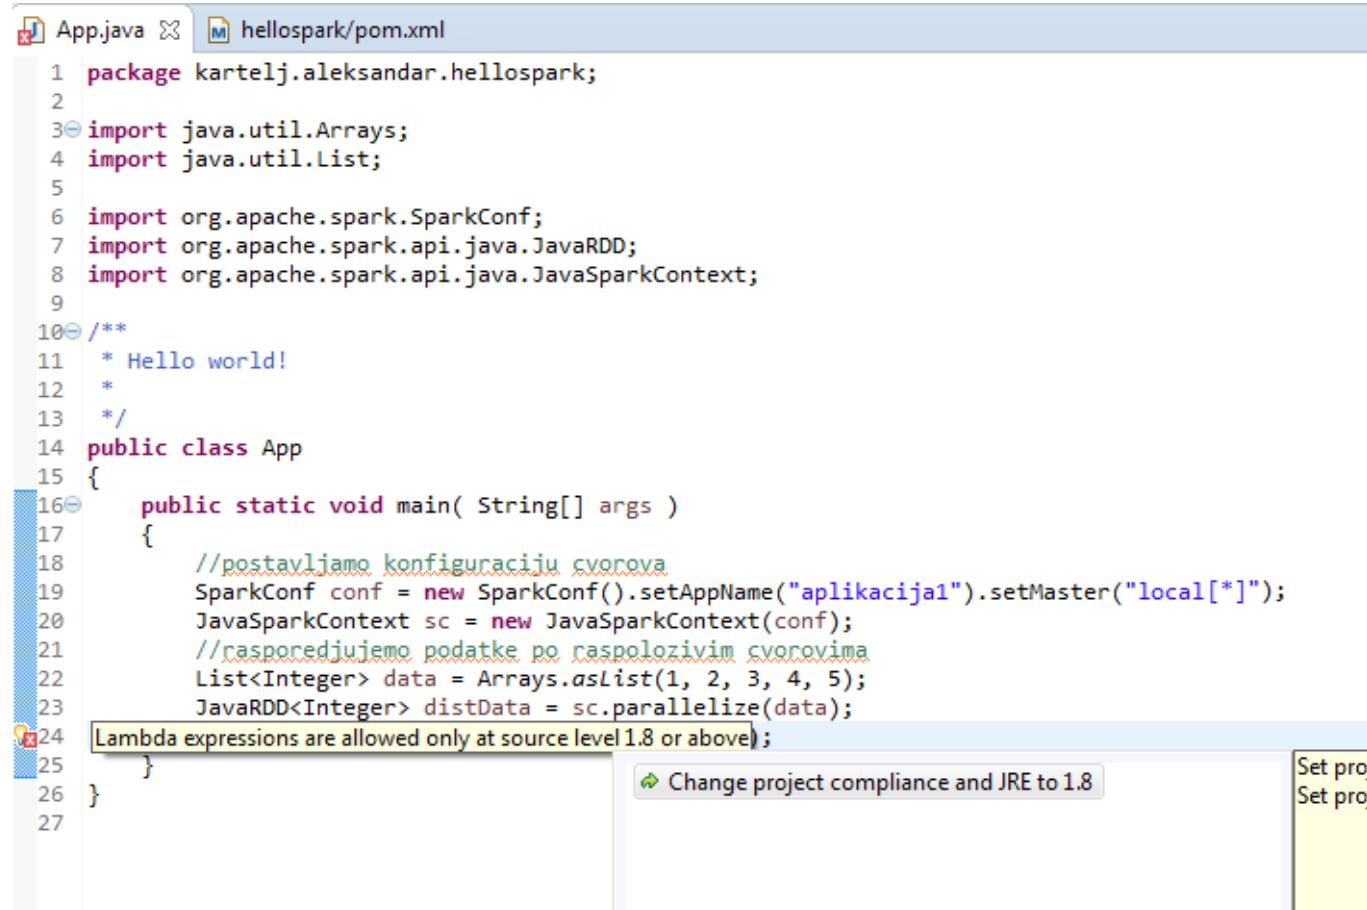
The code uses Java 8 features like `parallelize` and `reduce`, which are highlighted in red by the IDE's syntax highlighting.

Može da crveni jer ne prepoznaje lambda izraze.

Iako smo podesili verziju Java 8 source kod se i dalje validira prema ranijoj verziji.

Kliknite na žuto crvenu ikonicu i pritisnite „Change project compliance...“

4. Izvršavanje jednostavnog programa u lokalnom okruženju

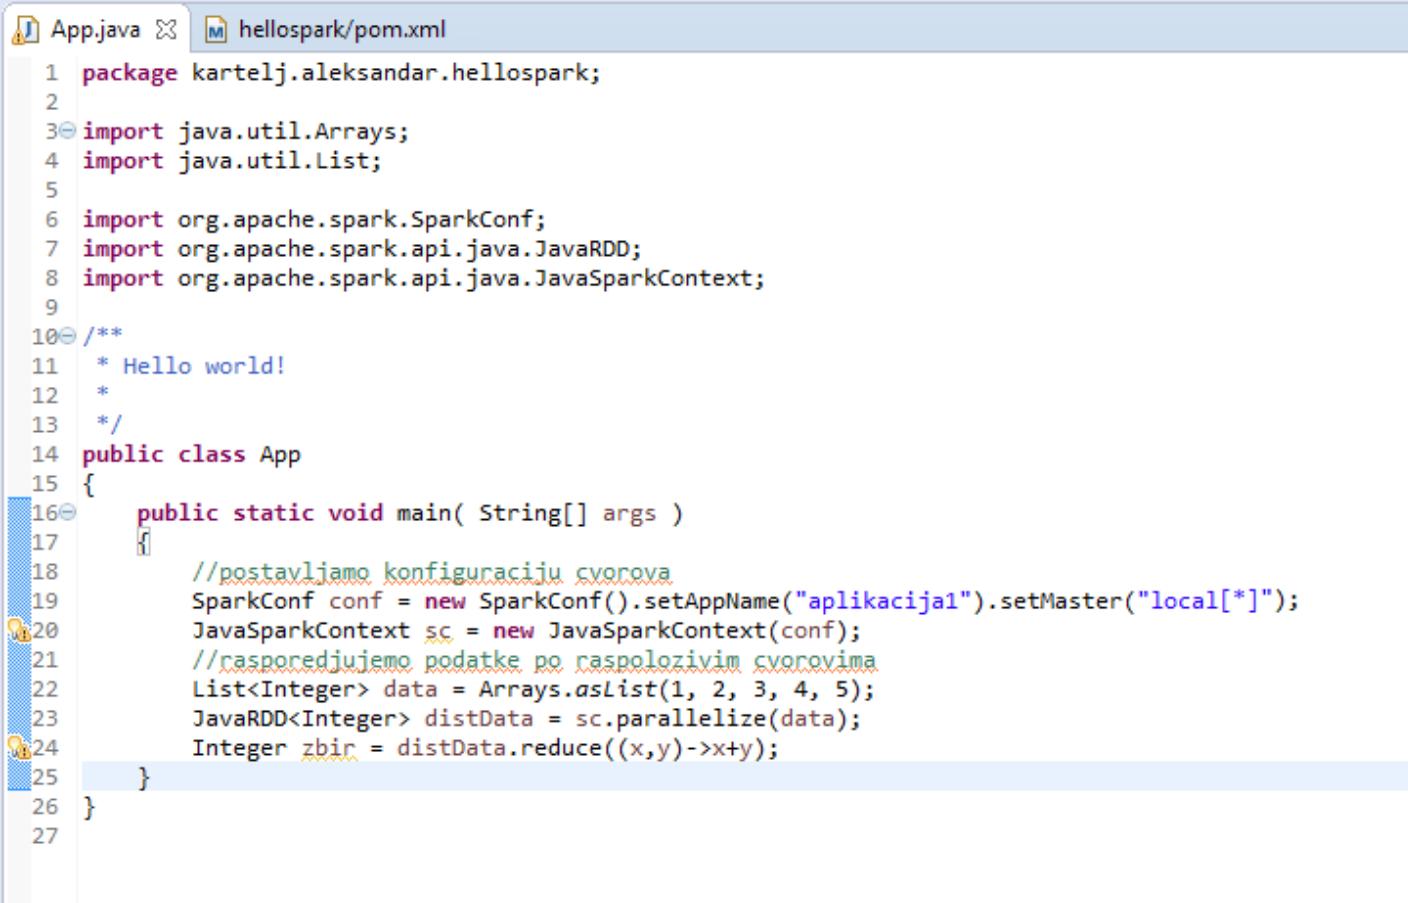


The screenshot shows a Java code editor with two tabs: "App.java" and "hellospark/pom.xml". The "App.java" tab is active, displaying the following code:

```
1 package kartelj.aleksandar.hellospark;
2
3 import java.util.Arrays;
4 import java.util.List;
5
6 import org.apache.spark.SparkConf;
7 import org.apache.spark.api.java.JavaRDD;
8 import org.apache.spark.api.java.JavaSparkContext;
9
10 /**
11  * Hello world!
12  *
13  */
14 public class App
15 {
16     public static void main( String[] args )
17     {
18         //postavljamo konfiguraciju cvorova
19         SparkConf conf = new SparkConf().setAppName("aplikacija1").setMaster("local[*]");
20         JavaSparkContext sc = new JavaSparkContext(conf);
21         //raspoređujemo podatke po raspolozivim cvorovima
22         List<Integer> data = Arrays.asList(1, 2, 3, 4, 5);
23         JavaRDD<Integer> distData = sc.parallelize(data);
24         Lambda expressions are allowed only at source level 1.8 or above;
25     }
26 }
27
```

A tooltip appears over line 24, stating "Lambda expressions are allowed only at source level 1.8 or above;". A button below the tooltip says "Change project compliance and JRE to 1.8". To the right, there are two "Set proj" buttons.

4. Izvršavanje jednostavnog programa u lokalnom okruženju

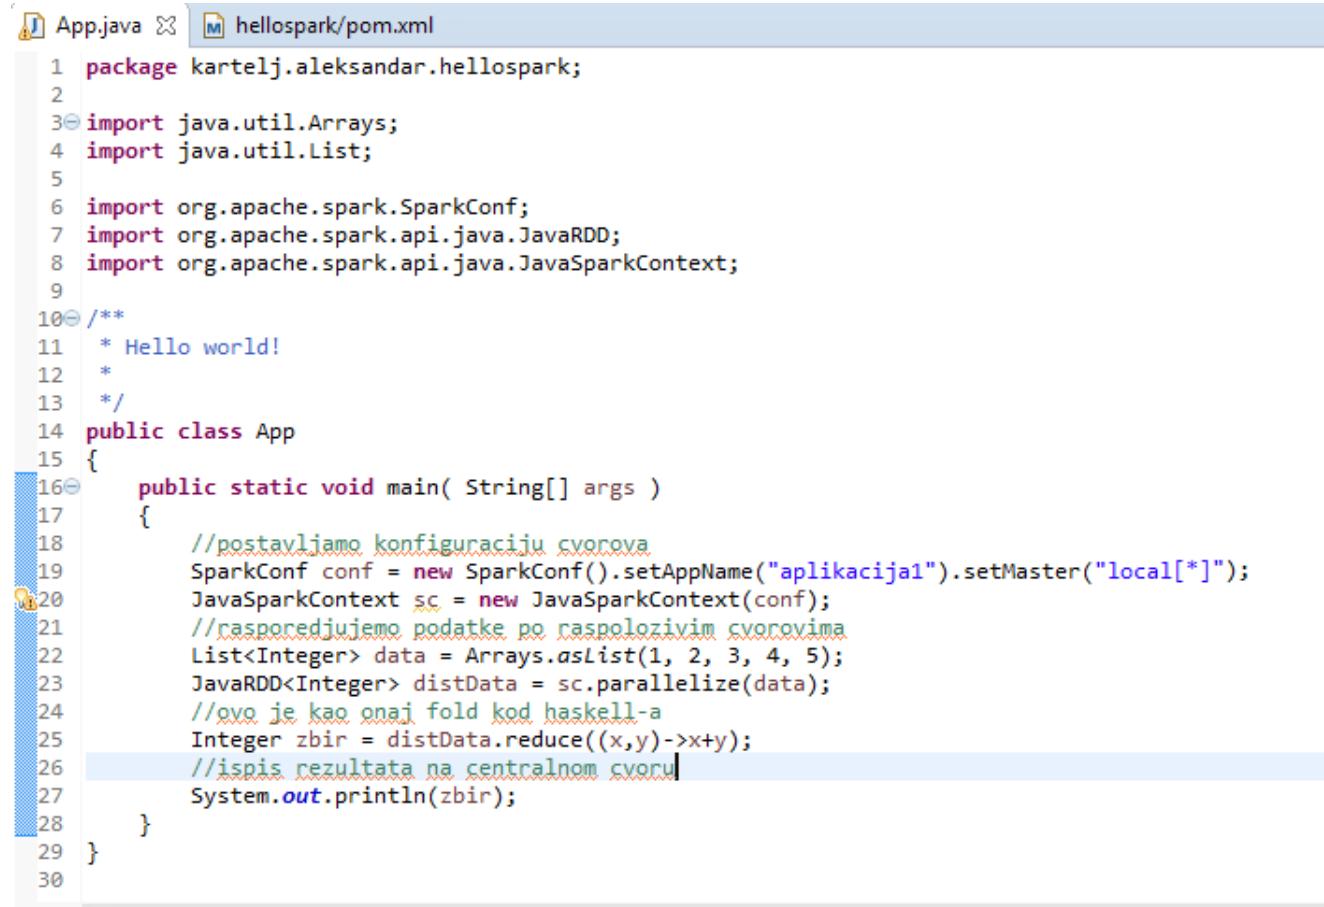


The screenshot shows a Java code editor with two tabs: "App.java" and "hellospark/pom.xml". The "App.java" tab is active, displaying the following code:

```
1 package kartelj.aleksandar.hellospark;
2
3 import java.util.Arrays;
4 import java.util.List;
5
6 import org.apache.spark.SparkConf;
7 import org.apache.spark.api.java.JavaRDD;
8 import org.apache.spark.api.java.JavaSparkContext;
9
10 /**
11  * Hello world!
12  *
13 */
14 public class App
15 {
16     public static void main( String[] args )
17     {
18         //postavljamo konfiguraciju cvorova
19         SparkConf conf = new SparkConf().setAppName("aplikacija1").setMaster("local[*]");
20         JavaSparkContext sc = new JavaSparkContext(conf);
21         //rasporedjujemo podatke po raspolozivim cvorovima
22         List<Integer> data = Arrays.asList(1, 2, 3, 4, 5);
23         JavaRDD<Integer> distData = sc.parallelize(data);
24         Integer zbir = distData.reduce((x,y)->x+y);
25     }
26 }
27
```

The code implements a simple "Hello World" application using Apache Spark. It sets up a local Spark context and parallelizes a list of integers, then reduces them to calculate the sum.

4. Izvršavanje jednostavnog programa u lokalnom okruženju



The screenshot shows a Java code editor with two tabs: "App.java" and "hellospark/pom.xml". The "App.java" tab is active, displaying the following Java code:

```
1 package kartelj.aleksandar.hellospark;
2
3 import java.util.Arrays;
4 import java.util.List;
5
6 import org.apache.spark.SparkConf;
7 import org.apache.spark.api.java.JavaRDD;
8 import org.apache.spark.api.java.JavaSparkContext;
9
10 /**
11  * Hello world!
12  *
13  */
14 public class App
15 {
16     public static void main( String[] args )
17     {
18         //postavljamo konfiguraciju cvorova
19         SparkConf conf = new SparkConf().setAppName("aplikacija1").setMaster("local[*]");
20         JavaSparkContext sc = new JavaSparkContext(conf);
21         //rasporedujemo podatke po raspolozivim cvorcovima
22         List<Integer> data = Arrays.asList(1, 2, 3, 4, 5);
23         JavaRDD<Integer> distData = sc.parallelize(data);
24         //ovo je kao onaj fold kod haskell-a
25         Integer zbir = distData.reduce((x,y)->x+y);
26         //ispis rezultata na centralnom cvoru
27         System.out.println(zbir);
28     }
29 }
30
```

The code implements a simple Hello World application using Apache Spark. It sets up a SparkConf, creates a JavaSparkContext, and then parallelizes a list of integers (1, 2, 3, 4, 5) using the reduce operation to calculate their sum and print it to the console.

Toliko za sada...

Povezivanje na Amazon Hadoop sledeći put...