

Stručni skup „Knjižnični podaci“: interoperabilnost, povezivanje i razmjena

Nestandardizirani podaci u  
standardiziranom kontekstu:  
primjena programskoga jezika Awk u cilju  
sintaktičke interoperabilnosti podataka

Ivan Kapec

Nacionalna i sveučilišna knjižnica

Kruno Peter

Nastavni zavod za javno zdravstvo „Dr. Andrija Štampar“

# Ideja

- rad s građom posebne vrste
- neoperabilnost podataka
- ograničenost resursa

# Tekstualna građa – nestandardizirana

- pisma, članci, leci, skice, književna djela, koncepti, dnevnici, novinski izvještaji, itd.
- rukopisi, strojopisi, kopije, faksimilne kopije, strojopisi s rukopisnim bilješkama, tiskopisi, računalni ispisi

# Organizacija podataka

- proračunske tablice (Excel, Calc)
- tiskani katalogi
- kataložni listići

# Problem

- tablice su dostupne su samo lokalno
- ograničen oblik izrade izvještaja
- nefleksibilnost
- neoperabilnost
- nemogućnost integracije u veće sustave

# Proces obrade je i proces organizacije

- tijekom pregleda građe stvaraju se okvir njene organizacije
- potreban je fleksibilni sistem unosa podataka koji se može lako preoblikovati u tijeku procesa obrade

# Manipulacija podataka

1. izrada tiskanog kataloga
2. izrada bibliografije, brošura
3. izrada kataloga izložbe ili legendi za izložbe
4. fleksibilna izrada raznih vrsta popisa
5. integracija u veće sustave (online katalog, digitalna knjižnica, skupni katalog, itd.)

# Primjena Awka u cilju sintaktičke interoperabilnosti podataka

- pohrana podataka u CSV format – tekstualni format
- generiranje tekstualnog izvještaja
- generiranje izvještaja u formi Web-stranice (HTML format)
- pohrana podataka iz CSV formata u XML format (MARCXML)

# Tekstualni format podataka

Proračunska  
tablica

	A	B	C	D	E	F	G	H	I
1	Broj	Autor	Naslov	Mjesto	Vrijeme	Opseg	Dimenzije	Napomena o načinu izrade	Napomena o sadržaju
2	1	Maren Köster-H	Nejednaka trojka	[s. l.]	27. 4. 1990.	2 l.	28,5 x 21 cm	strojopis s rukopisnim bilješkama	strani tisak
3	2	Tihomil Radja	Kakav priključak na Europu	[s. l.]	[1990.]	8 l.	razl. vel.	faksimil rukopisa	članak
4	3	Jakša Kušan	Predsjednik buduće hrvatske vlade	[s. l.]	[1990.]	2 l.	28,5 x 21 cm	rukopis - autograf	
5	4	Vain Packe	Sonata za solo flautu	Santa Cruz	2011.	5 l.	28 x 23 cm	rukopis - autograf	note

Knjižnična građa

CSV format  
(engl. Comma  
Separated  
Values)

Broj;Autor;Naslov;Mjesto;Vrijeme;Opseg;Dimenzije;Napomena o načinu izrade;Napomena o sadržaju  
1;Maren Köster-Hetzendorf;Nejednaka trojka;[s. l.];27. 4. 1990.;2 l.;28,5 x 21 cm;strojopis s rukopisnim bilješkama;strani tisak  
2;Tihomil Radja;Kakav priključak na Europu;[s. l.];[1990.];8 l.;razl. vel.;faksimil rukopisa;članak  
3;Jakša Kušan;Predsjednik buduće hrvatske vlade;[s. l.];[1990.];2 l.;28,5 x 21 cm;rukopis - autograf;  
4; Vain Packe ;Sonata za solo flautu;Santa Cruz; 2011.;5 l.;28 x 23 cm;rukopis - autograf;note

# Generiranje tekstualnog izvještaja Awkom

<p>Awkova skripta ( naredba: <code>awk -f skripta.awk podaci.csv &gt; izvjestaj.txt</code>)</p>	<pre>BEGIN { FS = ";" }  NR &gt; 1 {   print ""   print "Br. " \$1 "."   print " " \$3 " / " \$2 " , " \$4 " , " \$5 " ; " \$6 " , " \$7   napomena = " , " \$9   if (\$9 == "") napomena = ""   print " " "(" \$8 napomena ")" }</pre>
<p>Tekstualni izvještaj (izvjestaj.txt)</p>	<p>Br. 1. Nejednaka trojka / Maren Köster-Hetzendorf, [s. l.], 27. 4. 1990.; 2 l., 28,5 x 21 cm (strojopis s rukopisnim bilješkama, strani tisak)</p> <p>Br. 2. Kakav priključak na Europu / Tihomil Radja, [s. l.], [1990.]; 8 l., razl. vel. (faksimil rukopisa, članak)</p> <p>Br. 3. Predsjednik buduće hrvatske vlade / Jakša Kušan, [s. l.], [1990.]; 2 l., 28,5 x 21 cm (rukopis - autograf)</p> <p>Br. 4. Sonata za solo flautu / Vain Packe , Santa Cruz, 2011.; 5 l., 28 x 23 cm (rukopis - autograf, note)</p>

# Generiranje izvještaja u formi Web-stranice

Awkova skripta	<pre>BEGIN {   FS = ",";   print "&lt;!doctype html&gt;"   print "&lt;html&gt;"   print "&lt;head&gt;"   print " &lt;title&gt;Knjižnična građa&lt;/title&gt;"   print "&lt;style&gt;html { color: DarkBlue; font-family: sans-serif }&lt;/style&gt;"   print "&lt;/head&gt;"   print "&lt;body&gt;" }</pre>	<pre>NR &gt; 1 {   print "&lt;p&gt;" "&lt;strong&gt;" "Br. " \$1 "&lt;/strong&gt;" "&lt;/p&gt;"   print "&lt;p&gt;" "&amp;nbsp;&amp;nbsp;&amp;nbsp;" \$3 "/" \$2 ", " \$4 ", " \$5 "; " \$6 ", " \$7 "&lt;/p&gt;"   napomena = ", " \$9   if (\$9 == "") napomena = ""   print "&lt;p&gt;" "&amp;nbsp;&amp;nbsp;&amp;nbsp;" "(" \$8 napomena ")" "&lt;/p&gt;" }</pre>	<pre>END {   print "&lt;/body&gt;"   print "&lt;/html&gt;" }</pre>
Web-stranica (HTML format)	 <p>The screenshot shows a web browser window with the title "Knjižnična građa". The address bar displays "file:///C:/src/Leci/gradja.html". The page content is as follows:</p> <ul style="list-style-type: none"><li><b>Br. 1</b> Nejednaka trojka / Maren Köster-Hetzendorf, [s. 1.], 27. 4. 1990.; 2 l., 28,5 x 21 cm (strojopis s rukopisnim bilješkama, strani tisak)</li><li><b>Br. 2</b> Kakav priključak na Europu / Tihomil Radja, [s. 1.], [1990.]; 8 l., razl. vel. (faksimil rukopisa, članak)</li><li><b>Br. 3</b> Predsjednik buduće hrvatske vlade / Jakša Kušan, [s. 1.], [1990.]; 2 l., 28,5 x 21 cm (rukopis - autograf)</li><li><b>Br. 4</b> Sonata za solo flautu / Vain Packe , Santa Cruz, 2011.; 5 l., 28 x 23 cm (rukopis - autograf, note)</li></ul>		

# Pohrana podataka iz CSV formata u XML format

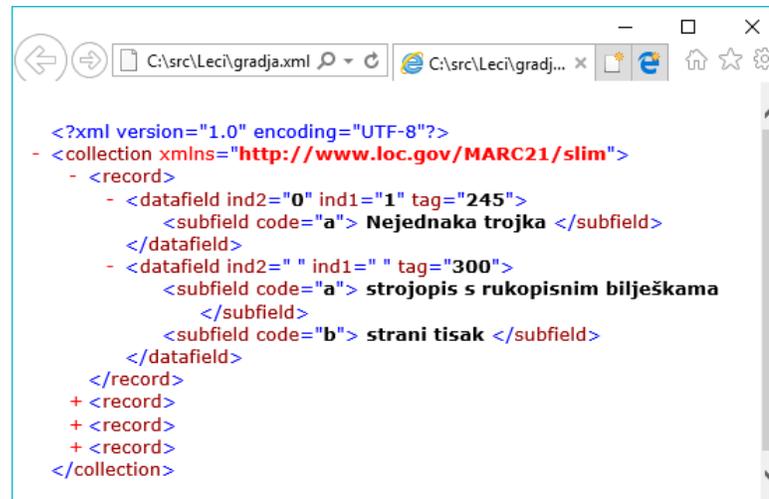
Awkova skripta

```
BEGIN {  
  FS = ","  
  
  print "<?xml version=\"1.0\" encoding=\"UTF-8\"?>"  
  print "<collection xmlns=\"http://www.loc.gov/MARC21/slim\">"  
}
```

```
NR > 1 {  
  print " "<record>"  
  print " "<datafield tag=\"245\" ind1=\"1\" ind2=\"0\">"  
  print " " "<subfield code=\"a\">"  
  print " " $3  
  print " " "</subfield>"  
  print " " "</datafield>"  
  print " "<datafield tag=\"300\" ind1=\" \" ind2=\" \">"  
  print " " "<subfield code=\"a\">"  
  print " " $8  
  print " " "</subfield>"  
  print " " "<subfield code=\"b\">"  
  print " " $9  
  print " " "</subfield>"  
  print " " "</datafield>"  
  print " " "</record>"  
}
```

```
END {  
  print "</collection>"  
}
```

XML format  
(MARCXML) (prikaz  
grananja s jednim  
razvijenim zapisom)



```
<?xml version="1.0" encoding="UTF-8"?>  
- <collection xmlns="http://www.loc.gov/MARC21/slim">  
  - <record>  
    - <datafield ind2="0" ind1="1" tag="245">  
      <subfield code="a"> Nejednaka trojka </subfield>  
    </datafield>  
    - <datafield ind2=" " ind1=" " tag="300">  
      <subfield code="a"> strojopis s rukopisnim bilješkama  
      </subfield>  
      <subfield code="b"> strani tisak </subfield>  
    </datafield>  
  </record>  
  + <record>  
  + <record>  
  + <record>  
</collection>
```

# Prednosti primjene Awka u obradi tekstualnih podataka

- besplatan i dostupan za razne operacijske sustave
- lagana i brza instalacija – jedna izvršna datoteka
- jednostavnost sintakse; minimum koda
- rapidni razvoj; izrada prototipova

Kapec, I. Peter, K. Nestandardizirani podaci u standardiziranom kontekstu: primjena programskoga jezika Awk u cilju sintaktičke interoperabilnosti podataka

© CC BY 3.0 HR

STRUČNI SKUP KNJIŽNIČNI PODACI: INTEROPERABILNOST, POVEZIVANJE I RAZMJENA, 28.-29.11.2017.,  
NACIONALNA I SVEUČILIŠNA KNJIŽNICA U ZAGREBU