

GDEX FOR SLOVENE

Iztok Kosem

Trojina, Institute for Applied Slovene Studies &
Faculty of Arts, University of Ljubljana

WG3 Workshop, Vienna, 12 February 2015

GDEX for Slovene

- Communication in Slovene project
 - 2008-2013
 - 3,2 million euro
 - <http://www.slovenscina.eu>
- Slovene Lexical Database (Krek & Gantar 2012)
- Corpora:
 - 620-million word FidaPLUS corpus (v1)
 - 1.2-billion word corpus of Slovene (Gigafida) (v2)

aktiv

(pridevnik)

Fida PLUS 620m (SLD sketch grammar) freq = 43634 (59.1 per million)

<u>osebek+biti</u>	<u>701</u>	<u>14.8</u>
<input type="checkbox"/> sekcija	<u>21</u>	31.1
<input type="checkbox"/> društvo	<u>25</u>	22.09
<input type="checkbox"/> član	<u>20</u>	19.6

>>

<u>kdo-kaj?</u>	<u>32726</u>	<u>7.0</u>
<input type="checkbox"/> matrika	<u>739</u>	87.89
<input checked="" type="checkbox"/> prebivalstvo	<u>1063</u>	63.52
<input type="checkbox"/> preživljanje	<u>358</u>	62.93
<input checked="" type="checkbox"/> oglje	<u>190</u>	57.45
<input type="checkbox"/> politika	<u>1819</u>	56.96
<input type="checkbox"/> učinkovina	<u>203</u>	53.65
<input checked="" type="checkbox"/> snov	<u>750</u>	52.34
<input checked="" type="checkbox"/> počitnice	<u>518</u>	51.51
<input type="checkbox"/> oddih	<u>180</u>	49.66
<input type="checkbox"/> član	<u>1142</u>	47.38
<input type="checkbox"/> vloga	<u>945</u>	46.56
<input checked="" type="checkbox"/> igranje	<u>280</u>	46.07
<input type="checkbox"/> sodelovanje	<u>809</u>	44.54
<input type="checkbox"/> sestavina	<u>249</u>	43.41
<input type="checkbox"/> zglavnik	<u>42</u>	43.31
<input type="checkbox"/> vzglavnik	<u>63</u>	42.84
<input type="checkbox"/> oprema	<u>618</u>	42.83

<u>v_rodil-p</u>	<u>688</u>	<u>6.4</u>
<input type="checkbox"/> leto	<u>125</u>	29.17
<input type="checkbox"/> čas	<u>30</u>	17.9

>>

<u>kako-kdaj?</u>	<u>12326</u>	<u>6.2</u>
<input type="checkbox"/> delovno	<u>801</u>	91.23
<input type="checkbox"/> spolno	<u>210</u>	61.76
<input type="checkbox"/> telesno	<u>226</u>	60.78
<input type="checkbox"/> zelo	<u>1781</u>	59.29
<input type="checkbox"/> fizično	<u>157</u>	54.16
<input type="checkbox"/> biološko	<u>97</u>	53.11
<input type="checkbox"/> najbolj	<u>979</u>	52.25
<input type="checkbox"/> športno	<u>173</u>	51.84
<input type="checkbox"/> politično	<u>205</u>	51.18
<input type="checkbox"/> bolj	<u>926</u>	49.02
<input type="checkbox"/> površinsko	<u>44</u>	48.96
<input type="checkbox"/> trenutno	<u>276</u>	48.64
<input type="checkbox"/> vedno	<u>621</u>	44.64
<input type="checkbox"/> vsestransko	<u>54</u>	41.52
<input type="checkbox"/> malo	<u>458</u>	39.89
<input type="checkbox"/> potresno	<u>27</u>	38.42
<input type="checkbox"/> izredno	<u>140</u>	38.36

<u>kakšen-g?</u>	<u>306</u>	<u>12.6</u>
<input type="checkbox"/> postati	<u>175</u>	38.75
<input type="checkbox"/> ostati	<u>73</u>	30.28

>>

<u>v_tožil-p</u>	<u>532</u>	<u>7.4</u>
<input type="checkbox"/> čas	<u>75</u>	29.91
<input type="checkbox"/> vrsta	<u>27</u>	23.03
<input type="checkbox"/> kot	<u>19</u>	18.9
<input type="checkbox"/> dan	<u>24</u>	16.93
<input type="checkbox"/> leto	<u>36</u>	16.64

>>

Tickbox Lexicography - Select Examples

Lemma: aktivnen

Gramrel: kdo-kaj?

Template: fidaplus_slovene Alternative GDEX configuration:

None 

prebivalstvo

- V večini držav v razvoju naj bi siva ekonomija vključevala med 30 - 70 odstotkov **aktivnega** prebivalstva.
- Leta 2001 naj bi bilo v EU brezposelnih 8 odstotkov **aktivnega** prebivalstva oziroma 15 milijonov oseb.
- Zakon določa, da je lahko le pet odstotkov **aktivnega** prebivalstva tujcev, torej približno 41.000 ljudi.
- Brez službe je okoli 388.000 ljudi ali več kakor 22 odstotkov **aktivnega** prebivalstva.
- Do leta 2010 naj bi imelo 85 odstotkov **aktivnega** prebivalstva doseženo srednješolsko izobrazbo.
- Brezposelnost na širšem območju Maribora je pred dobrima dvema letoma zajela že skoraj četrtino **aktivnega** prebivalstva.
- Rast zaposlenosti v ZDA je letos že presegla naravno povečanje **aktivnega** prebivalstva za skoraj pol odstotne točke.
- Februarja 2001 je tako v Sloveniji internet uporabljalo okoli 19 % **aktivnega** prebivalstva.
- V črnomaljski in semiški občini je zaposlenih 5.634 ljudi ali 80,5 odst **aktivnega** prebivalstva.
- Tedaj bo razmerje med **aktivnim** prebivalstvom in upokojenci 10 proti 7.

oglje


Vienna, 12 February 2015

- Po zaužitju do treh jagod mora oseba vzeti **aktivno** oglje in nadomeščati z drisko izgubljeno tekočino.

GDEX for Slovene v1

- GDEX for Slovene (Kosem, Husák and McCarthy, 2011)
- Initial GDEX configuration:
 - Non-language specific classifiers of English GDEX
 - analysis of manually selected examples in the database (using WEKA tool)
- Evaluation in TBL:
 - Comparing different GDEX configurations
 - Logging good (selected) and “bad” (unselected) examples
- Improving GDEX for Slovene based on:
 - Recorded observations
 - Analysis of good (and bad) examples
- Result: GDEX configuration Slovene3b

GDEX for Slovene – version 1



GDEX: Slovene3

prebivalstvo

V večini držav v razvoju naj bi siva ekonomija vključevala med 30 - 70 odstotkov **aktivnega** prebivalstva.

Leta 2001 naj bi bilo v EU brezposelnih 8 odstotkov **aktivnega** prebivalstva oziroma 15 milijonov oseb.

Zakon določa, da je lahko le pet odstotkov **aktivnega** prebivalstva tujcev, torej približno 41.000 ljudi.

Brez službe je okoli 388.000 ljudi ali več kakor 22 odstotkov **aktivnega** prebivalstva.

Do leta 2010 naj bi imelo 85 odstotkov **aktivnega** prebivalstva doseženo srednješolsko izobrazbo.

Brezposelnost na širšem območju Maribora je pred dobrima dvema letoma zajela že skoraj četrtino **aktivnega** prebivalstva.

Rast zaposlenosti v ZDA je letos že presegla naravno povečanje **aktivnega** prebivalstva za skoraj pol odstotne točke.

Februarja 2001 je tako v Sloveniji internet uporabljalo okoli 19 % **aktivnega** prebivalstva.

V črnomaljski in semiški občini je zaposlenih 5.634 ljudi ali 80,5 odst **aktivnega** prebivalstva.

Tedaj bo razmerje med **aktivnim** prebivalstvom in upokojenci 10 proti 7.

GDEX: Slovene2

prebivalstvo

Zaradi bolečin v križu so največje težave pri **aktivnem** prebivalstvu.

Tedaj bo razmerje med **aktivnim** prebivalstvom in upokojenci 10 proti 7.

Zakaj je **aktivno** prebivalstvo na udaru?

To pa je okrog 60 odstotkov **aktivnega** prebivalstva.

Brez službe je okoli 388.000 ljudi ali več kakor 22 odstotkov **aktivnega** prebivalstva.

Delovno aktivni in brezposelni sestavljajo skupaj **aktivno** prebivalstvo.

V večini držav v razvoju naj bi siva ekonomija vključevala med 30 - 70 odstotkov **aktivnega** prebivalstva.

Delež aktivnih žensk v skupnem številu **aktivnega** prebivalstva je 47 odstotkov.

Do leta 2010 naj bi imelo 85 odstotkov **aktivnega** prebivalstva doseženo srednješolsko izobrazbo.

Najbolj ogroža **aktivno** prebivalstvo, predvsem ljudi, stare od 35 do 45 let.

Findings

- Sentence length
 - from 8-30 to 15-35 → considerable improvement
- Keyword position
 - English – beginning of the sentence (0-20%)
 - Slovene – middle to end of the sentence (40-100%)
- Penalizing repetitions of the word in the same example
- Sentence length (max 60)
- Word length (>18 characters)


GDEX for Slovene – from v1 to v2

- Automatic extraction:
point of departure → GDEX for Slovene v1



GDEX for Slovene – from v1 to v2


- Automatic extraction:
point of departure → GDEX for Slovene v1
- Aim: separate GDEX configurations for nouns, verbs,
adjectives, adverbs
- Different task: **first 3 examples of each collocate
need to be good** (not any 3 out of 10 examples)



GDEX (via TBL) +
example selection



database



Classifiers – no change

- Boolean classifier group (binary) (weight = 100)
 - Whole sentence
 - Classifier matching regexp (`[<| \][>/\ \]`)
 - Any token frequency < 3
- “Penalty” classifiers
 - Proper nouns (weight = 2): -0.2 deduction for each proper noun
- Example diversity: Levenshtein distance > 30%

Fine-tuning of classifiers

- Removed classifiers:
 - Boolean: maximum token length
 - Percentage of tokens with frequency above 104
- Classifiers moved under boolean:
 - classifier penalizing web addresses, emails
 - keyword repetition (matching lemma, not token)
- Changed classifiers:
 - Token length (originally 6 – from English GDEX → 8)
 - maximum sentence length = 60 → 35-40 tokens
- Changed weights:
 - Sentence length (2 → 10)
 - Capital letters (2 → 4)
 - Symbols (1 → 5)
 - Punctuation (1 → 5)

New classifiers

- Blacklist of sentence-initial words:
 - *sledi, zatorej, torej, nato, vendar, gre, oboji, dotlej, zato, tovrsten, to, ta, slednji, tak, takšen, potekati*
 - *both, it follows, thus, therefore, then, but, this is, till then, because, this type of, this, that, latter, it takes place*
- Blacklist of sentence-initial phrases
- Penalty for lemmas with frequency below 600 or 1000
- Separate classifier for commas (penalty for multi-clause sentences)
- **Third-collocate classifier!** (e.g. *take a long walk*)

Summary

- Slovenian experience:
 - Good results
 - Particularly good at **helping to identify good database examples**
 - More useful when used at collocational (under gramrels) than at lemma level
- GDEX already used in various projects
 - Lexicographic (Slovene lexical database)
 - Terminological (TERMIS)
 - Pedagogical (Pedagogic corpus-based grammar)