

Luščenje in jezikoslovna analiza kolokacij iz korpusa Šolar

TADEJA ROZMAN

ŠPELA ARHAR HOLDT

SENJA POLLAK

IZTOK KOSEM

JTDH 2016

Okvir

korpusna leksikalna analiza – usvajanje besedišča

- Špela Arhar Holdt in Tadeja Rozman. 2015. Možnosti uporabe podatkov iz korpusa Šolar za pripravo slovarskih priročnikov.
- Mojca Stritar Kučuk: Napake besedišča. (V: Iztok Kosem idr. 2012.)

Raziskovalno vprašanje

Kaj nam lahko korpus Šolar pove o usvajanju kolokacij
in
kako te informacije uporabiti pri načrtovanju pouka leksike ter
pripravi didaktičnih gradiv in jezikovnih priročnikov,
namenjenih šolski populaciji?

Raziskovalni problem

- specifice v rabi kolokacij pri mladini v primerjavi z običajno rabo odraslih v splošni rabi
 - primerjalna analiza korpusov Šolar in Kres
- detekcija težav v rabi kolokacij pri mladini
 - analiza učiteljskih popravkov v Šolarju

Primerjalno luščenje kolokacij: Šolar vs. Kres

- **Primerjalno luščenje kolokacij** ([Pollak in Arhar Holdt, 2015](#)):
 - za seznam besed v korpusu: avtomatski izvoz kolokacij iz orodja SketchEngine ([Kilgariff et al., 2004](#), [API Pollak, 2015](#)): frekvence, kolok. vrednosti (LogDice), povezava na zglede
 - izračun primerjalnih kolokacijskih vrednosti LD-diff (LDŠolar-LDKres), dodatni pogoji (bes. vrsta, minimalne vrednosti, ...)
- **Motivacija:** nove kolokacije, enake oz. primerljive kolokacije, tipične kolokacije vs. redke zveze
- **Izbor za luščenje in analizo:**
 - top 100 samost. v korpusu Šolar (*človek, življenje, ljubezen, otrok, čas* itd.),
 - pozicija pred lemo (in bes. vrsta: pridetnik, glagol ali samostalnik)
 - logDice ≥ 3 in relativna frekvanca ≥ 2 promila (vsaj 2 pojavitvi v Šolarju oz. vsaj 200 v Kresu).

Izluščeni podatki za vzorec [pridevnik + čustvo]

Kolokator	Iztočnica	lowUP	LD_diff	logDiceSolar	Frek-Sola	logDiceKres	Frek-Kres	linkSola	linkKres	Pojavljanje
negativen	čustvo	LOWER	-9,089	0,000	0	9,089	263	nolink	http://solar	SAMO_KRES
ljubezenski	čustvo	LOWER	-0,580	7,159	3	7,738	93	http://sola	http://solar	V_OBEH
globok	čustvo	LOWER	0,010	7,685	4	7,677	108	http://sola	http://solar	V_OBEH
romantičen	čustvo	LOWER	0,670	6,712	2	6,040	26	http://sola	http://solar	V_OBEH
pozitiven	čustvo	LOWER	1,500	8,447	8	6,951	70	http://sola	http://solar	V_OBEH
poln	čustvo	LOWER	2,040	6,424	2	4,381	19	http://sola	http://solar	V_OBEH
močen	čustvo	LOWER	2,410	9,764	28	7,354	177	http://sola	http://solar	V_OBEH
osnoven	čustvo	LOWER	2,810	6,438	2	3,625	13	http://sola	http://solar	V_OBEH
lep	čustvo	LOWER	3,210	6,508	4	3,303	18	http://sola	http://solar	V_OBEH
intimen	čustvo	LOWER	3,550	7,433	3	3,884	5	http://sola	http://solar	V_OBEH
pomemben	čustvo	LOWER	4,500	5,701	2	1,200	5	http://sola	http://solar	V_OBEH
ustrezen	čustvo	LOWER	5,540	6,805	2	1,264	2	http://sola	http://solar	V_OBEH
psihičen	čustvo	LOWER	7,359	7,359	3	0,000	0	http://solar	nolink	SAMO_SOLAR

[pridevnik + čustvo] glede na LD_Diff



Gim, 4. letnik, NG

Berk je nezmožen **psihičnih čustev** nesvobodo-miselen, neprilagodljiv intelektualец, ki se je kot partizan boril proti Nemcem.

Strok, 4. letnik, MB

Sama dajem mogoče malo večji poudarek **psihičnim čustvom**, ki znajo biti nenadomestljiva, čeprav se zavedam, da je telesna ljubezen prav tako pomembna.

[pridevnik + samostalnik] prekrivno:
1810 zvez izmed 2266 izluščenih (79,9%)

Prvih 40 glede na frekvenco v korpusu Šolar

šolski spis (frek. 390), šolska naloga, današnji čas,
nezakonska mati, družbene razmere, osnovna šola,
dobro življenje, naslednji dan, glavni junak, srednja
šola, materni jezik, današnji svet, glavni lik, prosti čas
dober prijatelj, prava ljubezen, športni dan, glavna
oseba, izgubljeni sin, pravi prijatelj, posmrtno
življenje, svetovna vojna, celo življenje, krščanska
vera, velik vpliv, spolni odnos, organska potreba,
ljubljena oseba, človekova usoda, kulturni dom,
nezakonski otrok, očetova smrt, velik problem, mlado
dekle, vsakdanje življenje, današnja družba, povodni
mož, dolg čas, Cankarjev roman, pisna naloga (frek. 36)

temeljno besedišče
vzgojna vloga slovenščine

[pridevnik + samostalnik] samo v Kresu: 279 zvez izmed 2266 izluščenih (12,3 %)

Prvih 40 glede na logDice

pravna oseba (logDice 11,176), nadaljnje besedilo, fizična oseba, nadzorni svet, gospodarska družba, združene države, svetovalna služba, obveščevalna služba, diplomska naloga, prečiščeno besedilo, delniška družba, zemljiška knjiga, socialno delo, državni svet, občinski svet, odgovorna oseba, posebna potreba, negativno čustvo, lastninska pravica, študentski dom prednostna naloga, leva stran, škodljivi vpliv, varnostna služba, desna stran, izredna razmera, uradna oseba, tajna služba, državni svet, investicijska družba, delovni čas, terensko delo, prihodnje leto, posredniška družba, zvezna država, ločeno mnenje, brezposelna oseba, mednarodni odnos, ustavna pravica, letalska družba (logDice 8,357)

medpredmet. povezava
neumetnostna besedila
neliterarni eseji
šolski slovar

[pridevnik + samostalnik] samo v Šolarju:
177 zvez izmed 2266 izluščenih (7,8 %)

Prvih 40 glede na logDice

Antigonina sestra (logDice 10,034), Črtomirjev vojak,
Kreonov sin, Rebulov roman, Kreonov zakon, Bronjin
mož, Antigonin brat, Lojzkin starš, Kreonova žena,
Descartesova misel, kiparska naloga*, zavedni deł*,
Kovačičev roman, Polikarpov odnos, Jazonova žena,
Hamletova težava, mrtvaški pot, Polinejkova sestra,
zardele oči, Lojzkine oči, aplikativni cilj*, Polikarpovo
dejanje, Salomin odnos, Gregorjevo mesto,
Sofoklejevo delo, novodobni razum, Bubijevo dekle,
Bogomilina želja, Bronjina želja, Odisejevo mnenje,
Johanaanova glava, Johannova glava, prerokova
glava, edini način, psihično čustvo, edina oseba,
Ožbejev oče, rumeni junak, edini prijatelj (logDice 7,241)

Kvalitativna analiza popravkov v korpusu Šolar

- **Luščenje kolokacij:**
 - vsaj en del zveze mora biti popravljen
 - jezikovni popravek mora biti uvrščen v tip 'napaka besedišča'
- **Izbor za luščenje in analizo:**
 - pridelnik + samostalnik (278)
 - samostalnik + samostalnik (271)
 - glagol + samostalnik (274)

[pridevnik + samostalnik] statistika

- skupaj 278 primerov
- šum: 52 primerov (18,7 %)
- relevantnih za analizo = 226 primerov (81,3 %):
 - popravek besedne zveze: 47 primerov (20,8 %); popravek ene besede v zvezi: 179 (79,2 %)
 - esej/spis: 213 (94,2 %), pisni izdelek (učna ura): 13 (5,8 %)
 - samo slovenščina

[pridevnik + samostalnik]

- praviloma nizke frekvence

red prišla <i>nova</i>	punca	<i>sošolka</i> po imenu :
<i>bivša</i> <i>bivše</i>	punca	<i>dekle</i> . Na vsak na
stvari. <i>Mlada</i>	punca	<i>dekleta</i> <i>dekletc</i>
<i>nlada</i> <i>mlado</i>	punca	<i>dekle</i> nadgrajeval
je o <i>najstniški</i>	punci	<i>dekletu</i> Fatimi Isn
<i>njo</i> <i>prejšnje</i>	punco	<i>dekle</i> . Nisi ji hote
, kako <i>lepo</i>	punco	<i>dekle</i> ima. Julija t

materin	<i>materni jezik</i> in se
materin	<i>materni jezik</i> . Prer
materin	<i>materni jezik</i> lep in
materin	<i>materni jezik</i> . Razl
materinega	<i>maternega jezika</i> .
materinega	<i>maternega jezika</i> .
materinskega	<i>maternega jezika</i> .
materinskem	<i>maternem jeziku</i> in
materinskem	<i>maternem jeziku</i>
materinskemu	<i>materinem</i> <i>jeziku</i>
materinski	<i>materni jezik</i> upora
materinski	<i>materni jezik</i> . Zave
materinski	<i>materni jezik</i> in to j
materinski	<i>materni jezik</i> . V ce
materinski	<i>materni jezik</i> in to j
maternim	<i>maternim jezik</i> je

[pridevnik + samostalnik] nerelevantni primeri

- vsebinsko narobe, besedilni popravki, nerazumljivi popravki, oblika

< p > Tartuffe je bil duhovnik, ki je odšel k **bogatemu** o se mama, ata in Tone odpravili na izlet v **Kranjsko** »lj znano mislijo razsvetljenstva, ki jo je zapisal znan i upogibalo s tokom. < /p > < p > Kreona, *Antigoninega* »elje v Dobjo vas | , kjer imam pevske vaje. **Pevske mesto** meri 275 km², kar nam pove, da je **največje im** . Ko **Polonij pove** | **je Polonij povedal** Klavdiju o a stoji §§§ v | **na** nekem nam neznanem **prevoznem** »jvečkrat opazimo športne copate. Je **velik** | **velika**

Argonu | **Oregonu** na dom in se naprav
goro | **Rogaško Slatino** . Tam je videl
grški | **francoski pisatelj** Descartes
očeta | **strica** , | pa težko uvrstimo |
vaje | **Te** trajajo do šestih , | in ko
mesto | **središče** v Sloveniji. V Ljubljani
Hamletovi | **prinčevi** **ljubezni** do Ofelije,
sredstvu | **avtobusu** , ki bi lahko bil avto
ljubitelj | **ljubiteljica** narave in živali. §

[pridevnik + samostalnik] skupine podobnih primerov leksikalnih popravkov

- tipologija popravkov
- tipologija besedišča
 - izrazi s področja slovenščine – ostalo besedišče (pomenska/pojmovna polja, abstraktnost, strokovnost, pogostost rabe ...)
- beseda – besedna zveza – mejni primeri

[pridevnik + samostalnik] zaznamovano

- večinoma popravki besed, manj zvez

pedofilija, droge, nezvestoba pa so največkrat *rizični jaz* | *Jaz* sem se čisto malo , | – imam *nova* | *novi* . Mislim, da ji je na začetku *pomembna* | *pomemben* </p> <p> Ljudje smo bitja odnosov. Za naše *normalno* e. Romeo je tik pred tem, da spiye strup, a v *zadnjem rali* prisluziti kruh. Vzgajala jih je *kot* | *za pogumne* gremo skupaj na policijo. Ko smo prispeli na *najbližjo* dolgočasna. Prav gotovo ga tudi to potre in je njegovo e prikupiti s tem, da ga je zavajala in ga peljala na vsa

faktorji | *dejavniki* , da se starši od otrok umaknejo, stika z njimi ne
frizuro | *pričesko* in nekaj lažja sem. Čez dva tedna grem na morje s
funkcija | *položaj* kraljice, ker ne ve, kaj se je v resnici zgodilo z
funkcioniranje | *delovanje* potrebujemo drug drugega. Sami pripomoremo k c
momentu | *trenutku* do vežice pride duhovnik Lorenzo, ki Romea seznan
možake | *ljudi* . To vidimo tudi v besedilu kot je: ” | „ Zdaj greš v bo
policijo | *policjsko postajo* , smo poiskali dežurnega policista in mu
brezvezno | *nesmiselno življenje* tako še bolj temno in pesimistično. V
živa | *mogoča potovanja* | , misleč, da gre na službeno potovanje

[pridevnik + samostalnik] nenapake

- bolj specifično (vsebinsko natančnejše, pomensko ožje)

<i>oddigrali</i> <i>odigrali</i> predstavo o Romeu in Juliji, ki je bila <i>prava</i> v različnem času, kar ni bilo značilno za <i>Antično</i> <i>antično</i> obdobju renesanse.	<i>drama</i>	<i>tragedija</i> .
<i>Romeo in Julija</i> sta <i>glavna</i> <i>glavni</i> bo dobro godilo, če ga dobi s kakšno flašo.	<i>gledališče</i>	<i>dramatiko</i> . Tudi v življe
<i>Celotna so</i> <i>sta</i> izpostavljeni dve najbolj temeljni sporočili <i>celotne jaz mislim.</i>	<i>junaka</i>	<i>dram. osebi</i> . Capuletovi so priredi
<i>Odlomek Krst pri Savici</i> je epsko- <i>lirska</i> tudi otroka ne.	<i>knjiga</i>	<i>drama</i> je dokaj grozna, saj se doga
<i>Delo Krst pri Savici</i> je epsko- <i>lirska</i> <i>romantike</i> , ki traja od 1830 do 1848.	<i>knjige</i>	<i>komedije</i> . Prvo sporočilo je povez
<i>Delo</i> je epsko- <i>lirska</i> oba potrudita za to.	<i>pesem</i>	<i>pesnitev</i> , ker <i>sestavlja</i> <i>vsebuje</i>
<i>Nezakonska mati</i> je <i>lirska</i> <i>lirsko</i> Za konec lahko povem, da je Wiliam Shakespeare <i>odličen</i>	<i>pesem</i>	<i>pesnitev</i> , ki izpoveduje čustva in §
<i>Romeo in Julija</i> , ljubezenska tragedija odličnega <i>renesančnega</i> Temu sonetu <i>je sledil</i> <i>sledi</i> Uvod, kjer govorí o <i>sami</i> <i>samih</i> dramatika Williama Shakespearea je najbolj poznana <i>ljubezenska</i> ipravljena storiti marsikaj. Njen značaj spoznavamo skozi <i>celotno</i>	<i>pesnitev</i>	<i>delo</i> , ki spada v obdobje <i>romantik</i>
	<i>pisatelj</i>	<i>dramatik</i> in najboljši pisec tragedij
	<i>pisatelja</i>	<i>dramatika</i> Williama <i>Shakespearea</i>
	<i>vojni</i>	<i>bojih</i> <i>bojih med</i> <i>za</i> pogansko
	<i>zgodba</i>	<i>drama/</i> . Je dramsko delo, zgodba
	<i>zgodbo</i>	<i>dramo</i> in če sprva deluje plehko in

[pridevnik + samostalnik] književnost in jezik

atik Sofokles in <i>je</i> tragično zvrst oz. odlomek je epsko in jena iz treh delov. Prvi del je nes imamo vse preveč tujk in <i>večinoma</i> uporabljamo sleng, jonska mati spada v liriko in je jonska mati spada v liriko in je	dramatsko ilirsko posvetni prenesenih privzete vložena vložena	<i>dramska besedilo</i> . <i>lirska besedilo</i> , to <i>posvetilni sonet</i> Mat <i>prevzetih besed</i> iz r <i>prevzete besede</i> , p <i>vložna pesem</i> . Nast <i>vložna pesem</i> . Nast
---	---	--

[pridevnik + samostalnik] oblikovno blizu, pomenško različne

raje rekli država ponekod še vedno obnaša na tak **diskriminanten** | *diskriminatorem način* . Na
Po končani osnovni šoli , | se je vpisal v srednjo **električno** | *elektro šolo* ſſſ – TOK, v \
e in junakovega idealu. </p> <p> V delu je veliko **izpovednih** | *izpovedanih čustev* , še po:
šestdeset let. </p> <p> Na našo šolo je prišel kot **književni** | *knjižni gost* , zato , | ker
velik nesmisel, karikira pomembne osebnosti. Za **Majhne** | *male ljudi* , kamor spada t
” (umobolnici), prav tako tudi **veliki** | *starejši* in **mali** | *mlajši izvedenec* za metaf
Kreonu privedli Antigono, **kot** | storilko **tega** | **protizakonskega** | *protizakonitega dejanja* .
ka je bila poražena. Da je bilo to delo Prešernova **osebnostna** | *osebna izpoved* , bi lahko i
Prešeren preusmeri slog predvsem na Črtomirovo **osebnostno** | *osebno raven* . Zato pravin
cela družina ostane sama? Spomnim se družine iz **sosedovega** | *sosednjega kraja* , kjer sei
rja , | pridejo mladi in stari v Podpeco in gradijo **snežene** | *snežne gradove* . Imenuješ
ključek bi lahko neskončne ure pisali, kaj je prav, **trda** | *trdna načela* ali prilagajan

[pridevnik + samostalnik] oblikovno blizu, pomensko različne

Gregor je partizan, ki na *rutinskem* ila Črtomirja. Krščanska vera govori o ljubil Bogomilo in je hotel biti tudi v opazovalec | , saj je opazil čisto vse i. Poznam en primer ki zaradi *verske*

sprehodu
posvetnem
posvetnem
možne
izpovednosti

| *obhodu* opazi mladenko, ki s svojimi kre |
| *posmrtnem življenju* , | – da bosta lal |
| *posmrtnem življenju* znjo. Črtomir se je |
| *mogoče podrobnosti* . Od ženice do nek |
| *verske pripadnosti/izpovedi* starši svoji |

[pridevnik + samostalnik] kolokacije

- uporaba pomensko neustrezne kolokacije:

posvetno > posmrtno življenje, iz socialnega **reda** > sloja, na družbeni **ravni** > lestvici, na višji **ravni** > na višjem položaju, filmski **trak** > filmsko platno

- manj običajna kombinacija besed:

nabрано > naropano bogastvo, imeti **v popolni kontroli** > pod kontrolo, **zadelana** > zamašena ušesa, **zlati** > velik zaslužek, biti vzipljive **jeze** > narave, vse **mogoče** > možne podrobnosti, **velika** > visoka samopodoba

- mešanje:

verska **izpovednost** > pripadnost/izpoved, nadmorska **gladina** > višina

Ocena kvalitativne analize

- razmeroma zamudna
- frekvence relevantnih primerov so nizke, a so podatki pomembni > prispevajo k razumevanju procesov usvajanja „aktivnega“ besedišča > načrtovanje pouka leksike, izbor gradiv za usvajanje besedišča in snovanje priročnikov
- na podlagi trenutnih delnih analiz posploševanje rezultatov še ni mogoče oz. zaključki o procesih usvajanja kolokacij (leksike) ne morejo biti zanesljivi

Kako naprej?

- primerjalno luščenje kolokacij razširiti tudi na manj frekventne samostalnike > primerjava s podatki iz kvalitativne analize
- primerjalno luščenje kolokacij uporabiti na verziji korpusa Šolar brez popravkov (šum!) > statistična analiza
- obe metodi (primerjalno luščenje kolokacij in kvalitativno analizo popravkov) razširiti na druge zveze
- ? analiza po razredih
- ? leksikalne analiza besed (kot osnova)
- ??? nove ideje ???

Reference

Špela Arhar Holdt in Tadeja Rozman. 2015. Možnosti uporabe podatkov iz korpusa Šolar za pripravo slovarskih priročnikov. V: M. Smolej, ur., Obdobja 34: Slovnična in slovar - aktualni jezikovni opis, 1. del, str. 67–74. Znanstvena založba Filozofske fakultete UL. http://centerslo.si/wp-content/uploads/2015/11/34_1-Arhar-Hol-Roz.pdf

Vojko Gorjanc, Polona Gantar, Iztok Kosem in Simon Krek, ur. 2015. *Slovar sodobne slovenščine: problemi in rešitve*. Znanstvena založba Filozofske fakultete UL.

Adam Kilgarriff, Pavel Rychly, Pavel Smrz in David Tugwell. 2004. The Sketch Engine. V: G. Williams in S. Vessier, ur., *Proceedings of the Eleventh EURALEX International Congress, EURALEX 2004 Lorient, France July 6–10, 2004*, str. 105–116. Université de Bretagne-sud.

Iztok Kosem, Mojca Stritar Kučuk, Sara Može, Ana Zwitter Vitez, Špela Arhar Holdt in Tadeja Rozman. 2012. *Analiza jezikovnih težav učencev: korpusni pristop*. Trojina, zavod za uporabno slovenistiko.

Nataša, Logar, Miha Grčar, Marko Brakus, Tomaž Erjavec, Špela Arhar Holdt, Simon Krek. 2012: *Korpusi slovenskega jezika Gigafida, KRES, ccGigafida in ccKRES: gradnja, vsebina, uporaba*. Trojina, Fakulteta za družbene vede.

Senja Pollak. 2015. Luščenje kolokacij iz korpusa uporabniških spletnih vsebin. V: M. Smolej, ur., *Obdobja 34: Slovnična in slovar - aktualni jezikovni opis*, 2. del, str. 601–607. Znanstvena založba Filozofske fakultete UL. http://centerslo.si/wp-content/uploads/2015/11/34_2-Pollak.pdf

Senja Pollak in Špela Arhar Holdt. 2015. Identifying corpus-specific collocations: the case of spoken Slovene. V: K. Gajdošová in A. Žáková, ur., *Natural language processing, corpus linguistics, lexicography: proceedings*, S. l., str. 117–125. RAM-Verlag.

Tadeja Rozman, Iztok Kosem, Nataša Pirih Svetina in Ina Ferbežar. 2015. Slovarji in učenje slovenščine. V: V. Gorjanc, P. Gantar, I. Kosem in S. Krek, ur., *Slovar sodobne slovenščine: problemi in rešitve*, str. 150–167. Znanstvena založba Filozofske fakultete UL.

Tadeja Rozman, Irena Krapš Vodopivec, Mojca Stritar Kučuk in Iztok Kosem. 2012. *Empirični pogled na pouk slovenskega jezika*. Trojina, zavod za uporabno slovenistiko.

Marko Stabej. 2011. Jezikovni potrošnik in potrošnica. *Sodobna pedagogika*, 62=128(2), 102–113. Zveza društev pedagoških delavcev Slovenije. <http://www.dlib.si/details/URN:NBN:SI:doc-RF8JNPLQ>