



Center za
jezikovne vire
in tehnologije



Univerza v Ljubljani



PROP

Priprava učnih gradiv s korpusom šolskih pisnih izdelkov Šolar 3.0

[Filozofska fakulteta, 24. 11. 2023]

Špela Arhar Holdt

Spela.ArharHoldt@ff.uni-lj.si

Predstavitev

- **Center za jezikovne vire in tehnologije:** raziskovalna enota Univerze v Ljubljani, razvoj **jezikovnih virov in orodij** za sodobno slovenščino.
- Npr. Slovar sopomenk sodobne slovenščine, Kolokacijski slovar sodobne slovenščine, Sloleks, korpus Gigafida, orodje Vejice ...
- Raziskovalni projekti, mdr.
Empirična podlaga za digitalno podprt razvoj jezikovnih kompetenc (ARIS J7-3159).



Ogrevanje: šolsko popravljanje besedil

"Antigona se bari za pravicnost. Tako tudi
čeli Škreova dokonati, da ne more ukončiti življenje
vsiliti in da ustanove dolocijo dogf. Teli dokonati, da

Izzivi šolskega popravljanja besedil

- V učnem procesu vrsto in količino popravkov **prilagajamo** razvojni stopnji učenke oz. učenca in drugim relevantnim okoliščinam.
- Določeni popravki so nedvoumni (npr. ločila, črkovanje, velike ali male začetnice, zapis skupaj ali narazen), velik del je pa **interpretativen** in tu so možne raznovrstne odločitve (slogovni, vsebinski popravki).
- Upoštevati je treba jezikovno **variantnost**: ne zanima nas le, kaj popravljati, ampak tudi, česa ne.
- Priprava premišljene, kakovostne povratne informacije zahteva **veliko časa**, učinki pa so vidni šele na srednji in dolgi rok.
- Prakse so relativno **slabo raziskane**, ne obstajajo jasne smernice, tudi ne pri izobraževanju za učiteljski poklic.

Korpus Šolar 3.0

- Zbirka pisnih izdelkov, ki so jih učenci in dijaki (zadnja triada OŠ in različne SŠ) samostojno tvorili pri pouku, predvsem
- 5.485 besedil (1.638.229 besed), predvsem **spisi in eseji**.
- Besedila smo zbrali s pomočjo učiteljic in učiteljev iz **vseh slovenskih regij in različnih vrst šol**.
- Besedila, ki so bila po večini pisana na roko, smo **pretipkali in dodatno uredili**, da jih lahko analiziramo z digitalnimi orodji.
- Cca. tretjina besedil (35,6 %) vsebuje **učiteljske popravke**, ki smo jih transkribirali in vsebinsko kategorizirali: skupno je v korpusu **36.570** avtentičnih jezikovnih popravkov z oznako problema.

10:20068

Antigona

~~Antigona~~ je vladarica, ki se ~~legi~~ so pravčnost. bratov. ~~Antigona~~ je ~~krasna~~ učiteljica in bo Threon napo to išču, in jo nalliu ka ~~nem~~. da li ~~je~~, saj je to naredilo.

Antigona se bori za pravčnost. Tako tudi želi Threona dokazati, da ne mor sakerov ljudev usiliti in da učence določijo dogaj. Teli dokazati, da je ~~to~~ Threon narekel ~~in naj~~ ~~je~~ ~~pridobiti~~ Polinejka. ~~Antigona~~ ne mogla kriči lečnih pravil, ~~čeudi~~ ~~je~~ ~~bilo~~ strah pred človekom. ~~le~~ ~~ne~~ ~~bo~~ imela. Da tia napoveda po snati, ji vedela, in ee na to nizmonila. Nič je ni bolo ločljivo, ker da ne bi mogla pokopati brata. in ~~adel~~ ~~in~~ Threon je nare, įe norostē

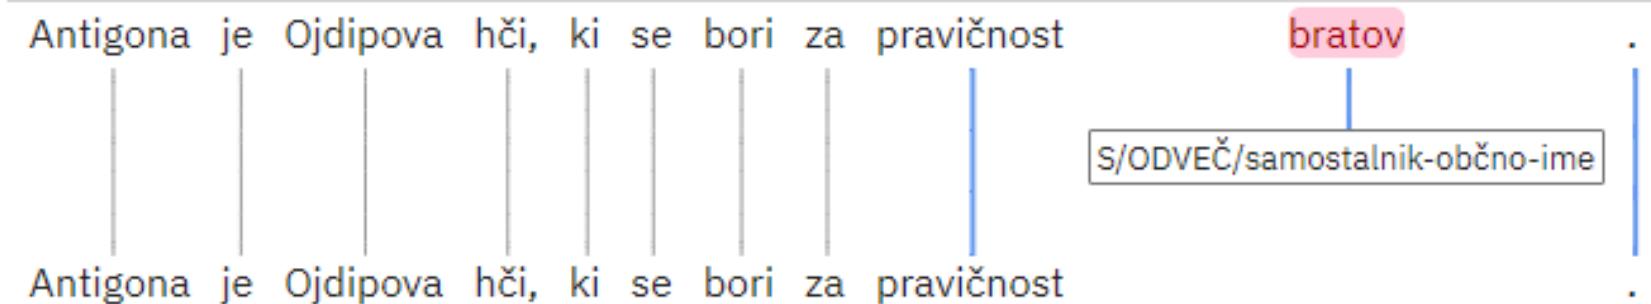
Izvorno besedilo

Antigona je Ojdipova hči, ki se bori za pravičnost bratov. Antigona prekrši Kreonov ukaz in Kreon za to izve in jo pokliče k njemu. Da bi izvedel, zakaj je to naredila.

Popravljeno besedilo

Antigona je Ojdipova hči, ki se bori za pravičnost. Prekrši Kreonov ukaz in ko Kreon za to izve, in jo pokliče k sebi, da bi izvedel, zakaj je to naredila.

Oznake popravkov (orodje CJVT Svala)



Jezikovni popravki v korpusu Šolar

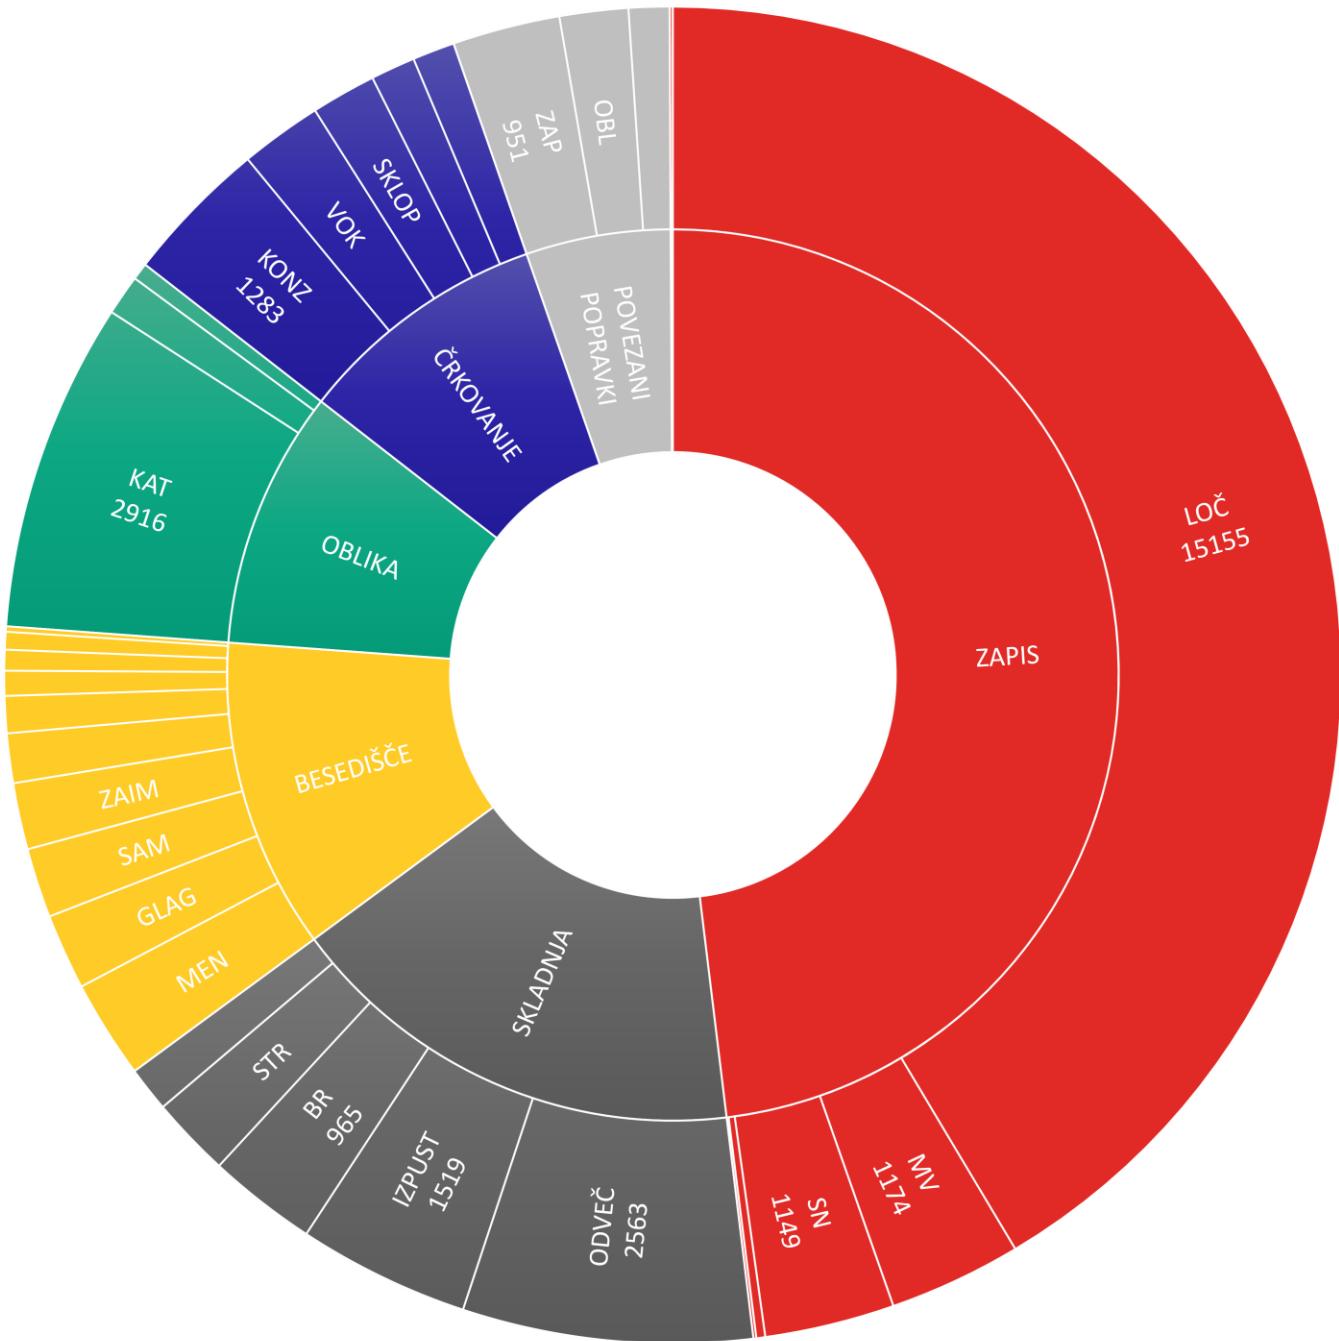
- Jezikovni popravki so razvrščeni v 180 različnih skupin, kar opisujejo smernice [Arhar Holdt et al. 2022.](#)
- Oznake, s pomočjo katerih lahko najdemo primere jezikovnih problemov, so sestavljene iz treh delov (**Z/MV/osebna-imena**)
 - **1. nivo = jezikovna ravnina:** zapis, črkovanje, oblika, besedišče, skladnja, povezani popravki + oznake za nečitljivo besedilo.
 - **2. nivo = tip problema,** npr. zapis se deli na popravke ločil, male/velike začetnice, pisanja skupaj/narazen, zapisa kratic in zapisa števil.
 - **3. nivo = natančnejši opis problema,** npr. zapis začetnice se deli na *osebna-imena, pridevnik-ski, premi-govor, začetek-povedi* ...

Gradivo:

smernice za označevanje

| | |
|--|----------|
| 1 ČRKOVANJE | 6 |
| 1.1 Vokali | 6 |
| 1.1.1 Odvečni vokal = Č/VOK/odveč | 6 |
| 1.1.2 Izpuščeni vokal = Č/VOK/izpust | 7 |
| 1.1.3 Menjava AO = Č/VOK/menjava-ao..... | 7 |
| 1.1.4 Menjava EI = Č/VOK/menjava-ei | 8 |
| 1.1.5 Menjava UO = Č/VOK/menjava-uo | 8 |
| 1.1.6 Druge menjave vokala = Č/VOK/menjava-drugo..... | 8 |

<https://www.cjvt.si/prop/wp-content/uploads/sites/23/2023/11/Smernice-za-oznacevanje-korpusa-Solar-v1.1.pdf>



Gradivo: frekvečni seznam problemov

| 1 | ID besedila | ID odstavka | D. stavki | Ime besedila | Leto | Šola | Predm. | Razre | ip besé | Regij | oj | Koda popravka | 1 rave | 2 rave | 3 raven | šklic popra | Izvorna poved | Končna po |
|---|-------------|-------------|-----------|---|------|--------------------------------|--------------------|-------------------------|---------|-------|-----------------|---|--------|--------|---------|-------------|---------------|-----------|
| 2 | solar1s | solar1s.3 | | solar1s.3.; KUS-G-slo-1-GO-E-2009-10001 | 2009 | gimnazija slovenščir 1. letnik | esej ali sp Gorica | 1 Z/LOČ/nerazvrščeno | Z | LOČ | nerazvrščeno | #solar1s.3.1.1 "Ne da sovražim, da ljubim sem na svetu", Ne da sovražim, | | | | | | |
| 3 | solar1s | solar1s.3 | | solar1s.3.; KUS-G-slo-1-GO-E-2009-10001 | 2009 | gimnazija slovenščir 1. letnik | esej ali sp Gorica | 1 Z/LOČ/nerazvrščeno | Z | LOČ | nerazvrščeno | #solar1s.3.1.1 "Ne da sovražim, da ljubim sem na svetu", Ne da sovražim, | | | | | | |
| 4 | solar1s | solar1s.3 | | solar1s.3.; KUS-G-slo-1-GO-E-2009-10001 | 2009 | gimnazija slovenščir 1. letnik | esej ali sp Gorica | 1 O/KAT/povratnost | O | KAT | povratnost | #solar1t.3.1.1 "Ne da sovražim, da ljubim sem na svetu", Ne da sovražim, | | | | | | |
| 5 | solar1s | solar1s.3 | | solar1s.3.; KUS-G-slo-1-GO-E-2009-10001 | 2009 | gimnazija slovenščir 1. letnik | esej ali sp Gorica | 1 B/SAM/občno-besedišče | B | SAM | občno-besedišče | #solar1s.3.2.1 V tem verzu je dala vedeti, da živi iz ljube V tem verzu je da | | | | | | |
| 6 | solar1s | solar1s.3 | | solar1s.3.; KUS-G-slo-1-GO-E-2009-10001 | 2009 | gimnazija slovenščir 1. letnik | esej ali sp Gorica | 1 Z/LOČ/nerazvrščeno | Z | LOČ | nerazvrščeno | #solar1t.3.2.3 V tem verzu je dala vedeti, da živi iz ljube V tem verzu je da | | | | | | |
| 7 | solar1s | solar1s.3 | | solar1s.3.; KUS-G-slo-1-GO-E-2009-10001 | 2009 | gimnazija slovenščir 1. letnik | esej ali sp Gorica | 1 B/MEN/drugo | B | MEN | drugo | #solar1s.3.3.4 Ljubezen poznamo v večjih oblikah; najp Ljubezen poznam | | | | | | |
| 8 | solar1s | solar1s.3 | | solar1s.3.; KUS-G-slo-1-GO-E-2009-10001 | 2009 | gimnazija slovenščir 1. letnik | esej ali sp Gorica | 1 O/KAT/spol | O | KAT | spol | #solar1s.3.3.7 Ljubezen poznamo v večjih oblikah; najp Ljubezen poznam | | | | | | |
| 9 | solar1s | solar1s.3 | | solar1s.3.; KUS-G-slo-1-GO-E-2009-10001 | 2009 | gimnazija slovenščir 1. letnik | esej ali sp Gorica | 4 Č/SKLOP/nj | č | SKLOP | nj | #solar1s.3.3.1 Ljubezen poznamo v večjih oblikah; najp Ljubezen poznam | | | | | | |

<https://www.cjvt.si/prop/wp-content/uploads/sites/23/2023/11/Izobrazevalne-uciteljev-Frekvencni-seznam-jezikovnih-popravkov-Solar-3.0.xlsx>

Delo s programom: Šolar 3.0 v konkordančniku

<https://solar.cjvt.si/>

https://www.clarin.si/noske/run.cgi/first_form?corpname=solar30_orig;align=

POPRAVKI ČRKOVANJA

| POPRAVKI KONZONANTA | | POPRAVKI VOKALA | | | PROBLEMATIČNI SKLOPI | | |
|----------------------|-------------------|----------------------------|--------------------|--------------------------|----------------------|--------------------------|--------------|
| izpust 568 | | izpust 285 | | menjava- drugo 106 | | | |
| odveč 180 | menjava-sz 96 | menjava- strešice 92 | odveč 74 | | lj 212 | nj 193 | |
| menjava-drugo 158 | menjava-td 60 | menjava-mn 44 | menjava-ao 102 | menjava-ei 89 | menjava-uo 68 | ij 62 | zlog 40 |
| | menjava-kgh 49 | menjava-ž 36 | VARIANTNI PREDLOGI | | | ZAPISANI [W] | |
| | | | sz 373 | | | k... začetek 2... 196 | konec 103 |
| | | | | | | sredina 52 | v 22 |

■ POPRAVKI KONZONANTA ■ POPRAVKI VOKALA ■ PROBLEMATIČNI SKLOPI ■ VARIANTNI PREDLOGI ■ ZAPISANI [W]

POPRAVKI OBLIKE

| POPRAVEK KATEGORIJE | | | | | POPRAVEK PARADIGME | | | POPRAVEK DODATNE OZNAKE | |
|---------------------|--|-------------------|--|--------------------------|--------------------|-----------------------------|--|-----------------------------|--|
| sklon-drugo 490 | | število-em 317 | | čas 276 | | število-dm 246 | | neglagolska-končnica 106 | |
| sklon-rt 341 | | spol 206 | | nedoločnik-kratki 165 | | nedoločnik-namenilnik 99 | | glagolska-končnica 104 | |
| povratnost 175 | | število-ed 124 | | oseba 67 | | naklon 57 | | glagolska-osnova 51 | |
| | | | | | | vid 46 | | preglas-in-cč 40 | |
| | | | | | | oblika-zaimka 73 | | neglagolsk... osnova 32 | |
| | | | | | | stopnjevanje 31 | | neobst-vokal 24 | |
| | | | | | | določnost 41 | | DODATNA OZNAKA | |
| | | | | | | način 26 | | | |
| | | | | | | ned... ose... 24 | | besede-mati-hči 68 | |
| | | | | | | variantе 46 | | | |
| | | | | | | besede-otrok | | | |

■ POPRAVEK KATEGORIJE ■ POPRAVEK PARADIGME ■ DODATNA OZNAKA

Tako tudi želi Kreonu dokazati , da ne more zakone
 Tako tudi želi Kreonu dokazati , da ne more zakonov

O/KAT/sklon-rt

zakonov

The screenshot shows the NoSketch Engine interface with the following details:

- Corpus:** Šolar: učenci (razvojni)
- Simple query:** O_KAT_sklon-rt
- Query type:** CQL (selected)
- CQL:** [errtype="O_KAT_sklon-rt"]
- Default attribute:** errtype = Type of error

Zamenjati poševnice s podčrtajem!

NoSketch Engine Šolar: učenci (razvojni)

Home Search Word list Corpus info My jobs User guide ↗

Save Make subcorpus View options KWIC Sentence Sort Left Right Node References Shuffle Sample Filter Sub-hits 1st hit in doc Frequency Node tags Node forms Doc IDs Text types Collocations Visualize ? Menu position

Query O_KAT_sklon-rt 341 (178.76 per million) ⓘ

Page 1 of 14 Go Next | Last

KUS-G-slo-1-GO-E-2009-10002,1. letnik,gimnazija KUS-G-slo-2-GO-E-2009-10004,2. letnik,gimnazija KUS-G-slo-2-GO-E-2009-10004,2. letnik,gimnazija KUS-G-slo-1-GO-E-2009-10006,1. letnik,gimnazija KUS-G-slo-1-GO-E-2009-10006,1. letnik,gimnazija KUS-G-slo-2-GO-E-2009-10007,2. letnik,gimnazija KUS-G-slo-2-GO-E-2009-10008,2. letnik,gimnazija KUS-G-slo-4-GO-E-2009-10011,4. letnik,gimnazija KUS-G-slo-4-GO-E-2009-10011,4. letnik,gimnazija KUS-G-slo-4-GO-E-2009-10021,4. letnik,gimnazija KUS-G-slo-4-GO-E-2009-10024,4. letnik,gimnazija KUS-G-slo-4-GO-E-2009-10024,4. letnik,gimnazija KUS-G-slo-4-GO-E-2009-10025,4. letnik,gimnazija KUS-G-slo-4-GO-E-2009-10027,4. letnik,gimnazija KUS-G-slo-4-GO-E-2009-10027,4. letnik,gimnazija KUS-G-slo-4-GO-E-2009-10027,4. letnik,gimnazija KUS-G-slo-4-MB-E-2010-10039,4. letnik,gimnazija KUS-G-slo-1-MB-E-2008-10040,1. letnik,gimnazija KUS-G-slo-3-LJ-E-2009-10052,3. letnik,gimnazija KUS-G-slo-3-LJ-E-2009-10052,3. letnik,gimnazija KUS-G-slo-3-LJ-E-2009-10057,3. letnik,gimnazija KUS-G-slo-3-LJ-E-2009-10057,3. letnik,gimnazija KUS-G-slo-4-GO-E-2009-10065,4. letnik,gimnazija

Njena sestra pa je ravno nasprotnega mišlenja, kar v začetku navzven ne kaže preveč, vendar po „. Na prvem mestu je bilo sploh to, da bi naučili slovenski jezik. In ko so potem ljudje, kot je bil Linhart mestu je bilo sploh to, da bi naučili slovenski jezik. In ko so potem ljudje, kot je bil Linhart pisali nič omajalo, dokler ni moje telo začelo kazati vidne znake utrujenosti. V tistem obdobju sem eno , dokler ni moje telo začelo kazati vidne zbrane utrujenosti. V tistem obdobju sem eno izmed ženi in ne Nežki pa tudi osvajal je baronico in ne Nežko , kar pa je obema ugajalo. Le Matiček ni vedel za dan ali Matiček se ženi je komedija, katere bistvo ne razumeš, če ne veš tudi zgodovinskega , čustva. Samega sebe ni doživljal kot samostojno osebo z lastnimi ideali in cilji, ampak kot . Samega sebe ni doživljal kot samostojno osebo z lastnimi ideali in cilji, ampak kot partizana . Na zaslišanju je sicer zanikala krivdo, ni pa Berk je bolj intelektualce kot zgolj partizan. Vojno ne jemlje tako resno kot Gregor. Berk je , ki ti nekaj pomeni. Zelo težko bi se spopadala s osebe , ki ti nekaj pomeni. Zelo težko bi se spopadala s to hotela utemeljiti, zato so jo obsodili na smrt. lika romana Senčni ples. Kandor se po smrti svoje in zunanjim življenjem. Želijo si notranjega, uredničitev svojih sanj, želja, ampak so primorani ostati v od njih samih. Vem, da se usode ne da predvideti, jo spremeniti, a vendar naj bi se vsak za svojo tak, da je delal vse po svoje. Bil je z Vesno, kar ne bi smel. Zato je bil tudi prisiljen iti v za pomoč, takšnih ki se borijo za mir in drugačnih ki želijo uničiti problem razlik med ljudmi, Argonu povedala, kaj se v njegovi hiši dogaja ji tega ni vрel. Zato je njegova žena naredila načrt, z Bogom ne more nihče pozdraviti in spremeniti to to miselnost. Sam menim, da je prav cerkev kriva za Bogom ne more nihče pozdraviti in spremeniti to ko sem le eden od pečice, ki meni tako in ne morem , kako absurdno je življenje. Mislim, da ta miselnost. Sam menim, da je prav cerkev kriva za spremeniti. Omejiti je treba cerkveno oblast a , kako absurdno je življenje. Mislim, da ta ta ubojo in zakrivil namerno, kajti v nekem in zakrivil namerno, kajti v nekem trenutku, se glavni cilj v katerem vidi smisel. Ne ustavi ubojo nobena oblast in moč ki je nad njo. To je njena jo

Page 1 of 14 Go Next | Last

Novosti različice 3.0

- Skladenske oznake sistema JOS-SYN, po katerih je mogoče tudi iskati s programom Q-CAT.
- 93,89 % natančnost (SUK).

Link and chunk search

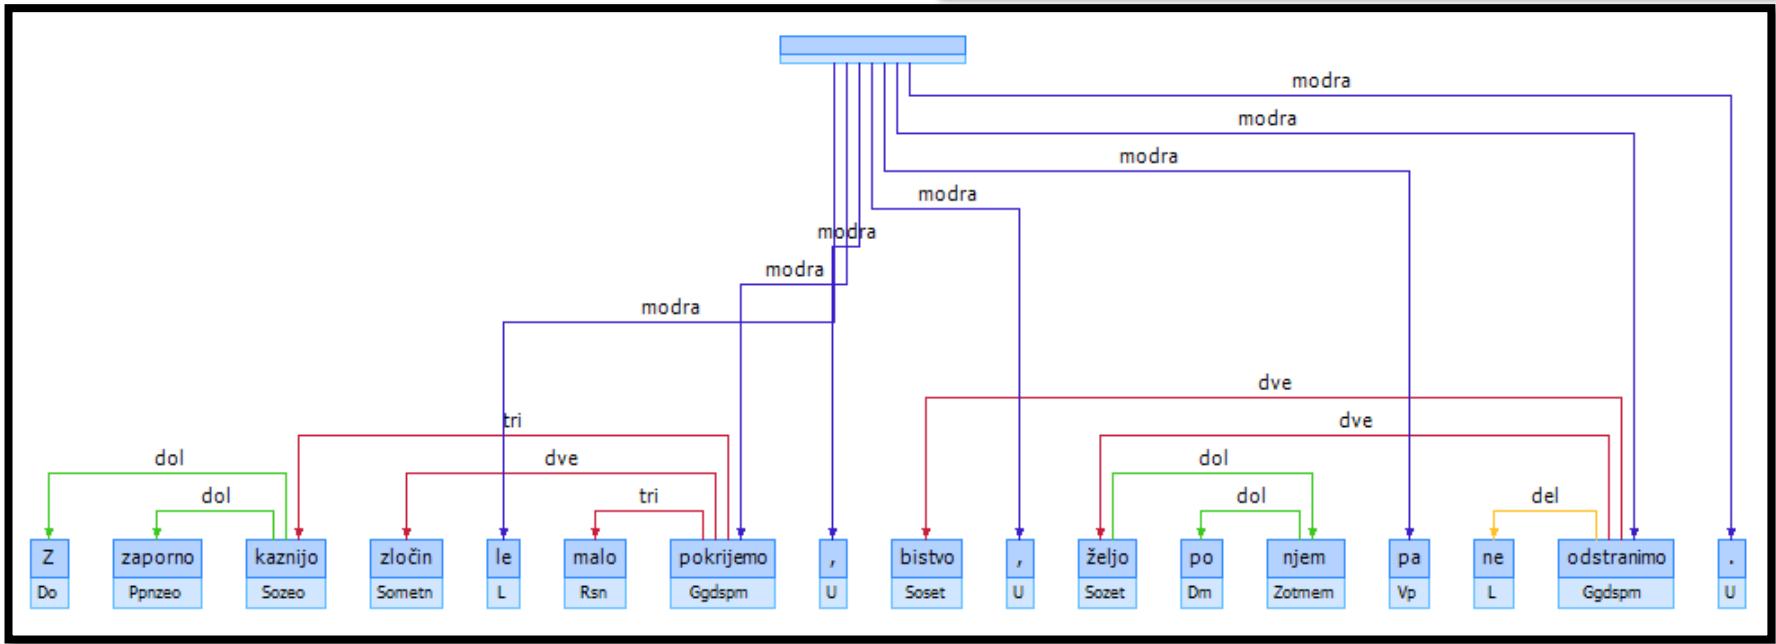
| | | | | | | | |
|---------|-----------------------------------|----|-----------------------------------|-------|-----------------------------------|---|--|
| A | <input type="checkbox"/> for each | B | <input type="checkbox"/> for each | C | <input type="checkbox"/> for each | D | <input checked="" type="checkbox"/> for each |
| Ana | G* | | | S??t* | | | D |
| Lemma | | ne | | | | | |
| Surface | | | | | | | |
| UPOS | | | | | | | |

Link and chunk constraints

| | | | | | | | | |
|---|---------------|--------|------|---|----|---|---------|-------------|
| X | exists | a link | from | A | to | B | of type | JOS-SYN:del |
| X | exists | a link | from | A | to | C | of type | JOS-SYN:dve |
| X | doesn't exist | a link | from | C | to | D | of type | JOS-SYN:* |
| + | | | | | | | | |

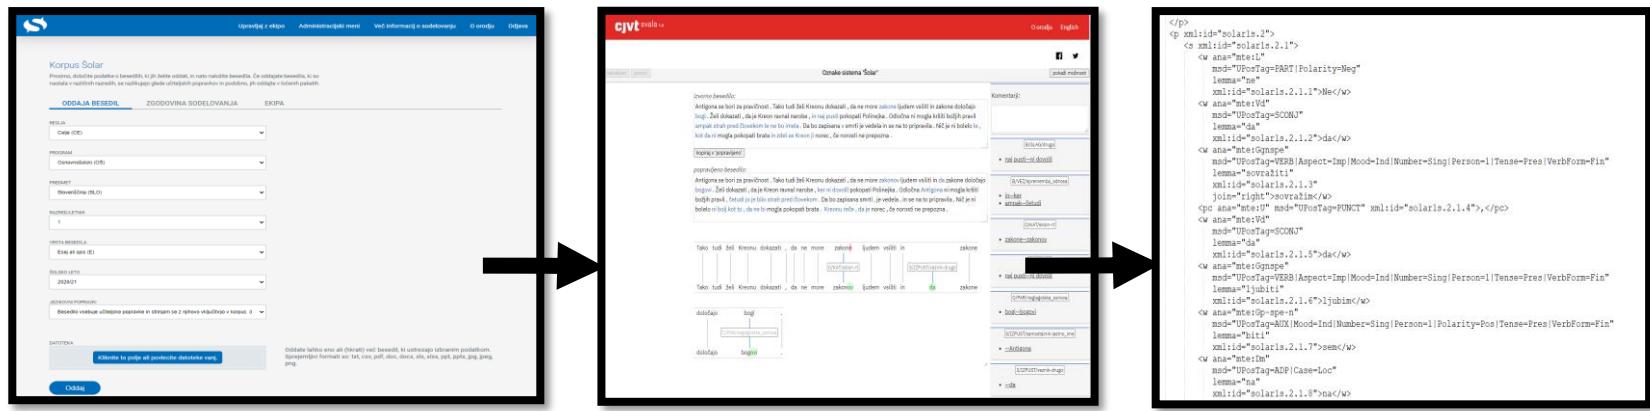
| Sentence | A | B | C | A -> B | A -> C |
|----------------|------------|----|------------|-------------|-------------|
| solar104s.8.5 | imelo | ne | Šalo | jos-syn:del | jos-syn:dve |
| solar132s.3.51 | odstranimo | ne | bistvo | jos-syn:del | jos-syn:dve |
| solar132s.3.51 | odstranimo | ne | željo | jos-syn:del | jos-syn:dve |
| solar136s.7.1 | zasledimo | ne | pravičnost | jos-syn:del | jos-syn:dve |
| solar197s.2.5 | izvemo | ne | razlog | jos-syn:del | jos-syn:dve |

Search... Clear 147 results Save...



Novosti različice 3.0

- Nova metodologija priprave korpusa in nov format.



Šolska besedila in
metapodatke
zberemo prek **portala
za učitelje**.

Besedila transkribiramo,
anonimiziramo in
popravke vsebinsko
označimo s programom
CJVT Svala.

Pripravimo korpus v
specializiranem XML
TEI za korpuse z
jezikovnimi popravki.

Dostopnost korpusa

- Kosem, Iztok; Rozman, Tadeja; Pori, Eva; Arhar Holdt, Špela; Kocjančič, Polonca; Laskowski, Cyprian; Klemenc, Bojan, 2019, ***Developmental corpus ccŠolar 1.0***, Slovenian language resource repository CLARIN.SI.
- Kosem, Iztok; Arhar Holdt, Špela; Stritar Kučuk, Mojca; Krek, Simon; Krapš Vodopivec, Irena; Stabej, Marko; Pori, Eva; Goli, Teja; Lavrič, Polona; Laskowski, Cyprian; Kocjančič, Polonca; Klemenc, Bojan; Rozman, Tadeja, 2019, ***Developmental corpus Šolar 2.0***, Slovenian language resource repository CLARIN.SI.
- Kosem, Iztok; Arhar Holdt, Špela; Stritar Kučuk, Mojca; Krek, Simon; Krapš Vodopivec, Irena; Stabej, Marko; Kocjančič, Polonca; Laskowski, Cyprian; Klemenc, Bojan; Pori, Eva; Rozman, Tadeja, 2019, ***Developmental corpus (without language corrections) Šolar 2.0 Clear***, Slovenian language resource repository CLARIN.SI.
- Arhar Holdt, Špela; Goli, Teja; Lavrič, Polona; Laskowski, Cyprian; Klemenc, Bojan; Rozman, Tadeja; Stritar Kučuk, Mojca; Krek, Simon; Krapš Vodopivec, Irena; Stabej, Marko; Kosem, Iztok, 2019, ***Error-annotated developmental corpus Šolar 2.0 Error***, Slovenian language resource repository CLARIN.SI.
- Arhar Holdt, Špela; Rozman, Tadeja; Stritar Kučuk, Mojca; Krek, Simon; Krapš Vodopivec, Irena; Stabej, Marko; Pori, Eva; Goli, Teja; Lavrič, Polona; Laskowski, Cyprian; Kocjančič, Polonca; Klemenc, Bojan; Krsnik, Luka; Kosem, Iztok; 2022, ***Developmental corpus Šolar 3.0***, Slovenian language resource repository CLARIN.SI.

The screenshot shows the konText interface with the following details:

- Query:** corpora Save Concordance Filter Frequency Collocations View Help
- Corpus:** šolar: učenci (razvojni) | Query: nebi (697 hits)
- Hits: 697 | l.p.m.: 365.39 (related to the whole corpus) | ARF: 352.04 | Result is sorted**
- Line selection: simple ▾**
- Results:** A list of 697 hits, each corresponding to a document ID (e.g., KUS-G-slo-2-00-E-2009-10005) and its content snippet. The snippets are in Slovene and discuss various topics like comedy, love, and life experiences.

NoSketchEngine interface (bottom right):

- Query:** nebi
- Page:** 1 of 35 | Go | Next | Last
- Results:** A list of 35 hits from the 'nebi' query, showing snippets from the 'Šolar: učenci (razvojni)' corpus.

Podobni korpusi za druge jezike

- Angleščina: **The LUCY Corpus** (Sampson 2003): mladostniki (33.000 besed), otroci 9–12 let (30.000 besed); **the LONESS corpus** (Granger, 1998): britanski učenci (60.209 besed), britanski in ameriški študenti (264.095 besed); **zbirka esejev Parr** (2010): 20.947 esejev novozelandskih učencev 4.–12. leta šolanja.
- Nemščina: **H1, H2, E2, ERK1** (Berkling 2016, 2018): šolarji 6–11 let (81.385 pojavnici); **the Litkey Corpus** (Laarman-Quante et al. 2019): 2.–4. razred (212.505 pojavnici); **the KoKo Corpus** (Abel et al. 2014): srednješolski eseji (950.000 pojavnici).
- Italijanščina: **ClTA** (Barbagli et al. 2016): 1.352 srednješolskih esejev; 5.000 spisov 1.–5. razred (Marconi et al. 1993) in 2.500 spisov iz 1. letnika rimskih SS (Borghi 2013).
- Francoščina: **È:CALM** (Ho-Dac et al. 2020), ki združuje cca. 6.700 besedil od OŠ do fakultete iz različnih korpusov (Garcia-Debanc in Bonnemaison 2014; Doquet et al. 2017; Jacques in Rinck 2017; Wolfarth et al. 2017).
- **LEONIDE** (Glaznieks et al. 2022): 2.512 srednješolskih esejev z večjezikovnega južnotiolskega območja. **DOESTE v0.5** (Martins et al. 2020): učenci in dijaki 10–18 let (244 esejev v portugalščini in 450 v brazilski portugalščini). **The Icelandic (Child) Error Corpus** (Arnardóttir et al. 2021, Ingason et al. 2021): 176 srednješolskih esejev in 119 besedil učencev 10.–15. leta. Češki **Chyby** (Pala et al. 2003): cca. 410.000 besed študentskih izdelkov – vključuje avtentične popravke dveh profesorjev.

Raziskave in objave

Opis namena in sestave korpusa Šolar 1.0 in 2.0

- Iztok Kosem, Sara Može (2011): [Rešitve sloveničnih zagat na dosegu miške: analiza napak v besedilih učencev in dijakov za potrebe elektronskega sloveničnega vira](#). V: S. Krajnc (ur.) Meddisciplinarnost v slovenistik, (Obdobja, Simpozij). Ljubljana: Znanstvena založba Filozofske fakultete, str. 249-257.
- KOSEM, Iztok; ROZMAN, Tadeja; STRITAR, Mojca. [How do Slovenian primary and secondary school students write and what their teachers correct: A corpus of student writing](#). In: *Proceedings of Corpus Linguistics Conference*. 2011. p. 20-22.
- Tadeja Rozman, Irena Krapš Vodopivec, Mojca Stritar Kučuk, Iztok Kosem. 2012. [Empirični pogled na pouk slovenskega jezika](#). Zbirka Sporazumevanje.
- Iztok Kosem, Mojca Stritar Kučuk, Sara Može, Ana Zwitter Vitez, Špela Arhar Holdt, Tadeja Rozman. 2012. [Analiza jezikovnih težav učencev, korpusni pristop](#). Zbirka Sporazumevanje.
- KOSEM, Iztok, ROZMAN, Tadeja, ARHAR HOLDT, Špela, KOCJANČIČ, Polonca, LASKOWSKI, Cyprian Adam. [Šolar 2.0 : nadgradnja korpusa šolskih pisnih izdelkov](#). V: ERJAVEC, Tomaž (ur.), FIŠER, Darja (ur.). *Jezikovne tehnologije in digitalna humanistika: zbornik konference*, 2016. V Ljubljani: Znanstvena založba Filozofske fakultete. Str. 95-100 .

Specializirani vmesnik za korpus s popravki

- KOSEM, Iztok, Vít Baisa, Vojtěch Kovář and Adam Kilgarriff. [User-friendly interface of error/correction-annotated corpus for both teachers and researchers. Book of Abstracts LCR 2013](#), Norway, September 2013, pp. 82–84.

Raba korpusa za pripravo didaktičnih gradiv

- ARHAR HOLDT, Špela, DOBROVOLJC, Kaja, POPIČ, Damjan. [Reprezentacija standardnega in nestandardnega v virih SSJ](#). V: ŽELE, Andreja (ur.). Družbena funkcionalnost jezika : (vidiki, merila, opredelitev). Ljubljana: Znanstvena založba Filozofske

fakultete, 2013. Str. 19-27.

- ARHAR HOLDT, Špela, ROZMAN, Tadeja. Korpus Šolar: gradivni vir za raziskave pisne produkcije učencev. *Bilten Bravo*. dec. 2015, letn. 11, št. 23, str. 17-23.
- ARHAR HOLDT, Špela; KOSEM, Iztok; GANTAR, Polona. *Corpus-based resources for L1 teaching: The case of Slovene. Handbook on digital learning for K-12 schools*, 2017, 91-113.
- ARHAR HOLDT, Špela, POLLAK, Senja, ROBNIK ŠIKONJA, Marko, KREK, Simon. [Referenčni seznam pogostih splošnih besed za slovenščino](#). V: FIŠER, Darja (ur.), ERJAVEC, Tomaž (ur.). *Jezikovne tehnologije in digitalna humanistika: zbornik konference*, 2020. Str. 10-15.
- ARHAR HOLDT, Špela, KOSEM, Iztok, PORI, Eva. [Jezikovni viri CJVT in njihova raba v izobraževalne namene](#). V: ULČNIK, Natalija (ur.), ANTLOGA, Špela. *Slovenščina na dlani 4*. Maribor: Univerza v Mariboru, Univerzitetna založba, 2021. Str. 19-36.

Raba korpusa za pripravo pedagoškega jezikovnega opisa

- Arhar Holdt, Špela, Rozman, Tadeja, 2015: [Možnosti uporabe podatkov iz korpusa Šolar za pripravo slovarskih priročnikov](#). Smolej, Mojca (ur.): Obdobja 34: Slovnična in slovar, aktualni jezikovni opis. Ljubljana: Znanstvena založba Filozofske fakultete. 67–74.
- ROZMAN, Tadeja, ARHAR HOLDT, Špela, POLLAK, Senja, KOSEM, Iztok. [Kolokacije v korpusu Šolar](#). *Jezik in slovstvo*. 2018, letn. 63, št. 2/3, str. [117]-128.

Metodologija korpusne gradnje

- ARHAR HOLDT, Špela, KOSEM, Iztok, STRITAR KUČUK, Mojca. [Metode in orodja za lažjo pripravo korpusov usvajanja jezika](#). V: PIRIH SVETINA, Nataša (ur.), FERBEŽAR, Ina (ur.). *Na stičišču svetov : slovenščina kot drugi in tudi jezik*. 1. natis. Ljubljana: Založba Univerze, 2022a. Str. 23-30, Zbirka Obdobja, 41.
- ARHAR HOLDT, Špela, LAVRIČ, Polona, ROBLEK, Rebeka, GOLI, Teja, 2022b: [Kategorizacija učiteljskih popravkov: Smernice za označevanje korpusa Šolar](#). Različica 1.1. Rezultat projekta Razvoj slovenščine v digitalnem okolju.

Uporaba za strojno učenje in evalvacijo orodij za popravljanje

- Holozan, Peter (2013). [Uporaba strojnega učenja za postavljanje vejc v slovenščini](#). Uporabna informatika (Ljubljana), letnik 21, številka 4, str. 196-209.
- KRAJNC, Anja, ROBNIK ŠIKONJA, Marko. [Postavljanje vejc v slovenščini s pomočjo strojnega učenja in izboljšanega korpusa Šolar](#). V: FIŠER, Darja (ur.). *Zbornik konference Slovenščina na spletu in v novih medijih*, Ljubljana, 25.-27. november 2015. Ljubljana: Znanstvena založba Filozofske fakultete, 2015. Str. 38-43.
- ANDOVA, Andrejana. *Ugotavljanje berljivosti besedil z uporabo statističnih mer in strojnega učenja*. 2017. PhD Thesis. Univerza v Ljubljani.
- ŽAGAR, Aleš. *Readability Model Based on ccGigafida and Šolar Corpora*. In: *MEi: CogSci Conference 2018*. 2018., p. 103.
- BOŽIČ, Martin. [Globoke nevronске mreže za postavljanje vejc v slovenskem jeziku](#): diplomsko delo : univerzitetni študijski program prve stopnje Računalništvo in informatika. Ljubljana: [M. Božič], 2020.
- PETRIČ, Timotej. [Predlogi jezikovnih popravkov v slovenščini z modelom SloBERTa](#): diplomsko delo : univerzitetni študijski program prve stopnje Računalništvo in informatika. Ljubljana: [T. Petrič], 2022.
- MOKOTAR, Rok. [Obvladovanje slovičnih napak v šolskih pisnih izdelkih z metodami za obdelavo naravnega jezika](#) : diplomsko delo : univerzitetni študijski program prve stopnje Računalništvo in informatika. Ljubljana: [R. Mokotar], 2023.