

Špela Arhar Holdt in Jaka Čibej  
**1 KORPUSI IN KORPUSNO JEZIKOSLOVJE**  
**1.1 Korpusi in korpusno jezikoslovje – izročki**

JANES

IJS



# Korpusi in korpusno jezikoslovje

Špela Arhar Holdt

Center za uporabno jezikoslovje ZUS Trojina  
Filozofska fakulteta UL

Ljubljana, 4. 7. 2016

JANES

IJS



## Naloga za prvi dan

Spoznati pojme in orodja, ki jih bomo uporabljali ta teden.

- Kaj je korpus?
- Vzorec in generalizacija
- Gradnja korpusov
- Raba korpusov
- Korpus in priročniki
- Slovenski korporusi

**JANES**

**Želimo raziskovati slovenščino!**

časopisi, revije  
pošta, e-pošta

knjige

besedilni drobiž

spletne strani

družbena omrežja

govorjeni jezik

**JANES**

**Kako?**

Gigafida Iskanje Oklica Seznam

čofotainik

Najdi

Uporabljai enostavno iskanje Napredno iskanje

1 2 3 4 naslednja stran ▶

Prikazujem 1-20 od 80 konkordanc (0.343 sekund).

Osnovne oblike > čofotainik (80)

Vrsta besedila > Casopisi (63)  
> Revije (12)  
> Internet (4)  
> Slovenske besedile (1)

Vir > Dnevnik (28)  
> Družba (22)  
> DELO (11)  
> Večer (6)  
> Gorenjski glas (5)  
> Več

Leto > 2003 (16)  
> 2004 (15)  
> 2001 (11)

JANES

IJS



## Besedilni korpus



Zberemo veliko količino besedil v elektronski obliki.

Besedila izberemo tako, da predstavljajo vzorec jezika.

Besedila pripravimo, da jih je lažje računalniško raziskovati.

Besedila vstavimo v specializiran program: konkordančnik.

JANES

IJS



## Besedilni korpus



Zberemo veliko količino besedil v elektronski obliki.

Besedila izberemo tako, da predstavljajo **vzorec jezika**.

Besedila pripravimo, da jih je lažje računalniško raziskovati.


Besedila vstavimo v specializiran program: konkordančnik.



## Vzorec - primer

Recimo, da nas zanima, kakšno glasbo poslušajo slovenski srednješolci.  
Kako bomo to ugotovili?

Je dovolj, če ocenimo stanje glede na svoje izkušnje? Vprašamo svoje sošolce? Ali vse dijake na svoji šoli? Dijake z različnih srednjih šol? Morda različnih starosti, spolov ali iz različnih regij?




Kakšen **vzorec** moramo zajeti v raziskavi, da lahko na koncu **generaliziramo** rezultate?



## Vzorec - primer

Recimo, da nas zanima, kakšno glasbo poslušajo slovenski srednješolci.  
Kako bomo to ugotovili?

Je dovolj, če ocenimo stanje glede na svoje izkušnje? Vprašamo svoje sošolce? Ali vse dijake na svoji šoli? Dijake z različnih srednjih šol? Morda različnih starosti, spolov ali iz različnih regij?



Kakšen **vzorec** moramo zajeti v raziskavi, da lahko na koncu **generaliziramo** rezultate?

## JANES



### Vzorec - korpus

Besedilni korpsi so zgrajeni tako, da predstavljajo **vzorec jezika**.

Da lahko pravilno **interpretiramo** in **generaliziramo** ugotovitve, moramo dobro razumeti, kakšna besedila določen korpus vsebuje, kako je bil zgrajen in kakšen je njegov namen.

Korpus Kres	Slovenska pisna slovenščina	časopisi, revije, leposlovje, strokovna literatura, spletna besedila, besedilni drobiž
Korpus GOS	Govorjena slovenščina	televizijske in radijske oddaje, javni nastopi, sestanki, zasebna komunikacija
Korpus Janes	Spletna slovenščina	tviti, blogi, uporabniški komentarji, forumi
Korpus Šolar	Jezik šolarjev	šolski eseji in testi + učiteljski popravki

## JANES



### Besedilni korpus



Zberemo veliko količino besedil v elektronski obliki.

Besedila izberemo tako, da predstavljajo vzorec jezika.

Besedila pripravimo, da jih je lažje računalniško raziskovati.

Besedila vstavimo v specializiran program: konkordančnik.

## JANES



### Besedilni korpus



Zberemo veliko količino besedil v elektronski obliki.

Besedila izberemo tako, da predstavljajo vzorec jezika.

Besedila **pripravimo**, da jih je lažje računalniško raziskovati.  
Besedila vstavimo v specializiran program: konkordančnik.

## JANES



### Priprava korpusnih besedil

1. K besedilom dodamo vse informacije, ki so na voljo: od kod besedilo izvira, kdaj je nastalo oz. izšlo, kdo je avtor ...
2. Besedila **jezikoslovno označimo**: s posebnim programom pripšemo besedi osnovno obliko, besedno vrsto in druge lastnosti. !

*Vaši malčki lahko varno uživajo v otroškem čofotalniku.* (časopis Celjan, 2009)

Vaši	vaš	svojilni zaimek; 2. oseba, moški spol, množina, imenovalnik, množina svojine
malčki	malček	samostalnik, občno ime; moški spol, množina, imenovalnik
lahko	lahko	splošni prislov; nedoločena stopnja
varno	varno	splošni prislov; nedoločena stopnja
uživajo	uživati	glavni glagol; nedovršni, sedanjik, 3. oseba, množina
v	v	predlog; mestnik
otroškem	otroški	splošni pridevnik; nedoločena stopnja, moški spol, ednina, mestnik
čofotalniku	čofotalnik	samostalnik, občno ime; moški spol, ednina, mestnik

JANES

IJS



## Besedilni korpus



Zberemo veliko količino besedil v elektronski obliki.

Besedila izberemo tako, da predstavljajo vzorec jezika.

Besedila pripravimo, da jih je lažje računalniško raziskovati.

Besedila vstavimo v specializiran program: konkordančnik.

JANES

IJS



## Besedilni korpus



Zberemo veliko količino besedil v elektronski obliki.

Besedila izberemo tako, da predstavljajo vzorec jezika.

Besedila pripravimo, da jih je lažje računalniško raziskovati.

Besedila vstavimo v specializiran program: **konkordančnik**.

**JAMES** 

Gigafida | Iskanje ▾ | Okolica | Seznam | [Najdi](#) | [Uporabljajšč enostavno iskanje](#) | [Napredno iskanje](#)

1 2 3 4 | naslednja stran ▾ | Prikazujem 1-20 od 80 konkordanc (0.343 sekund).  

**Osnovne oblike**  
» [čofotalnik](#) (80)

**Vrsta besedila**  
» [Casopisi](#) (63)  
» [Revije](#) (12)  
» [Internet](#) (4)  
» [Stvarna besedila](#) (1)  
» [Več](#)

**Vir**  
» [Dnevnik](#) (28)  
» [drugo](#) (22)  
» [Delo](#) (11)  
» [Večer](#) (6)  
» [Gorenjski glas](#) (5)  
» [Več](#)

**Leto**  
» [2003](#) (16)  
» [2004](#) (15)  
» [2001](#) (11)

sta bila od skupno 34 vzorcev dva mikrobiološko neustreznaliz bazena [čofotalnik](#) na kopališču RC Cizej, Orla vas pri Braslovčah.  
. To bo kompleks zunanjih bazenov, ki bo v [čofotalniku](#) ponujal vodno veselje najmajšim, na grčah in toboganih pa  
se lahko zabavajo tudi v zunanjem gusarskem bazenu in notranjem [čofotalniku](#).  
se lahko zabavajo tudi v zunanjem gusarskem bazenu in notranjem [čofotalniku](#).  
dodatno razveseliuje obnovljen bazen s številnimi vodnimi doživetji, otroški [čofotalnik](#) in masažni bazen whirlpool. Celovita ponudba Dežele dobrega počutja  
park z dvema drčama, toboganom in otroškim bazenom - [čofotalnikom](#). Za krepitev zdravja vabi Sawaddee, center tradicionalne tajske  
. posebne kopelei, za najmlajše pa je tu otroški [čofotalnik](#). Gozdni vodni park ponuja водне in biserne vrelce,  
ki se bodo lahko namakali v dveh bazenih ter otroškem [čofotalniku](#), se sprostili v velikem savna centru in telovadili v  
park z dvema drčama, toboganom in otroškim bazenom - [čofotalnikom](#). Za krepitev zdravja bodo poskrbelli v centru tradicionalne tajske  
za dezinfekcijo vode. Kopališču manjkata tudi koncenzacijski bazen in [čofotalnik](#) za dojenče ter manjše otroke, ki zdaj pogosto čofotajo  
tiste, ki želijo toplojšo vodo. Predlagat bi » [čofotalnik](#) «.

v treh bazenih: zunanjem, v velikem bazenu in [čofotalniku](#). V tamkajšnjem vročem bazenu oziroma savni pa je neustrezen  
o., Zimsko kopališče v velikem in malem bazenu ter [čofotalniku](#). V Zdravilišču Laško sta imela kemično neustrezeno vodo zunanjji  
. Gre za kompleks zunanjih bazenov, ki bo v [čofotalniku](#) ponujal vodno veselje najmajšim obiskovalcem, na grčah in toboganih

**JAMES** 

**Besedilni korpus - definicija**

Besedilni korpusi so **obsežne zbirke realnih besedil** v elektronski obliki. Besedila so zajeta iz različnih virov na način, da predstavljajo **vzorec jezikovne rabe določene vrste**. Korpusna besedila tipično vsebujejo programsko ali ročno pripisane **oznake**, npr. osnovno obliko besede, besedno vrsto in druge lastnosti besede. Za raziskovanje besedilnih korpusov so besedila umeščena v **konkordančnike** specializirane programe, ki omogočajo napredno iskanje po besedilih, razvrščanje, filtriranje, izvažanje podatkov in podobno.



## Zakaj uporabljati korpulse?

- Ker naša **jezikovna intuicija** ne more natančno predvideti, kako se jezik v širši rabi obnaša (kot ne moremo na pamet predvideti, kakšno glasbo imajo radi slovenski srednješolci).
- Ker s pomočjo računalnika lahko obdelamo večje količine podatkov na naprednejše načine in tako lažje poiščemo relevantne **jezikovne vzorce in trende** (to je posebej pomembno za večje projekte, npr. gradnjo slovarja),
- Ker so (v primerjavi z Googлом, na primer) zgrajeni na transparenten in dokumentiran način, da lahko podatke ustrezno **interpretiramo** in **generaliziramo**.



## Raba besedilnih korpusov

### Uporabno jezikoslovje

- slovarji, slovnice, pravopis, šolska gradiva ...

### Teoretično jezikoslovje

- nova dognanja o jezikovni rabi in sistemu

### Jezikovna produkcija


- pisanje, prevajanje, lektoriranje ...

### Ljubiteljsko raziskovanje

- preverjanje jezikovne rabe, zanimivosti ...



## Od korpusa do priročnika



korpuse  
uporabimo kot  
vir jezikovnih  
podatkov



uporabniki  
lahko preberejo  
opis jezika v  
priročnikih

Za slovenščino še ne obstaja veliko priročnikov, ki so narejeni na osnovi korpusnih podatkov (v prihodnosti jih bo več). Trenutno je zato najti razlike med korpusnimi podatki in podatki nekaterih priročnikov.



## Korpsi in jezikovni priročniki



KORPUSI

- Vidimo sobesedilo in podatke o besedilu
- Potrebna je sinteza in interpretacija
- Možnost hitrega posodabljanja
- Razen pripisanih oznak so besedila v izvorni obliki



PRIROČNIKI


- Vsak priročnik služi določenemu namenu.
- Jezikovno gradivo je izbrano in urejeno glede na ta namen.
- Priročniki imajo pogosto (tudi) normativno vrednost.

## JANES (•)

IJS



### Slovenski korpsi (izbor)



## JANES (•)

IJS



### Gigafida in Kres


- **Gigafida** je obsežna zbirka sodobnih (1990-2011) slovenskih besedil iz časopisov, revij, knjig, s spleta itd. Korpus obsega skoraj 1,2 milijarde besed.
- **Kres** je manjša različica tega korpusa, prinaša cca. 100 milijonov besed.
- Korpuse, ki prinašajo splošni, nespecializirani jezik, imenujemo **referenčni korpsi**. Ti se uporabljajo za izdelavo referenčnih priročnikov, v raziskavah pa jih pogosto uporabljamo tako, da z njimi primerjamo rezultate iz drugih korpusov (npr. rezultate raziskovanja po korpusu Janes primerjamo z referenčnim korpusom, da vidimo, kaj je specifično za spletni jezik, kaj pa se pojavlja tudi v splošni jezikovni rabi).

## JANES

## IJS



### Gigafida in Kres



## JANES

## IJS



### GOS

- GOS je prvi korpus govorjene slovenščine. Prinaša posnetke govora v različnih vsakodnevnih situacijah.
- Posnetki so transkribirani in umeščeni v zmogljiv konkordančnik, s katerim lahko primere govora iščemo, poslušamo in preučujemo.
- Korpus obsega okrog milijon besed.
- Namenjen je raziskovanju govora.

Transkribcija 1: *ja ne vem po kermu kluču se bomo odločali eee koga bomo poslali v samo trgovanje z volno eem ne vem a bo to žrebanje al al glasvanje al kekrkoli*

Transkribcija 2: *ja ne vem po kateremu ključu se bomo odločali eee koga bomo poslali v samo trgovanje z volno eem ne vem a bo to žrebanje ali ali glasovanje ali kakor*

## JANES



### Šolar


- Šolar vsebuje pisna besedila, ki so jih učenci in dijaki slovenskih šol tvorili pri pouku.
- V precejšnjem delu besedil so posebej označene tudi jezikovne napake, ki so jih v spisih **popravili učitelji**.
- Po jezikovnih napakah oz. učiteljskih popravkih lahko s pomočjo specializiranega konkordančnika tudi iščemo.
- Korpus vsebuje približno **milijon besed**.
- Korpus je primarno namenjen raziskavam šolske pisne produkcije oz. jezikovne zmožnosti šolarjev in pripravi učnih gradiv.

## JANES



### Janes

- Janes je korpus spletnje slovenščine. Vsebuje besedila, ki so jih na spletu tvorili uporabniki. Korpus obsega okrog **134 milijonov besed**.



**JANES** 

 IJS   
FILOZOFSKA  
FAKULTETA

## Janes

**Janes je tudi razlog, da smo tu:**

- JANES – Jezikoslovna analiza nestandardne slovenščine je nacionalni raziskovalni projekt (J6–6842), ki ga od 1. 7. 2014 do 30. 6. 2017 financira Javna agencija za raziskovalno dejavnost Republike Slovenije.
- Cilj projekta je zgraditi obsežen korpus spletne slovenščine, s pomočjo katerega bomo omogočili empirično podprtjo jezikoslovno analizo nestandardne spletne slovenščine, izboljšali jezikovnotehnološka orodja za obdelavo besedil, napisanih v nestandardnem jeziku, in izdelali slovarček spletne slovenščine.