Delavnica 1:
Raziskovanje spletne slovenščine

Darja Fišer
Oddelek za prevajalstvo, Filozofska fakulteta Univerze v Ljubljani
Odsek za tehnologije znanja, Inštitut Jožef Stefan

Ljubljana, 4. julij 2016

Korpus JANES

ISKANJE PO KORPUSU

Dostop do korpusa

- konkordančnik
  - https://sketch.cjvt.si/bonito/janes04.cgi/first_form
  - uporabniško ime **janes**, geslo **9neztandart6**
- navodila za uporabo

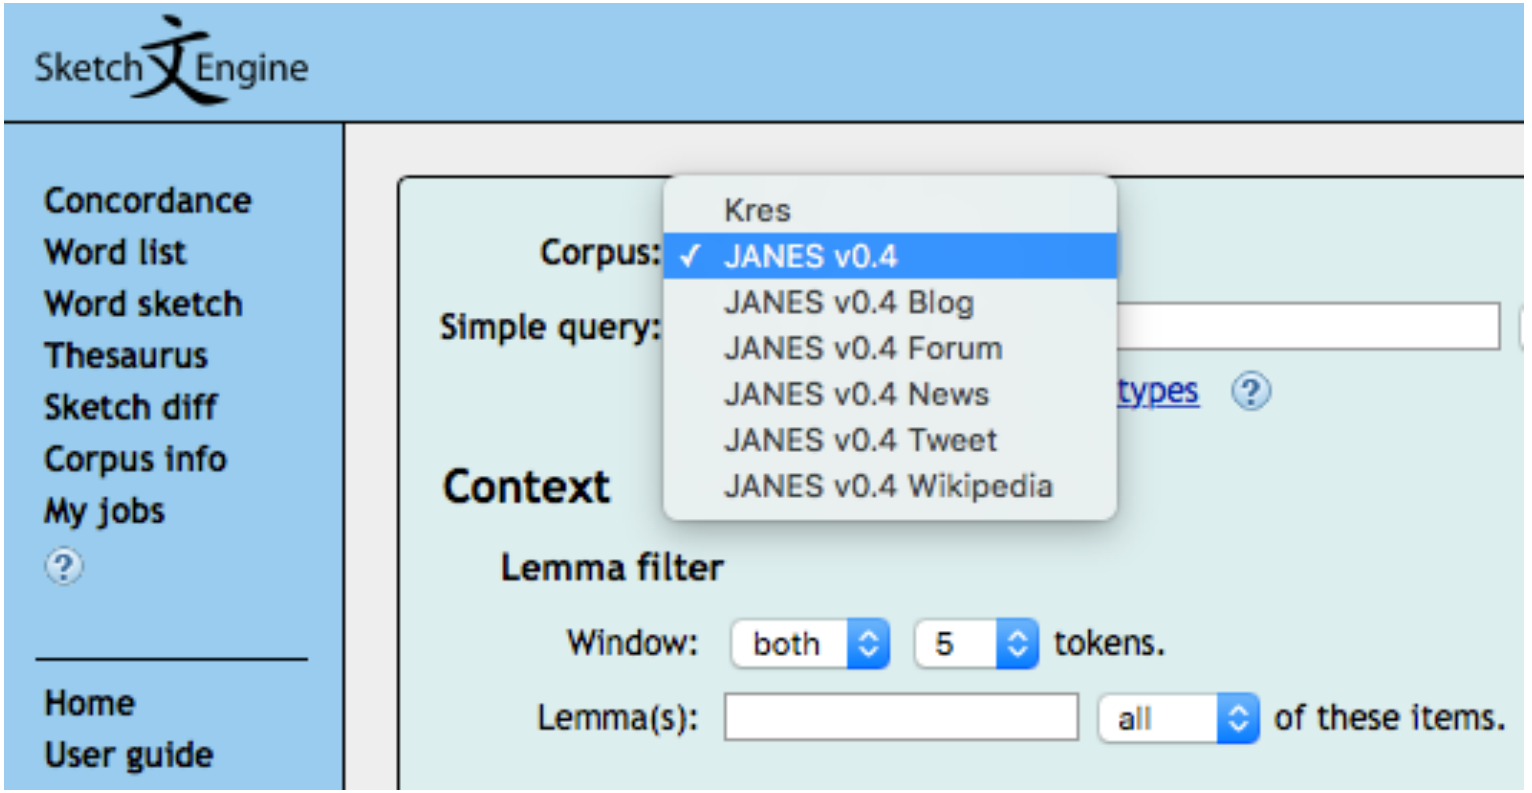

SketchEngine: načini iskanja

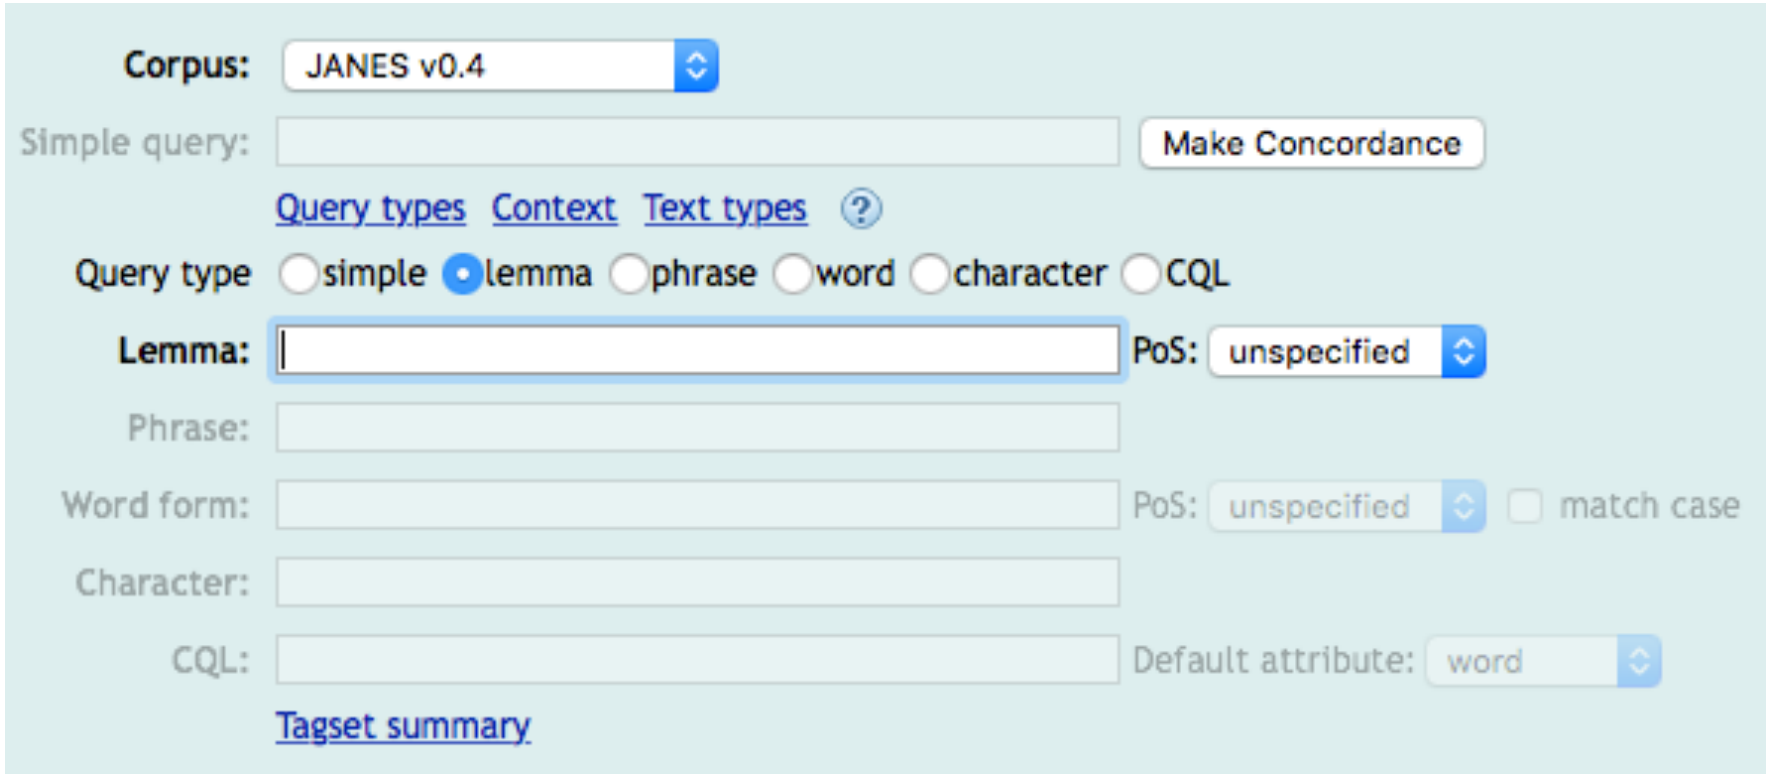

SketchEngine: filtriranje po metapodatkih

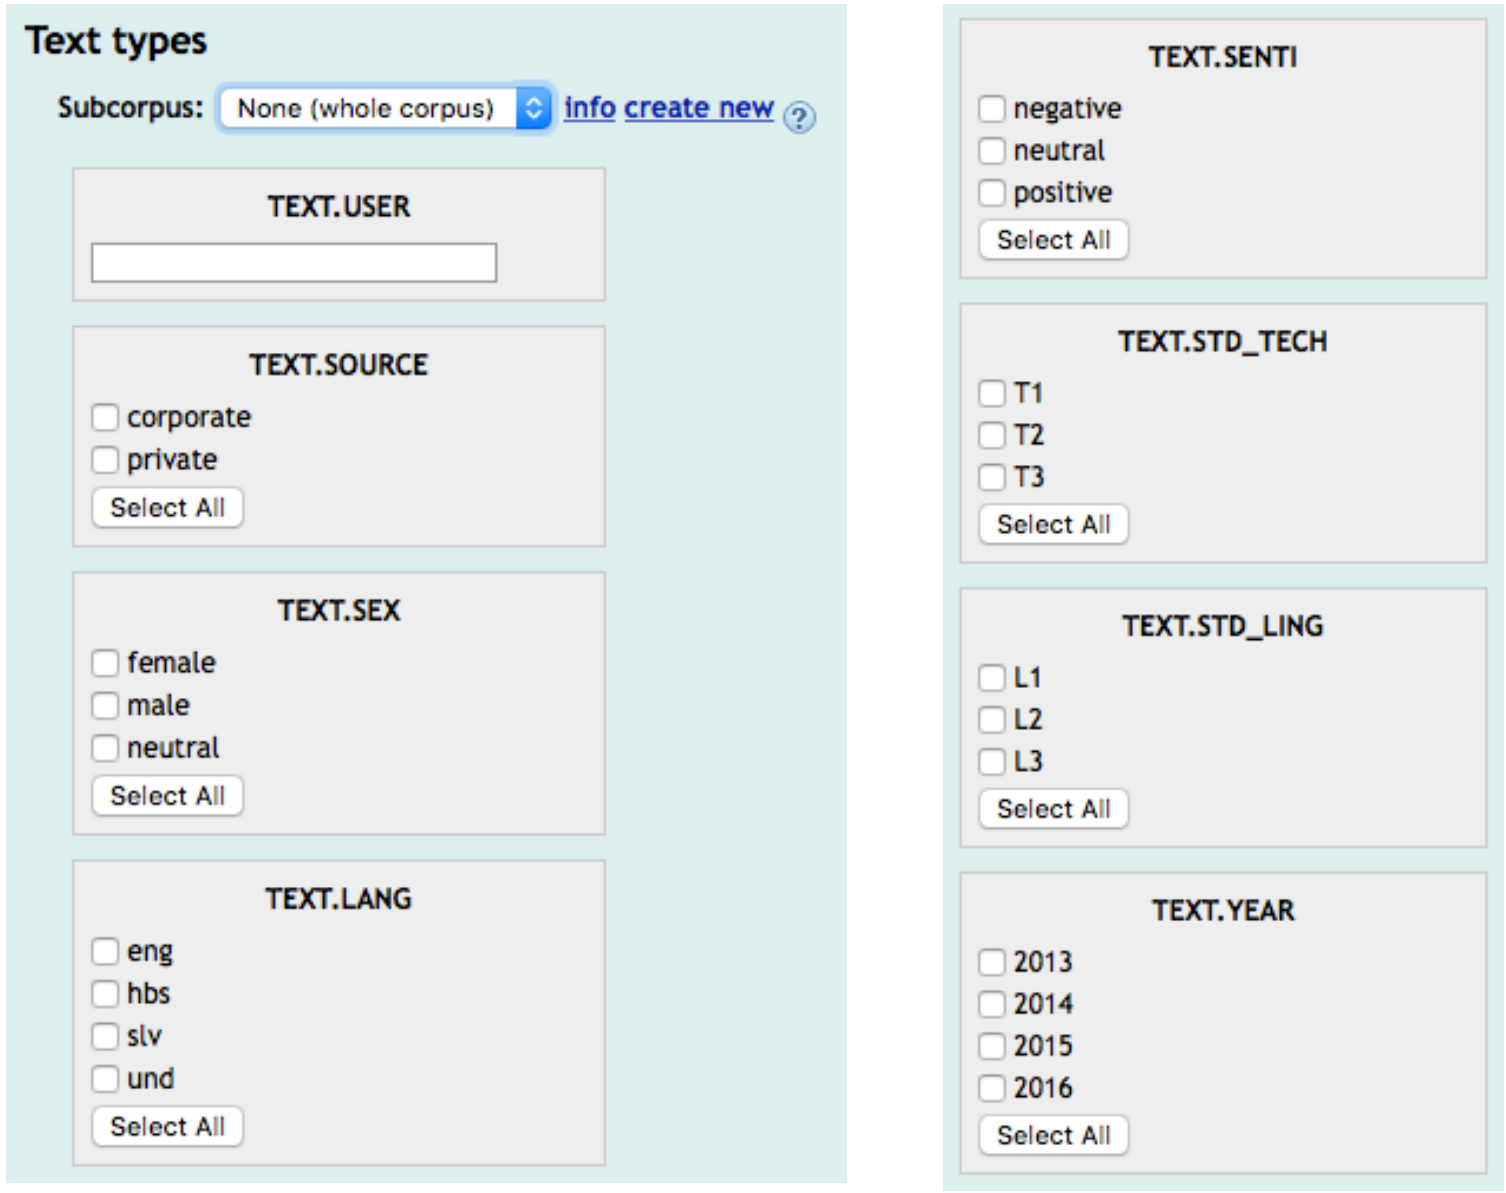

SketchEngine: konkordance

Iskalni niz **boljše** **27,257** > Premešaj **27,257** (169.0 na milijon)

Prva | Prejšnja Stran 2 od 1,363 Pojdi Naslednja | Zadnja

blog	distancirali tudi terminološko, če se jih ima večina itak za	boljše	/boljše/dober/Agcmpa	od novinarjev in njih cenzorskih, politično nastavljenih
tweet	nič spornega http://t.co/hsLiD7A6Dv ##ɠ @BozoPredalic	Boljše	/boljše/dobro/Rgc	za marsikoga, da je ne. Lahko katero prime, da ga
blog	tangu. Sicer je super, sedaj me zanima, če je lahko še	boljše	/boljše/dober/Agcfpn	. Grrrr ɠ heh, skrajni čas, bejbi.jst to že nekej časa
tweet	Affleck bo naslednji Batman. Buuu ##ɠ A ne bi bilo ful	boljše	/boljše/dober/Agcnsn	, če bi tvite z deli, zaposlitvami opremili z enim
forum	rdečic po telesu, včasih tudi po obrazu. Sedaj so vse	boljše	/boljše/dober/Agcfpn	, niso več rdeče le srbi jo še večkrat (včasih se
tweet	@maticslapsak Vsakemu svoje veselje. Kaj č'mo. Vseeno	boljše	/boljše/dobro/Rgc	kot nazi ikonografija. #alwayslookonthebrightsideoflife
tweet	slovenske oblasti in sodišča ji stojijo na poti v	boljše	/boljše/dober/Agcnsa	življenje http://t.co/6LE4s7GEzb ##ɠ Vsaka tretja ženska
forum	malo neprijetno. Savine so sicer v snegu bile veliko	boljše	/boljše/dober/Agcfpn	, na mokri in mastni podlagi pa prava katastrofa v
blog	13.09.2012 ob 16:57 ɠ ne vem, meni se zdi, da bi veliko	boljše	/boljše/dobro/Rgc	(in bolj seksi) izpadlo, če bi imela zgornji del
forum	kaksne narezane diske (npr. ATE, brembo...) in pa	boljse	/boljše/dober/Agcmpa	zavorne ploscice. ##ɠ Pri nekaterih avtih je res potrebno
tweet	koga ##ɠ @Razdelilec tista Gradišnikova je huda, ja.	boljš	/boljše/dobro/Rgc	da nima prav ##ɠ hm, a ni Al Gore 07 pokasiral Nobelove
blog	dalje), ker morda v takem moodu kaj lepega zamujaš ... ɠ	boljše	/boljše/dobro/Rgc	da neham besedičit ..... lačna sem pa se hočem zamotit
forum	cevi, če bi bilo morda res kej v dovodu nafte, pa nič	bolš	/boljše/dobro/Rgc	ɠ - ni 4motion ɠ - kompresija bi avto skos zajebavala
tweet	##ɠ @TamaraSvetina Sem zelo iz vaje, a če ne najdeš	boljše	/boljše/dober/Agcmpa	(ga) se lahko potrudim. @ales_gantar ##ɠ @_Inja _ Kaj
forum	Tudi meni ni všeč Astra enjoy, sport mi pa je. Mnogo	boljše	/boljše/dober/Agcmpa	sedeže ima, pa el. ročno in tudi ni veliko dražji
tweet	pol sm si pa kupu fruštk in sm še zmer u minusu...	Boljš	/boljše/dobro/Rgc	da bi šou u ošterijo: D http://t.co/SHzwwSnpKF ##ɠ
comment	koncano najmani srednje sole. Prekmurski Romi imajo	boljse		razmere, vecina romskih naselij ima elektriko, vodo
forum	njegovih			
tweet	za st			
forum	original			

Prva | Prejšnja Stra

text.type forum
text.author Goggy
text.title VW Passat BKP trese - NUJNO POMOČ
text.date 2011-03-15
text.url http://www.avtomobilizem.com/forum/viewtopic.php?f=6&t=84268&start=20#p1423667
text.id janes.forum.avtomobilizem.6.84268.1423667

SketchEngine: obdelava konkordanc

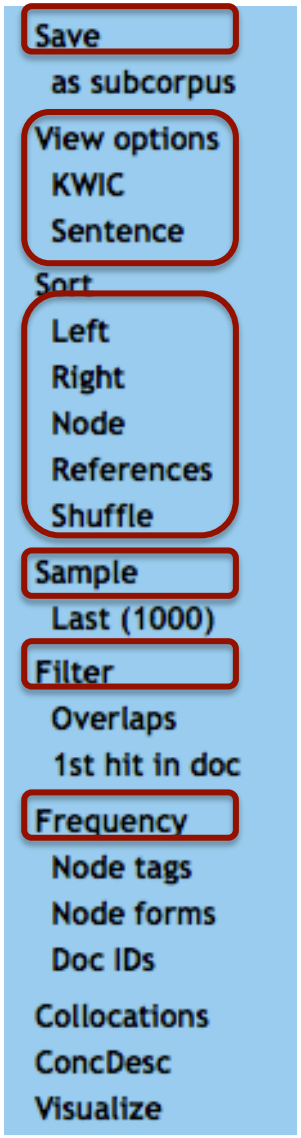

SketchEngine: izdelava frekvenčnih seznamov

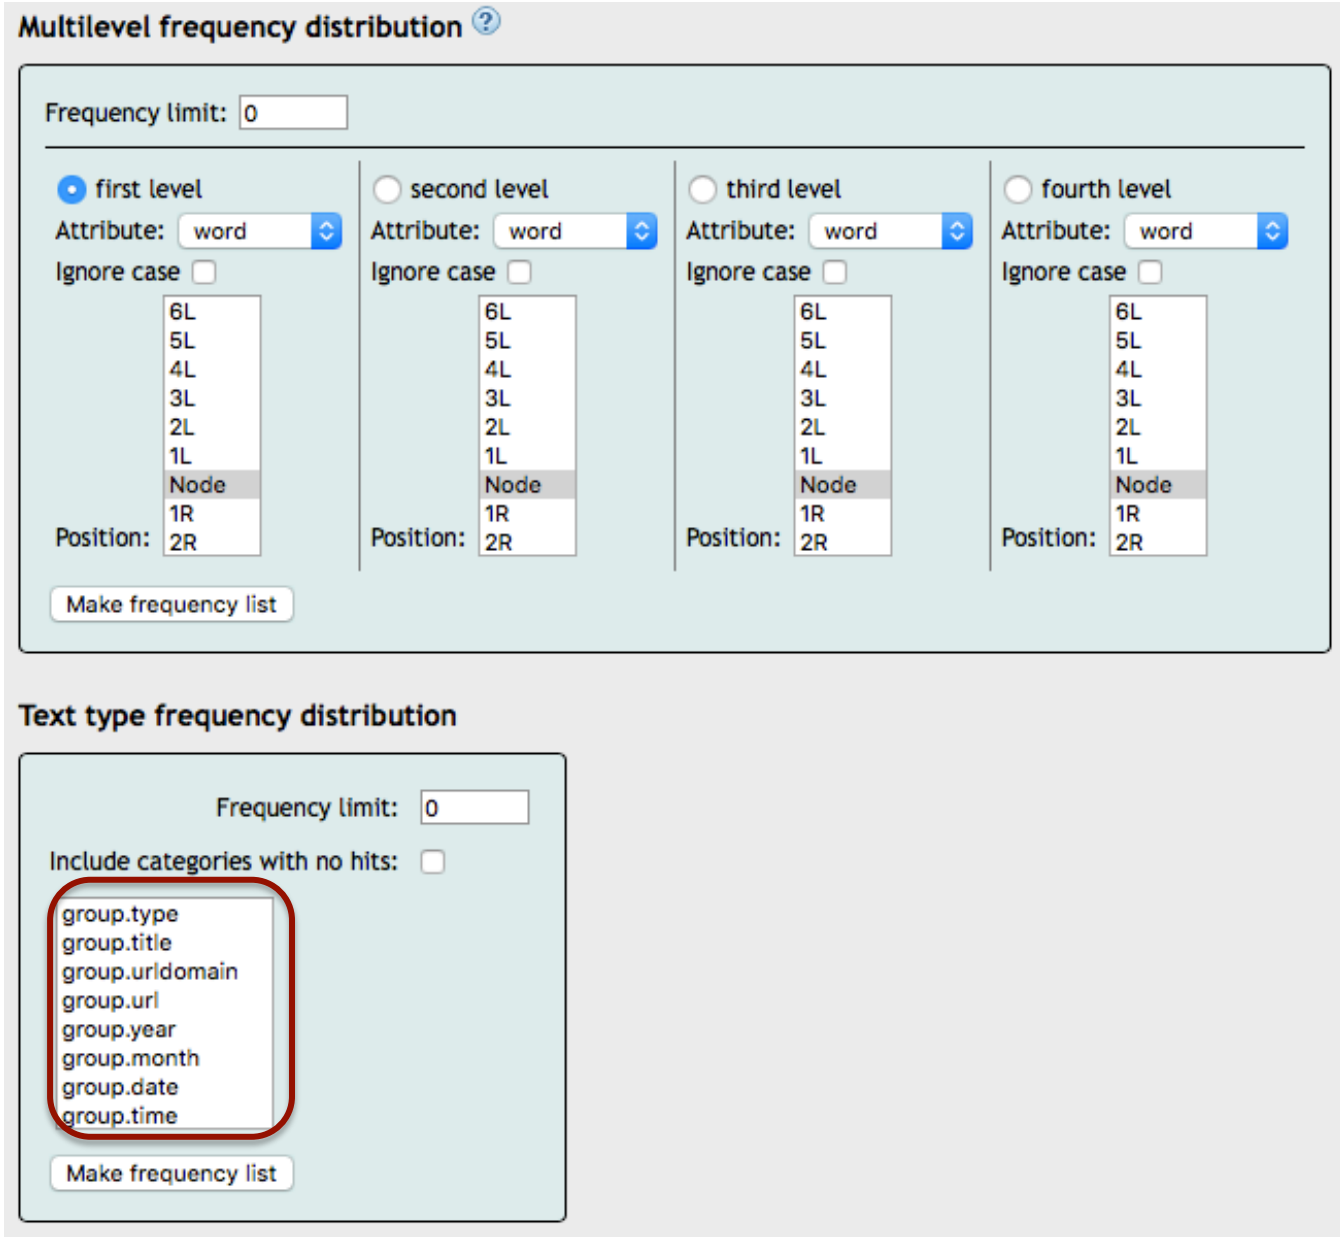

SketchEngine: izdelava frekvenčnih seznamov

	word	Frequency
P | N	mi	28,577
P | N	nas	20,637
P | N	nam	13,254
P | N	me	12,546
P | N	jaz	10,255
P | N	Jaz	6,089
P | N	mene	2,810
P | N	Mi	2,597
P | N	meni	2,396
P | N	Meni	1,894
P | N	Me	1,506
P | N	nami	1,313
P | N	Mene	1,110
P | N	jst	634
P | N	JS	524
P | N	mano	485
P | N	nama	341
P | N	MI	330
P | N	js	303
P | N	naju	270
P | N	Nam	219
P | N	Jst	209
P | N	menoj	202
P | N	midva	183
P | N	Nas	172
P | N	Js	126

	tag	Frequency
P | N	Zop-ed--k	26,758
P | N	Zop-ei	18,216
P | N	Zop-md	13,551
P | N	Zop-et--k	13,053
P | N	Zop-mt	11,685
P | N	Zop-mm	7,341
P | N	Zopmmi	4,773
P | N	Zop-ed	3,799
P | N	Zop-er	2,446
P | N	Zop-mr	1,824
P | N	Zop-et	1,535
P | N	Zop-mo	1,323

	group.type	Frequency	Rel [%]
P | N	news.rtvslo	86,647	277,660.70
P | N	news.mladina	20,788	115,597.10
P | N	news.reporter	2,367	42,154.00

	text.std_ling	Frequency	Rel [%]
P | N	L2	56,163	104.40
P | N	L1	48,581	92.10
P | N	L3	5,058	154.40

	text.senti	Frequency	Rel [%]
P | N	negative	80,128	106.00
P | N	neutral	15,784	73.50
P | N	positive	13,890	109.30

SketchEngine: besedni seznami

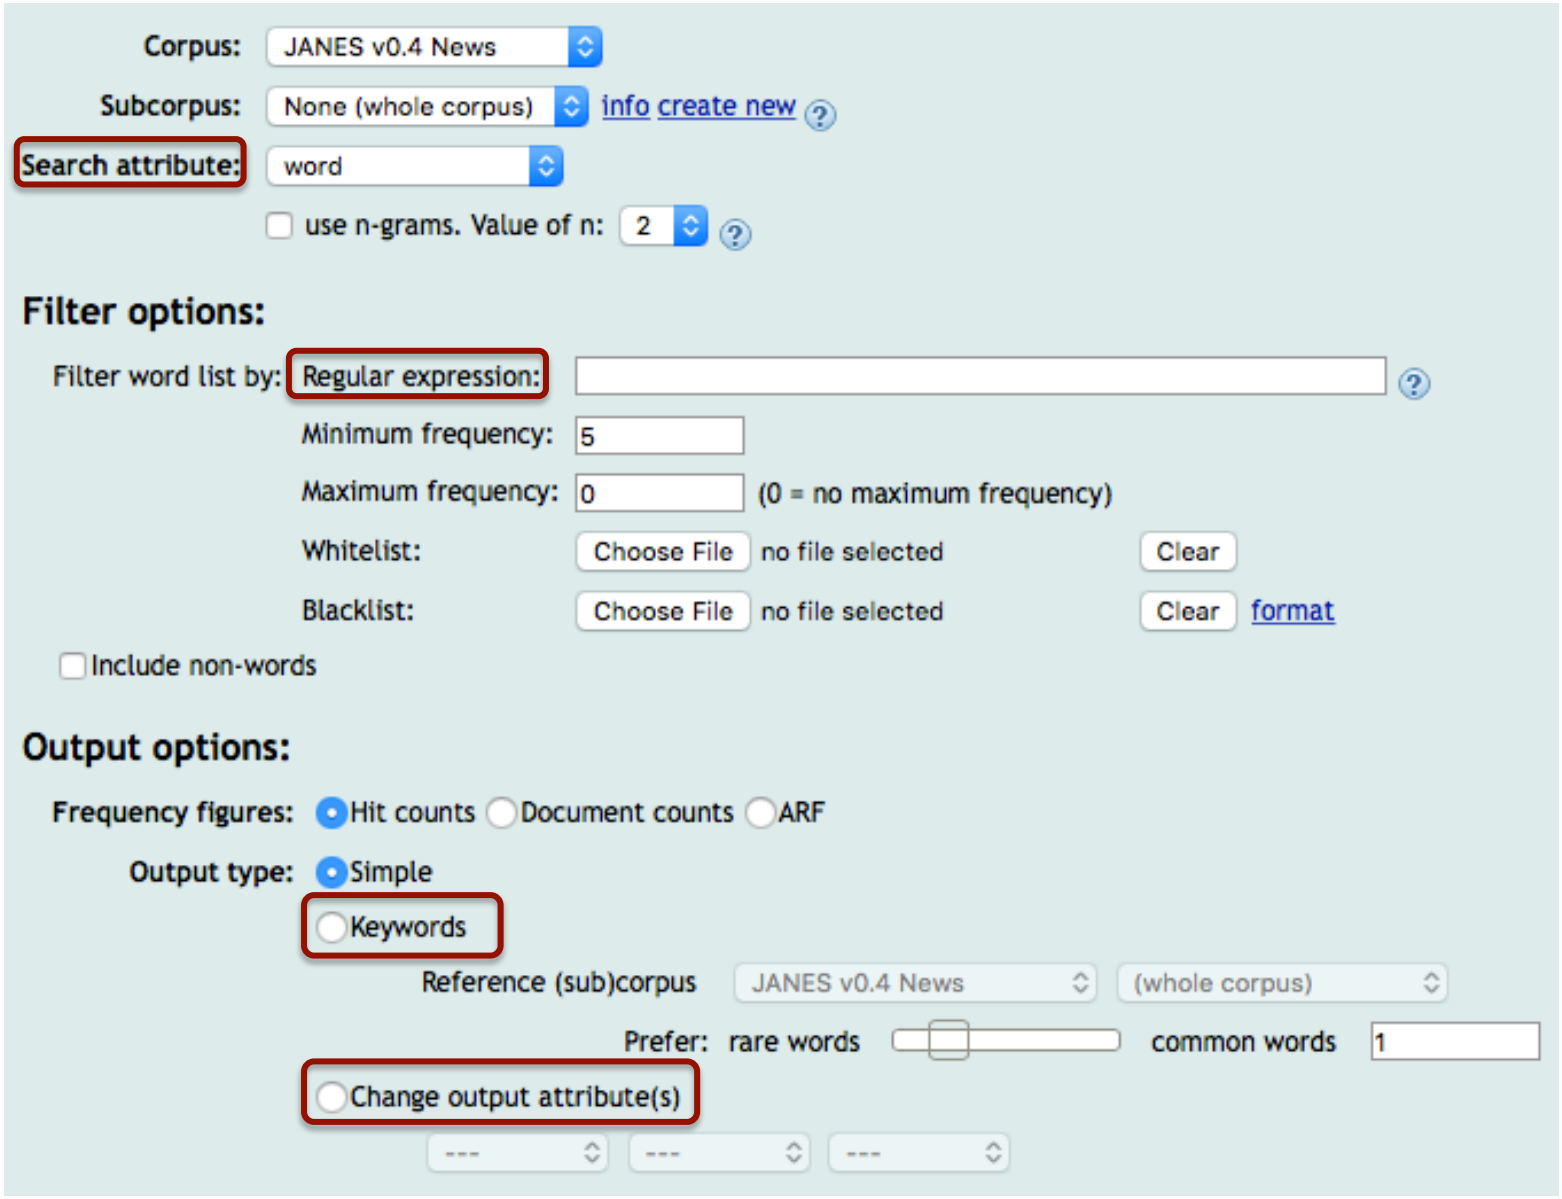

SketchEngine: besedni seznami

	word	lc	lemma	Frekvenca
p | N	jaz	jaz	jaz	10,255
p | N	Jaz	jaz	jaz	6,089
p | N	jst	jaz	jaz	634
p | N	js	jaz	jaz	303
p | N	JAZ	jaz	jaz	70
p | N	jes	jaz	jaz	33
p | N	jast	jaz	jaz	24
p | N	JAz	jaz	jaz	7
p | N	jales	jaz	jaz	5

SketchEngine: ključne besede

word	JANES v0.4 News Freq	JANES v0.4 News Freq/mill	JANES v0.4 Freq	JANES v0.4 Freq/mill	Score
MIRNČAN	618	28.8	625	2.9	7.6
K_ris	587	27.4	587	2.7	7.6
law1	523	24.4	523	2.4	7.4
zapatist	495	23.1	497	2.3	7.3
Dandet	462	21.5	467	2.2	7.1
Jethros	440	20.5	447	2.1	7.0
ČAN	419	19.5	421	2.0	6.9
vojnaslo91	426	19.9	432	2.0	6.9
Binder	445	20.8	460	2.1	6.9
Ramus	353	16.5	358	1.7	6.5
Tunek	320	14.9	330	1.5	6.3
šurda	299	13.9	303	1.4	6.2
Forex	328	15.3	371	1.7	6.0
IJJ	506	23.6	671	3.1	6.0
Mirnčan	263	12.3	268	1.2	5.9
Cmokc	237	11.1	237	1.1	5.7
oliva	292	13.6	335	1.6	5.7
rimos	228	10.6	228	1.1	5.6
olimpija	458	21.4	637	3.0	5.6
silvester	246	11.5	273	1.3	5.5
minuse	491	22.9	726	3.4	5.5
binbon	210	9.8	211	1.0	5.4
lojzek	232	10.8	257	1.2	5.4
gesan	198	9.2	198	0.9	5.3
SDS-a	712	33.2	1,204	5.6	5.2
martinove	189	8.8	197	0.9	5.1
čan	220	10.3	262	1.2	5.1
ti-ne	172	8.0	174	0.8	5.0
generusus	168	7.8	168	0.8	5.0

word	JANES v0.4 News Freq	JANES v0.4 News Freq/mill	Kres Freq	Kres Freq/mill	Score
Bratušek	1,615	75.3	15	0.1	67.9
KPK	1,334	62.2	35	0.3	49.0
Bratuškova	1,024	47.8	0	0.0	48.8
SMC	1,188	55.4	32	0.3	44.6
Cerarja	1,103	51.4	29	0.2	42.3
JJ	4,831	225.3	569	4.7	39.5
Prijavi	1,320	61.6	79	0.7	37.8
MIRNČAN	618	28.8	0	0.0	29.8
ZL	1,048	48.9	89	0.7	28.7
K_ris	587	27.4	0	0.0	28.4
Cerar	3,206	149.5	561	4.7	26.6
DUTB	528	24.6	0	0.0	25.6
law1	523	24.4	0	0.0	25.4
zapatist	495	23.1	0	0.0	24.1
Juncker	580	27.0	20	0.2	24.1
IJJ	506	23.6	7	0.1	23.2
Dandet	462	21.5	1	0.0	22.4
Janši	2,280	106.3	458	3.8	22.3
sds	683	31.9	59	0.5	22.1
Jethros	440	20.5	0	0.0	21.5
Ukrajini	1,583	73.8	299	2.5	21.5
vojnaslo91	426	19.9	0	0.0	20.9
ČAN	419	19.5	1	0.0	20.4
Janše	3,033	141.4	735	6.1	20.1
Janšo	2,990	139.4	730	6.1	19.9
Patria	1,346	62.8	280	2.3	19.2
Bravo	3,963	184.8	1,051	8.7	19.1
rusi	576	26.9	58	0.5	18.8
Zoki	815	38.0	131	1.1	18.7
Bratuškove	377	17.6	0	0.0	18.6
Bratuškovo	376	17.5	0	0.0	18.5
levica	1,545	72.1	356	3.0	18.5
Ukrajino	855	39.9	147	1.2	18.4

Korpus JANES

DELAVNICA

Potek delavnice

- 5 skupin
- vsaka skupina si izbere eno temo
- nalogo skupaj s 5-minutno predstavitvijo je treba pripraviti v 60 minutah
- v zadnjih 30 minutah bo predstavitev dela vsake skupine
- struktura predstavitve:
  1. Ozadnje in motivacija
  2. Zasnova raziskave
  3. Rezultati
  4. Interpretacija in diskusija
  5. Sklepi

Raziskovalna vprašanja

- Tema 1:
  - stopnja variantnosti na ortografski ravni med skupinami uporabnikov / pri posameznih uporabnikih
- Tema 2:
  - primerjava rabe izbranih slovničnih besednih vrst v spletni in govorjeni slovenščini
- Tema 3:
  - analiza sentimentnih korpusov
- Tema 4:
  - jezik komentarjev na ženske / moške politike na različnih portalih
- Tema 5:
  - mešanje jezikov / preklapljanje med jeziki

http://nl.ijs.si/janes/

tenks ☺