

Hrvatski mrežni subčestični (struktturni) rječnik

Josip Užarević, Suzana Molčanov, Antonio Jovanović
juzarevic@ffzg.hr; suzana.molcanov@gmail.com;
ajovanov@mathos.hr

CLGF-2020

Osijek, 25.-26. rujna 2020.

Sadržaj:

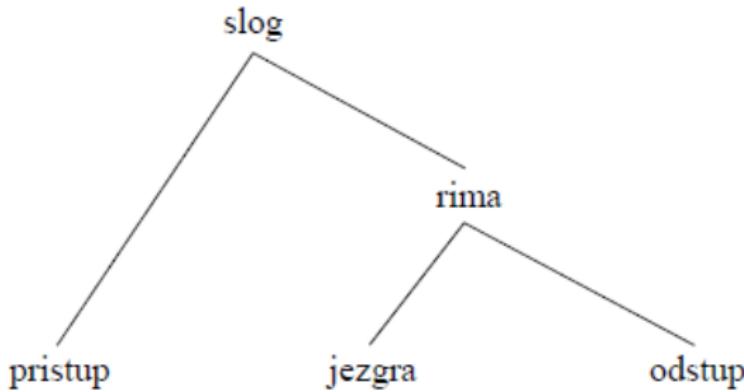
1 Nutarnja struktura riječi (Mario Essert)

- Subčestice riječi
- Slogotvorna pravila
- On-line raščlamba

2 O algoritmu rastavljanja (Antonio Jovanović)

- Jezgre
- Pristupi i odstupi
- Baza slogova u SSFu

Model sloga



- Osnovni model sloga sliči apstraktnome stablu u koje se svi slogovi trebaju uklopiti kako bi bili prepoznati kao prihvatljivi slogovi pojedinoga jezika¹
- Slog se može objasniti kao lûk sonornosti/zvonačnosti, odnosno kao fonološka jedinica sastavljena od jednog ili više odsječaka (glasova), koja ima jedan vrh sonornosti.²

¹Jelaska, Zrinka (2004) *Fonološki opisi hrvatskoga jezika. Glasovi, slogovi, naglasci.*

Zagreb: Hrvatska sveučilišna naklada.

²Škiljan, Dubravko (1980) *Pogled u lingvistiku.* Zagreb: Školska knjiga

Model morfema³

P0-3	K2	I	K1	S0-3	Sg	Oblik
------	----	---	----	------	----	-------

gdje su:

- **P0-3** - prefiksi od 0 do 3 morfa
- **K2 i K1** - korjeni riječi
- **I** - interfiks, sveza dvaju korijenaa
- **S0-3** - sufiksi od 0 do 3 morfa, a **Sg** - gramatički sufiks

Primjeri:

P0-3	K2	I	K1	S0-3	Sg	Oblik
-	-	-	ruk	n	i	ručni
za	-	-	ruk	i	ti	zaručiti
prep-po	-	-	ruk	i	ti	preporučiti
-	ljev	o	ruk	-	-	ljevoruk
-	ljev	o	ruk	-	im	ljevorukim
-	ruk	o	tvor	in	a	rukotvorina

³Marković, Ivan (2013) *Hrvatska morfonologija*. Zagreb: Disput

Model silabomorfema⁴

**Infinitivni dočetci (silabomorfemi) tipa $-\bar{v}c\bar{v}c(v)$
i prezentski dočetci (silabomorfemi) $-\bar{v}c\bar{v}c(v)$**

(Užarević 2013: 229-231)

Dočetci na <i>-a</i>		Dočetci na <i>-e</i>		Dočetci na <i>-i</i>		Dočetci na <i>-o</i>		Dočetci na <i>-r</i>		Dočetci na <i>-u</i>	
Inf.	Prez.	Inf.	Prez.	Inf.	Prez.	Inf.	Prez.	Inf.	Prez.	Inf.	Prez.
-ābāt > -ābām		-ēbāt > -ēbām		-ībāt > -ībām		-ōbāt > -ōbām		-rbāt > -rbām		-ūbāt > -ūbām	
-ābīt > -ābīm		-----		-ībīt > -ībīm		-----		-rbīt > -rbīm		-ūbīt > -ūbīm	
-ābljāt > -ābljām		-----		-----		-----		-----		-----	
-ābrīt > -ābrūn		-----		-----		-----		-----		-----	
-ācāt > -ācām		-ēcāt > -ēcām		-īcāt > -īcēm		-ōcāt > -ōcām		-rcāt > -rcām		-ūcāt > -ūcām	
-ācīt > -ācīm		-----		-----		-ōcīt > -ōcīm		-----		-ūcīt > -ūcīm	
-āckāt > -āckām		-----		-----		-----		-----		-ūckāt > -ūckām	
-----		-----		-----		-----		-rcnīt > -rcnūn		-ūcnīt > -ūcnūn	
-āčāt > -āčām		-----		-īčāt > -īčēm		-----		-----		-ūčāt > -ūčām	
-āčīt > -āčīm		-ēčīt > -ēčīm		-īčīt > -īčīm		-----		-rčīt > -rčīm		-ūčīt > -ūčīm	
-ācāt > -ācām		-----		-īcāt > -īcām		-----		-----		-ūcīt > -ūcīm	
-----		-----		-īckāt > -īckām		-----		-rckāt > -rckām		-ūckāt > -ūckām	
-----		-----		-īcnīt > -īcnūn		-----		-----		-ūcnīt > -ūcnūn	
-ādāt > -ādām		-ēdāt > -ēdām > -ēdēm		-īdāt > -īdām		-ōdāt > -ōdām		-rdāt > -rdām		-----	
-ādīt > -ādīm		-ēdīt > -ēdīm		-īdīt > -īdīm		-ōdīt > -ōdīm		-rdīt > -rdīm		-ūdīt > -ūdīm	
-ādāt > -ādām		-ēdāt > -ēdām		-īdāt > -īdām		-----		-----		-----	

⁴ Užarević, Josip, Skup u Osijeku: "Hrvatski jezik u računalnome jezikoslovju",
15. veljače 2019.

Fonologija - ljestvice zvonačnosti (zvonkosti, sonornosti)

Sedam razina⁵

- ① šumnici ili pravi konsontani: p, t, k, c, č, ď, s, š, f, h, b, d, g, đ, dž, z, ž
- ② zvonki usnici li labijalni sonanti: m, v
- ③ svijetli nosnici ili nazali: n, nj
- ④ bočnici ili laterali: l, lj
- ⑤ titrajanik ili vibrant: r
- ⑥ prijelaznik ili poluvokal: j
- ⑦ samoglasnici ili vokali: a, e, i, o, u

Četiri razine (J. Užarević, 2019.)

- ① p, t, k, c, č, ď, s, š, f, h
- ② b, d, g, đ, dž, z, ž
- ③ j, l, lj, m, n, nj, r, v
- ④ a, e, o, i, u, r, ije, je, ī, u

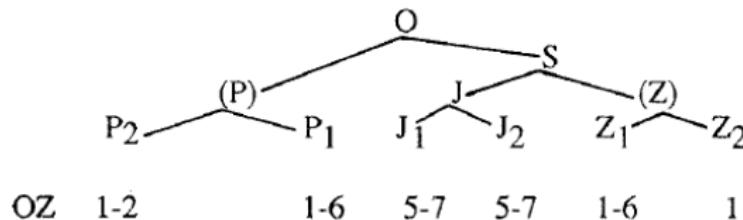
⁵Babić, Zrinka, Slogovna struktura hratskoga književnog jezika, Jezik, Vol. 36 No. 4, 1988

Tri opća slogovna (slogotvorna) pravila

- ① Zakon otvorenih slogova: slogovi teže ostati otvorenima, tj. tendiraju da se završe samoglasnikom: si-na-go-ga, cr-kva (ne crk-va), go-ri-vo
- ② Zakon narastajuće (uzlazne) zvonkosti (zvučnosti): ako se slog sastoji od samoglasnika i više suglasnika, suglasnici se raspoređuju tako da idu od niže zvučnosti prema višoj: str-pljen (113/4-134.), zgro-mi-ti (2234-34-14), cr-kva (13/4-134), be-spo-mo-ćnost (24-114-13411). Pravilo uzlazne zvonkosti ne vrijedi za slogove na kraju riječi – ondje se može nalaziti jedan ili više suglasnika različite zvonkosti u različitim kombinacijama (a-dvent, cr-ven-kast, grozd) (Zakon otvorenih slogova zapravo je uključen u zakon narastajuće zvučnosti, jer su samoglasnici po odredbi najzvučniji među glasovima.)
- ③ Dopunsko pravilo (mehaničko, odnosno nefonološko): Zakon trećega/četvrтoga suglasnika: Prvi od tri uzastopna suglasnika (bilo zvučna, bilo bezzvučna) može – prema potrebi – ići u prethodni slog: od-gri-sti (ali se kao početni ili kanonski oblik uzima o-dgri-sti), di-rek-tno (di-re-ktno). Ako imamo 4 uzastopna suglasnika, tada prva dva idu u prethodni slog, tj. razdioba je 2 + 2: gang-ster, a-dvent-ski

Hrvatski slog sa 7-razinskom ljestvicicom (Jelaska, 2004)

P-pristup, J-jezgra, Z-odstup, OZ-razina zvonačnosti



- ① šumnici ili pravi konsontani: p, t, k, c, č, Ć, s, š, f, h, b, d, g, đ, dž, z, ž
- ② zvonki usnici li labijalni sonanti: m, v
- ③ svijetli nosnici ili nazali: n, nj
- ④ bočnici ili lateralni: l, lj
- ⑤ titrajnik ili vibrant: r
- ⑥ prijelaznik ili poluvokal: j
- ⑦ samoglasnici ili vokali: a, e, i, o, u

13 razina (2019.)

- ① p, t, k, c, č, Ć
- ② b, d, g, đ, dž
- ③ s, š, f, h
- ④ z, ž
- ⑤ v, m
- ⑥ n, nj
- ⑦ l, lj
- ⑧ r
- ⑨ j
- ⑩ i, u, r
- ⑪ ije, je
- ⑫ e, o
- ⑬ a

<http://m-brojevi.com/slogovi2/>

Slogovi

rijeci.txt:

```
ispijken,svijen,trijem,grijem, smijem, sijem, dviju,
obzir,bezobziran,obzor,povlačiti,navlaka,uvlaka,
izbavljenje, predikativnost, aktivnost, slogovnik, stalnost,
daljnji, marni, stvarni, umni,šumni,
razumni,sublimni,svratiti,svraka,krajnji, praskozorje,
```

padine.py:

```
## Padine pristupa i odstupa ###
# '\u024c7'= r (slogotvorno), '\u01cc'=nj, '\u01c9'=lj, '\u01c6'=dž,
'\u2c21'=ije, '\u2c51'=je
pristupi = [
[
```

ispis međurezultata Proširenje

Obradi »

Reset

tezine.py:

```
### TABLICA ZVONAČNOSTI ###
```

tezine = {

```
'p': 1,'t': 1,'k': 1, 'c': 1,'č': 1,'ć': 1,
'b': 2,'d': 2,'g': 2,'đ': 2, '\u01c6': 2, #dž
```

IJE.txt:

```
antitijelo
avioprijevoznik
besprije koran
besprije korno
besvijest
```

Četiri tablična polja/datoteke (sve je moguće mijenjati i on-line):

- ① **riječi.txt** - riječi (koje moraju biti odvojene razmakom ili zarezom).
- ② **tezine.py** - ljestvice zvonačnosti, trenutačno s 13 razina.
- ③ **padine.py** - dopuštene kombinacije glasova u pristupima i odstupima
- ④ **IJE.txt** - rječi s dugim 'jat-om' (leme) iz kojih se generiraju pojavnice

Rezultati raščlambe

Rezultat:

R: bezobziran

S: ['be.zo.bzi.ran', 'be.zo.bzir.an', 'be.zob.zi.ran', 'be.zob.zir.an', 'bez.o.bzi.ran', 'bez.o.bzir.an', 'bez.ob.zi.ran', 'bez.ob.zir.an']

R: obzor

S: ['o.bzor', 'ob.zor']

R: povlačiti

S: ['po.vla.či.ti', 'po.vla.čit.i', 'po.vlač.i.ti', 'po.vlač.it.i', 'pov.la.či.ti', 'pov.la.čit.i', 'pov.lač.i.ti', 'pov.lač.it.i']

R: navlaka

S: ['na.vla.ka', 'na.vlak.a', 'nav.la.ka', 'nav.lak.a']

R: uvlaka

S: ['u.vla.ka', 'u.vlak.a', 'uv.la.ka', 'uv.lak.a']

R: izbavljenje

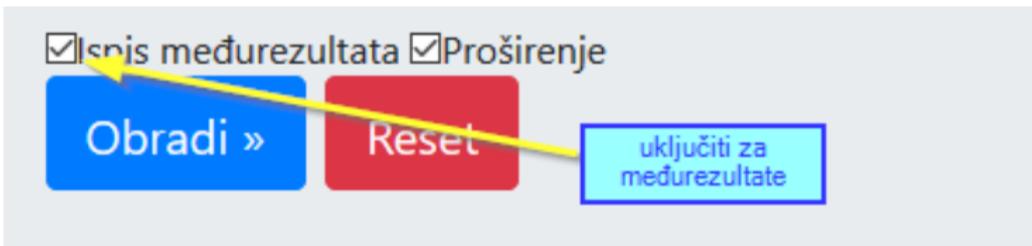
S: ['i.zba.vlje.nje', 'i.zba.vljenj.e', 'i.zbav.lje.nje', 'i.zbav.ljenj.e', 'iz.ba.vlje.nje', 'iz.ba.vljenj.e', 'iz.bav.lje.nje', 'iz.bav.ljenj.e']

R: predikativnost

S: ['pre.di.ka.ti.vnost', 'pre.di.ka.tiv.nost', 'pre.di.kat.i.vnost', 'pre.di.kat.iv.nost', 'pre.dik.a.ti.vnost', 'pre.dik.a.tiv.nost', 'pre.dik.at.i.vnost', 'pre.dik.at.iv.nost', 'pred.i.ka.ti.vnost', 'pred.i.ka.tiv.nost', 'pred.i.kat.vnost', 'pred.i.kat.iv.nost', 'pred.ik.a.ti.vnost', 'pred.ik.a.tiv.nost', 'pred.ik.at.i.vnost', 'pred.ik.at.iv.nost']

**Sva dopuštenja rastavljanja po pravilima (padina i težina).
Prva raščlamba u nizu predstavlja kanonski oblik raščlambe.**

Međurezultati - lako oblikovanje padina



R: predikativnost

pr_e_dikativnost

M: ('pre', 2, 0) 1.8.12. | ('pred', 2, 1) 1.8.12.2. |

F: ['pre', 'pred']

pred_i_kativnost

M: ('i', 0, 0) 10. | ('di', 1, 0) 2.10. | ('ik', 0, 1) 10.1. | ('dik', 1, 1) 2.10.1. |

F: ['i', 'di', 'ik', 'dik']

predik_a_tivnost

M: ('a', 0, 0) 13. | ('ka', 1, 0) 1.13. | ('at', 0, 1) 13.1. | ('kat', 1, 1) 1.13.1. |

F: ['a', 'ka', 'at', 'kat']

predikat_i_vnost

M: ('i', 0, 0) 10. | ('ti', 1, 0) 1.10. | ('iv', 0, 1) 10.5. | ('tiv', 1, 1) 1.10.5. | ('ivn', 0, 2) 10.5.6. | ('tivn', 1, 2) 1.10.5.6. |

F: ['i', 'ti', 'iv', 'tiv']

predikativn_o_st

M: ('ost', 0, 2) 12.3.1. | ('nost', 1, 2) 6.12.3.1. | ('vnost', 2, 2) 5.6.12.3.1. |

F: ['ost', 'nost', 'vnost']

S: ['pre.di.ka.ti.vnost', 'pre.di.ka.tiv.nost', 'pre.di.kat.i.vnost', 'pre.di.kat.iv.nost', 'pre.dik.a.ti.vnost', 'pre.dik.a.tiv.nost', 'pre.dik.at.i.vnost', 'pre.dik.at.iv.nost', 'pred.i.ka.ti.vnost', 'pred.i.ka.tiv.nost', 'pred.i.kat.i.vnost', 'pred.i.kat.iv.nost', 'pred.ik.a.ti.vnost', 'pred.ik.a.tiv.nost', 'pred.ik.at.i.vnost', 'pred.ik.at.iv.nost']

ALGORITAM RASTAVLJANJA I IMPLEMENTACIJA U SSF-u

Traženje jezgri slogova u riječi

Algorithm 1 SYLLABLENUCLEI(WORD, WEIGHTS) finds all syllable nuclei in a word

```
1: Input word, weights
2: Output list of boolean values, i-th value is True if word(i) is a nucleus, False otherwise
3: nucleus_list  $\leftarrow$  []
4: n  $\leftarrow$  length(word)
5: vowels  $\leftarrow$  ['a', 'e', 'i', 'o', 'u']
6: for i = 1 to n do
7:   sound  $\leftarrow$  word[i]
8:   cond_1  $\leftarrow$  sound is in vowel or sound is jat
9:   cond_2  $\leftarrow$  sound = 'r' and i = 1 and weights of following sound is  $\leq$  7
10:  cond_3  $\leftarrow$  sound = 'r' and i = n and weights of preceding sound is  $\leq$  7
11:  cond_4  $\leftarrow$  sound = 'r' and i not in [1, n] and weights of neighbouring sounds is  $\leq$  7
12:  cond_5  $\leftarrow$  sound = 'l' and i = n and weights of preceding sound is  $\leq$  6
13:  cond_6  $\leftarrow$  sound in ['l', 'lj'] and i not in [1, n] and weights of neighbouring sounds is  $\leq$  6
14:  cond_7  $\leftarrow$  sound = 'm' and i not in [1, n] and weights of neighbouring sounds is  $\leq$  4
15:  cond_8  $\leftarrow$  sound in ['n', 'nj'] and i not in [1, n] and weights of neighbouring sounds is  $\leq$  5
16:  if cond_1 or cond_2 or cond_3 or cond_4 or cond_5 or cond_6 or cond_7 or cond_8 then
17:    append True to nucleus_list
18:  else
19:    append False to nucleus_list
20: return nucleus_list
```

Rezultat:

R: drvo

S: ['dr.vo', 'drv.o']

R: trljati

S: ['tr.lja.ti', 'tr.ljat.i', 'trlj.a.ti', 'trlj.at.i']

R: rđati

S: ['r.đa.ti', 'r.đat.i', 'rd.a.ti', 'rd.at.i']

R: rvač

S: ['r.vač', 'rv.ač']

R: rzati

S: ['r.za.ti', 'r.zat.i', 'rz.a.ti', 'rz.at.i']

R: bicikl

S: ['bi.ci.kl', 'bi.cik.l', 'bic.i.kl', 'bic.ik.l']

R: monokl

S: ['mo.no.kl', 'mo.nok.l', 'mon.o.kl', 'mon.ok.l']

R: vltava

S: ['vl.ta.va', 'vl.tav.a', 'vlt.a.va', 'vlt.av.a']

Svi mogući ispravni slogovi u riječi

Algorithm 2 POSSIBLESYLLABLES(NUCLEUS, PREFIX, SUFFIX, NUCLEUS_LIST) finds all possible syllables in a word that contain nucleus

```
1: Input nucleus, prefix, suffix, nucleus_list
2: Output List of all possible syllables containing nucleus
3: syllable_list ← [nucleus]
4: if there are no nuclei in prefix then
5:     append prefix + nucleus to syllable_list
6: if there are no nuclei in suffix then
7:     if there are no nuclei in prefix then
8:         append prefix + nucleus + suffix to syllable_list
9:     else
10:        append prefix + nucleus to syllable_list
11: if there are nuclei in prefix then
12:     bottom ← -1
13:     for i ← length(prefix) to 1 do
14:         if nucleus_list[i] = True then
15:             break
16:         else
17:             if bottom = -1 and weight[prefix[i]] < weight[prefix[i - 1]] then
18:                 bottom ← i
19:             else if bottom ≠ -1 then
20:                 if bottom < length(prefix) then
21:                     break
22:                     if bottom = length(prefix) and weight[prefix[i]] > weight[prefix[i + 1]] then
23:                         break
24:                     append prefix[i :] + nucleus to syllable_list
```

```
25: if there are nuclei in suffix then
26:   bottom  $\leftarrow$  -1
27:   for i  $\leftarrow$  1 to length(suffix) do
28:     if nucleus_list[i + length(prefix) + 1] = True then
29:       break
30:     else
31:       if bottom = -1 and weight[suffix[i]] < weight[suffix[i + 1]] then
32:         bottom  $\leftarrow$  i
33:       else if bottom  $\neq$  -1 then
34:         if bottom > 1 then
35:           break
36:         if bottom = 1 and weight[suffix[i]] < weight[suffix[i - 1]] then
37:           break
38:         append syllable + suffix[i] to syllable_list for every syllable in syllable_list that ends in suffix[i - 1]
            or nucleus if i = 0
39: return syllable_list
```

Algorithm 3 FILTERSYLLABLES(SYLLABLE_LIST, WEIGHTS, PREFIX_RULES, SUFFIX_RULES) filters syllables according to rules

- 1: **Input** *syllable_list, weights, prefix_rules, suffix_rules*
- 2: **Output** *new_syllable_list*
- 3: **for** *syllable* in *syllable_list* **do**
- 4: *prefix* \leftarrow prefix of *syllable*
- 5: *suffix* \leftarrow suffix of *syllable*
- 6: **if** *prefix* in *prefix_rules* **and** *suffix* in *suffix_rules* **then**
- 7: insert *syllable* into *new_syllable_list*
- 8: **return** *new_syllable_list*

Algorithm 4 SYLLABLES(WORD, WEIGHTS, PREFIX_RULES, SUFFIX_RULES) finds all syllable decompositions of a word

- 1: **Input** *word, weights, prefix_rules, suffix_rules*
- 2: **Output** *syllable_list*
- 3: *word* \leftarrow transform every 'ije' and 'je' to 'jat' accordingly
- 4: *nucleus_list* \leftarrow SYLLABLENUCLEI(WORD, WEIGHTS)
- 5: *possible_syllables* \leftarrow \emptyset
- 6: **for** *i* from 1 to length(*word*) **do**
- 7: **if** *nucleus_list*[*i*] = True **then**
- 8: *possible* \leftarrow POSSIBLESYLLABLES(*word*[*i*], *word*[:*i*], *word*[*i* + 1:], *nucleus_list*)
- 9: append FILTERSYLLABLES(*possible*, *weights*, *prefix_rules*, *suffix_rules*) to *possible_syllables*
- 10: *syllables* \leftarrow list of every possible combination of syllables from *possible_syllables* that equals *word*
- 11: **return** *syllables*

Postavke za pretragu u SSF-u

Riječi

T-Strukture

Rečenice

MSY

LEX

MWE



Postavke pretrage

Broj morfova u bazi: 4.418 | Broj slogova u bazi: 7.591 | Broj silabomorfema u bazi: 323.253

Maksimalni broj rezultata: *0 za neograničeno

Tip pretrage:

Morfovi Slogovi Silabomorfemi

WOS/SOW filter:

Označi sve Odznači sve

<input type="checkbox"/>	<input type="checkbox"/>	Vrsta riječi
<input type="checkbox"/>	<input checked="" type="checkbox"/>	Imenica
<input type="checkbox"/>	<input type="checkbox"/>	Zamjenica
<input type="checkbox"/>	<input type="checkbox"/>	Pridjev
<input type="checkbox"/>		

Označi sve Odznači sve

<input type="checkbox"/>	<input type="checkbox"/>	GPS
<input type="checkbox"/>	<input type="checkbox"/>	Lokalitet
<input type="checkbox"/>	<input type="checkbox"/>	Definicija
<input type="checkbox"/>	<input type="checkbox"/>	Primjer
<input type="checkbox"/>		

Posicija u riječi

Bilo koja O1 O2 O3 O4 O5 O6 O7 O8 O9 O10 O11 Ozadnji

MSY

- odrediti obilježja riječi koje se raščlanjuju
- odrediti mjesto sloga po abecedi unutar riječi

Rezultati u SSF-u

← Povratak Pretraga WOS filter: Vrsta riječi • Imenica Pozicija u riječi: 2 Tip pretrage: Slogovi

A B C Č Ć D Đ E F G H I J K L U M N NJ O P R S Š T U V Z Ž

Postoje 496 riječi koje zadovoljavaju kriterij pretrage. Prikazuje se prvih 100

KA

Riječ:	pen-ka-la	lo-ka-ci-ja	stru-ka	bilj-ka	šilja-ka	broj-ka	tra-ka	sli-ka	bru-ka	blo-ka-da	lu-ka-vost	bolj-ka	do-ka-ziv-a-nje	vo-ka-cl-ja
bu-ka	zvu-ka	str-ka	alj-ka-vost	spoj-ka	mu-ka	ro-ka	pri-ka-za	sto-ka	pri-ka-ziv-a-nje	var-ka	manj-ka-vost	luc-ka-stost	školj-ka	
ko-ka	ru-ka-vac	de-ka	de-ka-gram	fle-ka	stan-ka	zbir-ka	snim-ka	kli-ka	vo-ka-li-za-ci-ja	po-ka-za-telj	po-ka-ziv-ač	po-ka-ziv-a-nje		
u-ka-ziv-a-nje	žen-ka	se-ka	stran-ka-ma	la-ka	ru-ka	ša-ka	la-ka-ta	ru-ka-ma	ba-ka	zra-ka	maj-ka	ri-ka	do-ka-ze	bar-ka
rije-ka	koc-ka-ma	do-ka-ziv-a-nja	član-ka	stran-ka	šmin-ka	lijе-ka	pla-ka-te	pla-ka-ta	li-ka	...				

KAC

Riječ:	ku-kac	šo-kac	džu-kac	tu-kac
--------	--------	--------	---------	--------

tukac

WOS:	Slogovi	Vrsta riječi • Imenica
Riječ:	ku-kač	Rod • Muški
	šo-kač	Broj • Jednina

Padež • Nominativ

kač pe-kač so-kač ba-kač mi-kač

Hvala na pozornosti



Nema više (kraj je blizu) ☺!