



UDK 811.163.6:681.3

Jure Zupan

Kemijski inštitut, Ljubljana

PROBLEMI IN NEKAJ REŠITEV RAČUNALNIŠKIH OBDELAV SLOVENSKIH BESEDIL

Opisan je problem avtomatske besedne analize slovenskih besedil. Posebej je izpostavljen problem različnosti končnic pri sklanjatvah in spregatvah. Navedeni so vsi nizi različnih računalniških končnic, ki so bili najdeni pri pregledu in klasifikaciji približno 156.000 slovenskih besed. Predstavljeni računalniški slovar, katerega vsako geslo je sestavljeno iz *računalniške osnove* besede in pripadajočega niza *računalniških končnic* vsebuje približno 150.000 pregibnih in okrog 6.000 nepregibnih gesel. Opisani slovar omogoča dokajšno stopnjo avtomatizacije pri besedni analizi. Navedena sta tudi dva primera uporabe.

A problem of automatic word analysis of Slovene texts is described and discussed. As the essential issue the variety of *computational endings* in Slovenian declination is exposed. All sets of different endings identified during the classification of about 156.000 Slovenian words are listed. The dictionary in which each entry is composed of the *computational root* and the set of *computational endings* consists of approximately 150.000 and about 6,000 flexible and non-flexible words. The described dictionary enables a variety of applications with two of them shown as examples.

Prva naloga, ki jo je pri obširnejši obdelavi besedila treba opraviti, je podrobna besedna analiza. Besedna analiza je izhodišče za nadaljnje raziskave, kot so npr.: primerjave med različnimi avtorji oziroma načini njihovih pisanj, študije naraščanja besednih zakladov v odvisnosti o obdobja pisanja in »zorenja« pisateljev, iskanje vplivov posameznih literarnih smeri v opusih sodobnikov, iskanje konkordanc v kontekstih itd. Žal mora vsak raziskovalec besedno analizo v pretežni meri še vedno opravljati »ročno«. Povsem računalniško vodena (brez posredovanja strokovnjaka) besedna analiza je zaradi mnogoterosti slovenskih pregibnih oblik in variacij tako otežkočena, da doslej še ni uspelo izdelati računalniškega programa, ki bi lahko posel zadovoljivo opravil. Beseda *zadovoljivo* je v tem kontekstu mišljena tako, da bi morala računalniška besedna analiza zadostiti standardom, ki sta jih postavila Jakopin in Bizjak (Jakopin 1995; Jakopin, Bizjak 1997) in biti hkrati narejena nekaj velikostnih razredov hitreje kot ročna. Posebej je treba poudariti, da se vsi, ki na tem področju delamo, zavedamo, da bo določen delež ročne analize nujen še precej časa. Hkrati vemo, da vsak napredek v tej smeri precej olajša ta najbolj utrujajoč in za marsikoga tudi najmanj zanimiv del raziskav. Avtonomična besedna analiza bo precej pripomogla k bolj natančnim in hitreje dobljenim končnim rezultatom kompleksnejših raziskav.

Zavedamo se tudi, da je prednost slovenščine pred drugimi jeziki, ki imajo bistveno revnejše pregibne možnosti, predvsem pred angleščino, prav bogastvo in razvejanost pregibnih oblik. Natančno poznavanje in sistemizacija vseh možnosti pregibnih oblik nudi izhodišče za izboljšave avtomatske (računalniško vodene) analize besedil. Hkrati z novimi dosežki narašča upanje, da bomo povsem (ali vsaj v veliki meri) avtomatizirano besedno analizo lahko nekoč tudi res imeli. Pri jezikih

s skromno pregibno raznolikostjo različne besedne vrste pogosto nastopajo v isti formalni (črkovni) obliki. Zato jim lahko šele iz konteksta določimo pravilno formalno opredelitev. Primer je beseda *iron*, ki v angleščini pomeni v zvezah *to iron*, *the iron in the iron (lady)* bodisi *likati* (glagol), *železo* (samostalnik) ali pa *odločno* (*železno*) žensko (pridevnik). Njihov pomen je potemtakem določen glede na položaj v stavku (kontekst) in mnogokrat tudi glede na ločila. Obdelava konteksta je tudi pri besedni analizi za take jezike neizogibna. Za razliko od angleščine (Popovič, Willet 1990; Zupan 1999) se da pri slovenščini v bistveno večjem številu primerov že iz same besedne forme (črkovne oblike = osnova + končnica) ugotoviti, za katero besedno vrsto gre. Večinoma lahko hkrati ugotovimo še sklon, spol, število ali čas. Natančna analiza možnih končnic pri sklanjatvi ali spregatvi nam ob upoštevanju pravil, ki določajo povezave med končnicami besed in predlogi, zaimki ali pomožnimi glagoli, omogoča precejšno mero avtomatizma.

Na načelni jezikoslovni ravni so pri sklanjanju in spreganju končnice in pravila za uporabo predlogov ter oblik pomožnega glagola dokaj natančno določene. Jezikoslovna pravila, po katerih delimo sklanjatve in spregatve (Toporišič 1975; 1984; 1994; Lenček 1982) in po katerih tvorimo pravilne končnice, mehčamo soglasnike ali izpuščamo polglasnik, so znana, a so za računalniško uporabo preveč raznolika. Večina slovničnih pravil je v etimološkem smislu in iz pedagoško-didaktičnega vidika sicer logična, žal pa ni uporabna pri računalniški logiki v obliki: »če – potem« (»if – then«). Primer: pravila živosti za tožilnik ednine samostalnikov moškega spola ne moremo sprogramirati drugače, kot da označimo vse samostalnike moškega spola, da so bodisi »živi« bodisi »neživi«. S samo oznako živosti/neživosti pa še ne povemo, kako se ti samostalniki dejansko sklanjajo. Zato moramo istočasno povedati še, katere končnice pritičajo posameznemu samostalniku pri vseh sklonih. Tak način uporabe logičnih slovničnih pravil je torej neekonomičen in v bistvu ne spremeni dejstva, da je za vsak samostalnik potrebno eksplisitno navesti, kako se le-ta sklanja.

Hipoteza v tem prispevku pravi, da je primernejše pripisati vsaki besedi v slovarju (geslu) vse možne končnice, kot pa iskati, postaviti in prevesti v računalniško logiko vsa slovnična pravila in vse izjeme, ki se pri besedni analizi pojavljajo. V sestavku so navedeni vsi nizi računalniških končnic, ki so bili dobljeni po pregledu in klasifikaciji približno 160.000 slovarskih gesel. Za vse vrste pregibnih besed je naštetih 240 različnih nizov računalniških končnic. Vsaka beseda v slovarju, če je seveda pregibna, ima poleg računalniške osnove navedeno še številko niza računalniških končnic. Niz pa vsebuje vse možne končnice tega gesla. Vsi ugotovljeni nizi računalniških končnic so navedeni v tabelah II do IX. Zbiranje končnic, pregledovanje besedišča in klasifikacija besed je trajalo osem let (Zupan 1991).

Osnovna izhodišča in definicije

Velika večina slovnici je namenjena učenju maternega jezika in zato vedno predpostavlja neko minimalno jezikovno predznanje. Zaradi te predpostavke v slovnicah niso navedena **vsa** slovnična pravila in vse izjeme, ki so potrebna za pravilno sklanjanje in spreganje. Domneva, da bo učenec po nekaj opisanih primerih zнал vse

nadaljnje nadgraditi sam, se izkaže za tujca kot precej zahteven pogoj. Kot primer poglejmo sklanjatve samostalnikov. V slovenskih slovnicah (Žagar 1991) navajajo, da so pri samostalnikih moškega in ženskega spola širje, pri samostalnikih srednjega spola pa trije sklanjatveni vzorci. Dodana so še pravila, ki pojasnjujejo, kako se pri različnih spolih in sklonih spremenljajo naglesi; povedanih je nekaj izjem, kot npr. podaljševanje osnove z *j* (*slikar, slikar-j-a*) in potem izjem od izjem (*meter, met(e)r-(j)-a*). Niso pa navedena še druga pravila in izjeme, ki so večini učencev s slovenskim maternim jezikom tako samoumevna, da jih je moč izpustiti ali pa so tako izjemna in redka, da praktično ne pridejo v poštev. Npr.: imenovalnik v množini, ki se konča na *-je*, je navadno pojasnjen le s tremi ali štirimi primeri (*brat-je, fant-je, gost-je, golob-je*), kar Slovencu zadostuje. Nikoli pa niso našteti **vsi** taki primeri (*škof-je, mož-je, ud-je, voz-je* in še mnogo drugih tudi tipološko posebnih *mož-je, las-je, voz-je, volc-je zob-je*). Tudi tu niso našteti vsi, ki pa so zbrani v računalniškem slovarju. Za računalniško obdelavo je namreč treba eksplisitno navesti prav vse. Primer za redko izjemo, ki skoraj nikoli ni omenjena v učbenikih, je sklanjanje samostalnika srednjega spola *igo* (*igo, ižesa, ižesu ...*). Upamo, da rojenemu Slovencu ali Slovenki posluh omogoči spoznanje, da se beseda sklanja podobno kot *aho* ali *oko*. Splošna pravila torej ne dajejo zanesljivih navodil, ki bi veljala za **vse** primere, in zato z njimi ne moremo narediti uporabnih računalniških programov, ker le-ti nimajo ne posluha, ne jezikovnega znanja. Ponovno pridemo do sklepa, da je najbolje vsaki besedi pripisati vse njene pregibne možnost eksplisitno.

Hudo težavo povzroča dejstvo, da pri pisanju slovenščine ne uporabljam naglasov. S tem so le-ti kot informacija za računalniško določitev pravilnih pregibnih oblik izgubljeni. Lep primer za dvoumnost in izgubo informacije pri izpuščanju naglasov je računalniška težava razlikovanja samostalnika od pridevnika v tako enostavnem primeru kot je naslov Levstikove povesti *Martin Krpan*. Zaradi opustitve naglasa računalnik ne zmore ločiti moškega imena *Martin* od pridevnika *Martin* ((od) Marte). Po drugi strani pa prav zaradi raznolikosti končnic slovenščina (in z njo večina slovanskih jezikov) nima toliko težav pri razlikovanju posameznih sklonov kot npr. angleščina, ki pozna le saški genitiv in nekaj množinskih oblik (Zupan 1999).

Seveda se tudi pri slovenščini ne smemo zanašati le na končnice. Poznamo celo vrsto dvoumnosti: nekateri skloni samostalnikov so oblikovno identični sklonom drugih besednih vrst. Primer za tako ekvivalenco so vsi samostalniki moškega spola, pri katerih rodilnika množine ni moč razlikovati od pridevniške oblike iste osnove: *gospod-ov, stol-ov, stroj-ev*. Takih primerov je še več, vendar niso toliko splošni, da bi jih lahko uokvrili v splošna pravila. Primer za netipično ekvivalenco (homografijo) besednih oblik (Popovič, Willet 1990) je samostalnik *puščava*, ki se v povsem enaki obliki pojavi tudi v drugi osebi dvojnine sedanjika glagola *puščati*.

Vsi navedeni primeri potrjujejo, da je človekov razum bistveno bolje usposobljen za razpoznavanje in analizo besed, kot so ali morda bodo v bodočnosti usposobljeni računalniki. Ker so slovnice napisane za ljudi in ne za računalnike, je

za učinkovito besedno analizo na podlagi lingvističnih pravil iz učbenikov zelo težko sestaviti računalniške algoritme, tj. do vseh podrobnosti pojasnjene postopke.

Osnovna zamisel predstavljene rešitve problema avtomatske besedne analize temelji na ideji tako imenovane *računalniške osnove*. Računalniška osnova besede je definirana kot tisti najdaljši začetni del besede, ki se ohrani pri vseh pregibnih oblikah. Tako so računalniške osnove besed *miza, meter, lep, majhen,igrati* in *peti: miz-* (miz-a, miz-e,...), *met-* (met-er, met-ra,...), *lep-* (lep-0, lep-a,...), *majh-* (majh-en, majh-na,..), *igra-* (igra-ti, igra-m,...) in *p-* (p-eti, p-ojem,...). Računalniška osnova je lahko enaka lingvistični, kot v primerih *lep* in *igra-ti*, vendar marsikdaj ni, kar vidimo iz primera računalniške osnove *p-* pri glagolu *p-eti: p-ojem, p-oješ, ... bom p-el, sva p-ela* itd.

Največkrat so računalniške osnove krajše od oblikoslovnih osnov. To je lahko posledica izpuščanja polglasnikov, kot v primeru *majh-en: majh-na, majh-ne* itd., zaradi premen pri glagolu *i-skati, i-ščem, i-ščeš* itd. ali zaradi drugih posebnosti slovenščine.

Veliko računalniških osnov je povezanih z različnimi nizi računalniških končnic. Različni nizi računalniških končnic pripeljejo eno računalniško osnovo do različnih slovarskih gesel. Primer za to sta računalniški osnovi *d-* in *pet-*. Osnova *d-* ima tri nize računalniških končnic za geslo: *d-an (d-ne, d-neva,...)*, za geslo *d-reti (d-erem, d-ereš,...)* in geslo *d-uti (d-mem, d-meš,...)* (SP 1962)). Osnova *pet-* pa ima celo šest različnih nizov računalniških končnic, in sicer za gesla: *pet-a, pet-ek, Pet-er, pet-lja, pet-i* (štěvnik) in *pet-en/ni* (pridevnik).

Ker so v slovarju besedna gesla shranjena kot računalniške osnove in pridajoči niz računalniških končnic, lahko vsaki besedi avtomatično poiščemo vse pregibne oblike. Velja tudi obratno: vsaki pregibni obliku lahko poiščemo pridajoče slovarsko geslo (Popovič, Willet 1990; Zupan 1991). Edina stvar, ki jo moramo ob osnovi še poznati, so vsi možni nizi računalniških končnic. Zato je bil velik del raziskave osredotočen prav na določitev vseh možnih nizov slovenskih računalniških končnic v slovenskem jeziku.

Pregled nizov računalniških končnic

Nizi računalniških končnic so razdeljeni na samostalniške, pridevniške in glagolske. Samostalniški nizi se dele na računalniške končnice sklanjatev samostalnikov moškega, ženskega in srednjega spola ter na računalniške končnice množinskih samostalnikov. Ti zadnji so prav tako razdeljeni na nize za samostalnike moškega, ženskega in srednjega spola. Nizi pridevniških končnic so razdeljeni na take, ki vsebujejo pridevniške, števniške in zaimenske računalniške končnice. Samostalniški zaimki so zaradi specifike obravnavani posebej: ne z nizi računalniških končnic, ampak kot samostojne nepregibne oblike. Najštevilčnejša skupina nizov so računalniške končnice glagolskih spregatev (89 različnih nizov). Pregled vseh nizov računalniških končnic kaže tabela I. Iz nje je razvidno, da je različnih nizov računalniških končnic 240.

Število računalniških končnic v nizih je pri posameznih besednih vrstah različno. Samostalniki imajo osemnajst, pridevniki dvanajst in glagoli enaindvajset računalniških končnic. Končnice so v nizih navedene vedno v istem vrstnem redu. Poleg pravih računalniških končnic nastopata v nizih še dve oznaki: *-0* in *-#*: prva oznaka (*-0*) pomeni, da na tem mestu računalniška osnova nima končnice in lahko stoji samostojno, npr.: prvi sklon in četrti sklon prve moške sklanjatve ednine (tabela II, nizi 2, 4, 6 in 8); druga oznaka (*#*) pa pomeni, da sklanjatev ali spregatev zadevnih končnic sploh ne pozna (npr.: množinske oblike besede *človek*, tabela II, niz 10).

Pri samostalnikih je vedno navedenih osemnajst računalniških končnic (za vse sklone v vseh številih) čeprav niso vse med seboj različne. Druga ženska sklanjatev ima sedem (npr.: *mis-el*, *-li*, *-lijo*, *-lima*, *-lih*, *-lim*, *-limi*), druga moška pa osem različnih računalniških končnic (pob-*a*, *-u*, *-om*, *-ov*, *-oma*, *-ih*, *-i*, *-e*). Tretje skanjatve vseh spolov pa sploh nimajo računalniških končnic (primeri: *oča*, *mami* in *doma*). V tabelah II do IV samostalniških sklanjatev so računalniške končnice za ednino, dvojino in množino ločene s črto.

Tabela I: Pregled števila različnih nizov računalniških končnic za vse sklanjatve in spregatve

Računalniške končnice		Dolžina niza	Število nizov
Navadne samostalniške sklanjatve	moški	18	48
	ženski	18	29
	srednji	18	23
Množinske samostalniške sklanjatve	moški	6	5
	ženski	6	10
	srednji	6	7
Pridevniške sklanjatve	pridevniki	12	11
	štavniki	12	9
	pridevniški zaimki	12	9
Glagolske spregatve	samostalniški zaimki imajo individualne oznake	–	–
		21	89
Skupaj			240

Zaradi ločevanja živosti v tožilniku ednine se število nizov različnih računalniških končnic pri moških samostalnikih skoraj podvoji. Samostalnikom za živa bitja so prirejeni drugačni nizi (z izpremenjeno končnico v tožilniku ednine) kot tistim za nežive stvari (primerjaj lihe in sode nize v tabeli II – razlikujejo se le po četrti končnici!). Edninske računalniške končnice za sklanjanje besede *žerjav-0* (ptica) so: *žerjav-0*, *-a*, *-u*, *-a*, *pri -u*, *z -om*, za besedo *žerjav-0* (dvigalna naprava) pa: *žerjav-0*, *-a*, *-u*, *-0*, *pri -u*, *z -om*. Podobno je tudi pri vseh ostalih moških samostalnikih, npr.: sklanjatvi samostalnikov na -em: *komuniz-em* in *Eraz-em*.

So še druge izjeme. Pri samostalnikih se za množice več od štiri v prvem sklonu uporablja drugačna končnica kot za tri ali štiri: *štirje slon-i*, *pet slon-ov* ali *štiri kače-e*, *pet kač-0* itd. Ta končnica je identična končnicama rodilnika dvojine in

množine, ki sta v vseh samostalniških nizih na osmem oziroma štirinajstem mestu. Zato posebna oznaka ni potrebna.

Posebnosti so tudi dodatne računalniške končnice pri nekaterih množinskih oblikah: npr.: *sin-i* in *sin-ovi*, *grob-i* in *grob-ovi* itd. Posebnosti, netipičnosti in alternativne končnice moških sklanjatev so navedene v tabeli II v nizih od 37 do 43. Pri sklanjatvah vseh spolov naletimo tudi na take nize računalniških kočnic, po katerih se sklanja le ena sama beseda, kar po definiciji predstavlja izjemo, npr.: *blag-or* (*blag-ra*, ...), *pes-em* (*pes-mi*, ...), *i-go* (*i-žesa*, ...), *u-ho* (*u-šesa*, ...) in *o-ko* (*o-česa*, ...) itd.

Navedene izjeme seveda še zdaleč niso vse. Vsi nizi različnih računalniških končnic, ki sem jih zasledil pri pregledu več kot 60.000 samostalnikov, so zbrani v tabelah II (moške), III (ženske) in IV (srednje).

Tabela II: Nizi samostalniških računalniških končnic moških sklanjatev

1	2	3	4	5	6	7	8	9	10
-0	-0	-0	-0	-0	-0	-0	-0	-0	-0
a	a	a	a	ja	ja	na	na	ta	a
u	u	u	u	ju	ju	nu	nu	tu	u
a	-0	a	-0	ja	-0	na	-0	ta	a
u	u	u	u	ju	ju	nu	nu	tu	u
om	om	em	em	jem	jem	nom	nom	tom	om
a	a	a	a	ja	ja	na	na	ta	a
ov	ov	ev	ev	jev	jev	nov	nov	tov	ov
oma	oma	ema	ema	jema	jema	noma	noma	toma	oma
a	a	a	a	ja	ja	na	na	ta	a
ih	ih	ih	ih	jih	jih	nih	nih	tih	ih
oma	oma	ema	ema	jema	jema	noma	noma	toma	oma
i	i	i	i	jí	jí	ni	ni	tí	-#
ov	ov	ev	ev	jev	jev	nov	nov	tov	-#
om	m	em	em	jem	jem	nom	nom	tom	-#
e	e	e	e	je	je	ne	ne	te	-#
ih	h	ih	ih	jih	jih	nih	nih	tih	-#
i	I	i	i	jí	jí	ni	ni	tí	-#
mulat	polip	garač	vrč	vratar	cekar	rabelj	nagelj	Pavle	človek

11	12	13	14	15	16	17	18	19	20
ec	ec	eg	ej	ek	ek	el	el	elj	elj
ca	ca	ga	ja	ka	ka	la	la	lja	lja
cu	cu	gu	ju	ku	ku	lu	lu	lju	lju
ec	ca	eg	ja	ka	ek	la	el	lja	elj
cu	cu	gu	ju	ku	ku	lu	lu	lju	lju
cem	cem	gom	jem	kom	kom	lom	lom	ljem	ljem
ca	ca	ga	ja	ka	ka	la	la	lja	lja
cev	cev	gov	jev	kov	kov	lov	lov	ljev	ljev
cem	cema	goma	jema	koma	koma	loma	loma	ljema	ljema
ca	ca	ga	ja	ka	ka	la	la	lja	lja
cih	cih	gih	jih	kih	kih	lih	lih	lijh	lijh
cema	cema	goma	jema	koma	koma	loma	loma	ljema	ljema
ci	ci	gi	ji	ki	ki	li	li	lji	lji
cev	cev	gov	ij	kov	kov	lov	lov	ljev	ljev
cem	cem	gom	jem	kom	kom	lom	lom	ljem	ljem
ce	ce	ge	e	ke	ke	le	le	lje	lje
cih	cih	gih	jih	kih	kih	lih	lih	lijh	lijh
ci	ci	gi	ji	ki	ki	li	li	lji	lji
kršec	tepec	bezeg	zlodej	maček	sodček	osel	vatel	rabelj	nagelj

21	22	23	24	25	26	27	28	29	30
em	em	en	en	enj	enj	er	er	es	es
ma	ma	na	na	nja	nja	ra	ra	sa	sa
mu	mu	nu	nu	nju	nju	ru	ru	su	su
ma	em	na	en	nja	enj	ra	er	sa	es
mu	mu	nu	nu	nju	nju	ru	ru	su	su
mom	mom	nom	nom	njem	njem	rom	rom	som	som
ma	ma	na	na	nja	nja	ra	ra	sa	sa
mov	mov	nov	nov	njev	njev	rov	rov	sov	sov
moma	moma	noma	noma	njema	njema	roma	roma	soma	soma
ma	ma	na	na	nja	nja	ra	ra	sa	sa
mih	mih	nih	nih	njh	njh	rih	rih	sih	sih
moma	moma	noma	noma	njema	njema	roma	roma	soma	soma
mi	mi	ni	ni	nji	nji	ri	ri	si	si
mov	mov	nov	nov	njev	njev	rov	rov	sov	sov
mom	mom	nom	nom	njem	njem	rom	rom	som	som
me	me	ne	ne	nje	nje	re	re	se	se
mih	mih	nih	nih	njh	njh	rih	rih	sih	sih
mi	mi	ni	ni	nji	nji	ri	ri	si	si
Erazem	kosem	oven	boben	suženj	reženj	pater	poper	pes	oves

31	32	33	34	35	36	37	38	39	40
et	et	or	e	o	o	k	-0	an	(an)
ta	ta	ra	a	a	a	ka	a	neva	-#
tu	tu	ru	u	u	u	ku	u	nevu	-#
ta	et	or	e	a	o	ka	a	an	-#
tu	tu	ru	u	u	u	ku	u	nevu	-#
tom	tom	rom	om	om	om	kom	em	nevom	-#
ta	ta	ra	a	a	a	ka	a	neva	ni
tov	tov	rov	-0	ov	ov	k	-0	nevov	ni
toma	toma	roma	oma	oma	oma	koma	ema	nevoma	nema
ta	ta	ra	a	a	a	ka	a	neva	ne
tih	tih	rih	ih	ih	ih	cih	eh	nevh	neh
toma	toma	roma	oma	oma	oma	koma	ema	nevoma	nema
ti	ti	ri	i	i	i	ci	je	nevi	ni
tov	tov	rov	-0	ov	ov	k	-0	nevov	ni
tom	tom	rom	om	om	om	kom	em	nevom	nem
te	te	re	a	e	e	ke	e	neve	ni
tih	tih	rih	ih	ih	ih	cih	eh	nevih	neh
ti	ti	ri	i	i	i	ki	mi	nevi	ni
valpet	hrbet	blagor	Čile	Marko	kino	otrok	mož	dan	dan

41	42	43	44	45	46	47	48	
-0	-0	-0	a	a	ja	-0	i	
u	-#	-#	e	a	je	#	ega	
#	-#	-#	i	u	ji	#	emu	
#	-#	-#	o	a	jo	#	ega	
#	-#	-#	i	u	ji	#	em	
#	-#	-#	o	om	jo	#	im	
#	ova	-#	i	a	ja	#	a	
#	ovov	-#	-0	ov	ij	#	ih	
#	ovoma	-#	ama	oma	jema	#	ima	
#	ova	-#	i	a	ji	#	a	
#	ovih	eh	ah	ih	jih	#	ih	
#	ovoma	-#	ama	oma	jema	#	ima	
#	ovi	-#	e	i	ji	#	i	
#	ovov	-#	-0	ov	ij	#	ih	
#	ovom	-#	am	om	jem	#	im	
#	ove	eh	e	e	je	#	e	
#	ovih	-#	ah	ih	jih	#	ih	
#	ovi	-#	ami	i	ji	#	imi	
med	vrt	dol	sluga	poba	vodja	oča	stari	

Tabela III: Nizi samostalniških računalniških končnic ženskih sklanjatev

1	2	3	4	5	6	7	8	9	10
a	a	a	a	(ca)	ja	(ka)	la	lja	ma
e	e	e	e	#	je	-#	le	lje	me
i	i	i	ej	#	ji	-#	li	lji	mi
o	o	o	o	#	jo	-#	lo	ljo	mo
i	i	i	e	#	ji	-#	li	lji	mi
o	o	o	o	#	jo	-#	lo	ljo	mo
i	i	i	e	#	ji	-#	li	lji	mi
-0	j	i	e	ac	ij	ak	el	elj	em
ama	ama	ema	ema	#	jama	-#	lama	ljama	mama
i	i	i	e	#	ji	-#	li	lji	mami
ah	ah	eh	eh	#	jah	-#	lah	ljah	mah
ama	ama	ema	ema	#	jama	-#	lama	ljama	mama
e	e	i	e	#	je	-#	le	lje	me
-0	j	i	a	ac	ij	ek	el	elj	em
am	am	em	em	#	jam	-#	lam	ljam	mam
e	e	i	e	#	je	-#	le	lje	me
ah	ah	eh	eh	#	jah	-#	lah	ljah	mah
ami	ami	emi	emi	#	jami	-#	lami	ljami	mami
pišk-a	bo-a	sl-a	gosp-a	ov-ca	zar-ja	peč-ka	nič-la	kok-lja	tek-ma

11	12	13	14	15	16	17	18	19	20
na	nja	ra	va	ev	o	-0	-0	i	i
ne	nje	re	ve	ve	e	i	i	vi	ere
ni	nji	ri	vi	vi	i	i	i	vi	eri
no	njo	ro	vo	ev	o	-0	-0	i	er
ni	nji	ri	vi	vi	i	i	i	vi	eri
no	njo	ro	vo	vijo	o	jo	jo	vjo	ero
ni	nji	ri	vi	vi	i	i	i	vi	eri
en	enj	er	ev	ev	-0	i	i	vi	era
nama	njama	rama	vama	vima	ama	ima	ema	vema	erama
ni	nji	ri	vi	vi	i	i	i	vi	eri
nah	njah	rah	vah	vah	ah	ih	eh	veh	erah
nama	njama	rama	vama	vama	ama	ima	ema	vema	erama
ne	nje	re	ve	ve	e	i	i	vi	ere
en	enj	er	ev	ev	-0	i	i	vi	era
nam	njam	ram	vam	vam	am	im	em	vem	eram
ne	nje	re	ve	ve	e	i	i	vi	ere
nah	njah	rah	vah	vah	ah	ih	eh	veh	erah
nami	njami	rami	vami	vami	ami	mi	mi	vmi	erami
him-na	luk-nja	šav-ra	smokev	belitev	Argo	plavut	klet	kr-i	hč-i

21	22	23	24	25	26	27	28	29
el	em	an	en	enj	er	et	-0	a
li	mi	ni	ni	nji	ri	ti	-0	e
li	mi	ni	ni	nji	ri	ti	-0	i
el	em	an	en	enj	er	et	-0	o
li	mi	ni	ni	nji	ri	ti	-0	i
lijo	nijo	nijo	nijo	nijjo	rijo	tjo	-0	o
li	mi	ní	ní	nji	ri	ti	-0	i
li	mim	ni	ni	njima	er	et	-0	ih
lima	mima	nema	nima	njima	rima	tema	-0	ima
li	mi	ni	ni	nji	ri	tima	-0	i
lih	mih	neh	nih	njima	rih	teh	-0	ih
lima	mimi	nema	nima	njima	rima	tima	-0	ima
li	mi	ni	ni	nji	ri	ti	-0	e
li	em	ni	ni	enj	er	ti	-0	ih
lim	mim	nem	nim	njim	rim	tem	-0	im
li	mi	ni	ni	nji	ri	ti	-0	e
lih	mih	neh	nih	njih	rih	tmi	-0	ih
limi	mimi	nmi	nimi	njimi	rimi	tmi	-0	imi
mis-el	pes-em	rav-an	kaz-en	povod-enj	reb-er	lak-et	Ines	star-a

Tabela IV: Nizi samostalniških računalniških končnic srednjih sklanjatev

1	2	3	4	5	6	7	8	9	10
o	o	o	O	go	ho	ko	lo	mo	no
a	a	a	esa	žesa	šesa	česa	la	ma	na
u	u	u	esu	žesu	šesu	česu	lu	mu	nu
o	o	o	o	go	ho	ko	lo	mo	no
u	u	u	esu	žesu	šesu	česu	lu	mu	nu
om	om	om	esom	žesom	šesom	česom	lom	mom	nom
i	i	esi	esi	žesi	šesi	česi	li	mi	ni
-	i	es	es	žes	šes	čes	el	em	en
oma	ima	esoma	esoma	žesoma	šesoma	čema	loma	mima	noma
i	i	esi	esi	žesi	šesi	česi	li	mi	ni
ih	ih	esih	esih	žesih	šesih	česih	lih	mih	nih
oma	ima	esoma	esoma	žesoma	šesoma	česoma	loma	mima	noma
a	a	esa	esa	žesa	šesa	či	la	ma	na
-	i	es	es	žes	šes	čes	el	em	en
om	im	esom	esom	žesom	šesom	čem	lom	mom	nom
a	a	esa	esa	žesa	šesa	či	la	ma	na
ih	ih	esih	esih	žesih	šesih	čeh	lih	mih	nih
i	i	esi	esi	žesi	šesi	čmi	li	mi	ni
blag-o	zlo	nebo	tel-o	i-go	u-ho	o-ko	ges-lo	pis-mo	ok-no

11	12	13	14	15	16	17	18	19	20
ro	vo	e	je	lje	nje	rje	-0	-0	-0
ra	va	a	ja	lja	nja	rja	na	sa	ta
ru	vu	u	ju	lju	nju	rju	nu	su	tu
ro	vo	e	je	lje	nje	rje	-0	-0	-0
ru	vu	u	ju	lju	nju	rju	nu	su	tu
rom	vom	em	jem	ljem	njem	rjem	nom	som	tom
ri	vi	i	ji	lji	nji	rji	ni	si	ti
er	ev	-0	ij	elj	enj	erij	n	s	t
roma	voma	ema	jema	ljema	njema	rjema	noma	soma	toma
ri	vi	i	ji	lji	nji	rji	ni	si	ti
rih	vih	ih	jih	ljih	njih	rjih	nih	sih	tih
roma	voma	ema	jema	ljema	njema	rjema	noma	soma	toma
ra	va	a	ja	lja	nja	rja	na	sa	ta
er	ev	-0	ij	elj	enj	erij	n	s	t
rom	vom	em	jem	ljem	njem	rjem	nom	som	tom
ra	va	a	ja	lja	nja	rja	na	sa	ta
rih	vom	ih	jih	ljih	njih	rjih	nih	sih	tih
ri	vi	i	ji	lji	nji	rji	ni	si	ti
jed-ro	ubošt-vo	kesan-je	žret-je	dup-lje	tr-nje	ned-rje	sle-me	oje-0	revše-0

21	22	23
-0	o	je
va	ega	jega
vu	emu	jemu
-0	o	je
vu	em	jem
vom	im	jim
vi	a	ji
vov	ih	ij
voma	ima	jema
vi	i	ji
vih	ima	jih
voma	im	jema
vi	a	ja
ev	ih	ij
vom	im	jem
ve	a	ja
vih	ih	jih
vi	imi	jimi
poldne	Laško	Kozje

Naslednji nizi računalniških končnic, ki vsebujejo le po šest končnic, pripadajo množinskim samostalnikom, ki jih je v slovenščini ni niti 500. Največ je ženskih (307). Ti imajo tudi največ različnih nizov računalniških končnic (tabela VI). Najmanj množinskih samostalnikov je srednjega spola – le 30, a imajo kljub temu več različnih nizov računalniških končnic kot moški (primerjaj tabeli V in VII). Pri moških množinskih samostalnikih je dodan še niz z eno samo računalniško končnico -je (tabela V, niz 5). Ta opiše posebno obliko imenovalnika množine samostalnikov kot so *očet-je*, *mož-je*, *škof-je* itd.

Tabela V: Nizi računalniških končnic moških množinskih samostalniških sklanjatev

1	2	3	4	5
i	i	i	je	(je)
ov	ev	ih	i	-#
om	em	im	em	#
e	e	e	je	-#
ih	ih	ih	eh	-#
i	i	imi	mi	#
Žir-i	Radenc-i	domač-i	ljud-je	očet-je

Tabela VI: Nizi računalniških končnic ženskih množinskih samostalniških sklanjatev

1	2	3	4	5	6	7	8	9	10
i	i	i	e	je	le	lje	ne	re	ve
i	i	i	-0	ij	el	elj	en	er	ev
im	im	em	am	jam	lam	ljam	nam	ram	vam
i	i	i	e	je	le	lje	ne	re	ve
ih	ih	eh	ah	jah	lah	ljah	nah	rah	vah
imi	mi	mi	ami	jami	lami	ljami	nami	rami	vami
gosl-i	prs-i	san-i	man-ce	gar-je	org-le	dim-lje	os-ne	cit-re	buk-ve

Tabela VII: Nizi računalniških končnic srednjih množinskih samostalniških sklanjatev

1	2	3	4	5	6	7
a	a	a	a	la	ra	(a)
-0	-0	-0	-0	al	er	#
am	em	om	om	lom	rom	#
a	a	a	a	la	ra	#
ah	ih	ih	eh	leh	rih	#
i	i	i	mi	li	ri	emi
pljuč-a	želez-c-a	črev-a	drv-a	t-la	ned-ra	tl-a

Samostalniškim nizom končnic sledе pridevniški. Ker se morajo pridevniške sklanjatve poleg s sklonom in številom ujemati s samostalnikom tudi v spolu, bi lahko bilo v vsakem pridevniškem nizu trikrat toliko računalniških končnic kot pri samostalnikih, torej štiriinpeta deset. K sreči je v veliki večini nizov med vsemi teoretično možnimi računalniškimi končnicami le po dvanajst različnih. Zato tudi različnih nizov ni veliko: osem standardnih nizov računalniških končnic in trije nizi z eno samo, dodatno računalniško končnico (tabela VIII). Edina večja razlika med nizi končnic je pri pridevnikih na -ski in ški. Pri njih se določna in nedoločna oblika ne razlikujeta. Zato se pri teh nizih prva končnica -i ponovi na četrtem mestu (drugi nizi v tabelah VIII–X). Posebne končnice -ak, -al in -an nastopajo le pri nekaj pridevnikih, npr.: *meh-ek* (*meh-ak*), *svet-el* (*svet-al*) in *tem-en* (*tem-an*). Tem pridevnikom so poleg navadnih končnic pripisani še dodatni nizi, tako da ima npr.

pridevnik *moč-en* v računalniškem slovarju poleg niza končnic na *-en* (tabela VIII, niz 5) naveden še niz z eno samo končnico *-an* (tabela VIII, niz 11). Podobno je v vseh ostalih primerih. Če se beseda sklanja (ali sprega) na dva različna načina, ima dva niza računalniških končnic.

Pri pridevniških sklanjatvah števnikov in zaimkov je število različnih nizov še manjše. V bistvu gre pri obeh tabelah le za pet oziroma tri standardne (tabela IX, nizi 1–5 in tabela X, nizi 1–3) in za dodatne nize računalniških končnic, ki se pojavljajo samo pri izjemah (tabela IX, nizi 6–9 in tabela X, nizi 4–9). Standardni nizi števnih in zaimenskih standardnih končnic so identični s standardnimi nizi pridevniških. Identične nize imamo v različnih tabelah samo zaradi tega, da računalniški slovar razlikuje med števniki, zaimki in pridevni, ki se sicer sklanjajo z enakimi računalniškimi končnicami. S tem omogočimo, da računalnik pri analizi avtomatično sporoči, ali gre pri besedi za pridevnik, števnik ali zaimek. Deležniki v slovarju nimajo posebnih nizov računalniških končnic, ampak iste kot pridevni. V izboljšavah so predvidene posebne tabele in oznake tudi za deležnike, ki se sklanjajo kot pridevni.

Tabela VIII: Nizi pridevniških računalniških končnic za pridevni

1	2	3	4	5	6	7	8	9	10	11
-0	i	ek	el	en	ev	eljk	er	(-ak)	(-al)	(-an)
a	a	ka	la	na	va	lja	ra	-#	-#	-#
e	e	ke	le	ne	ve	lje	re	-#	-#	-#
i	i	ki	li	ni	vi	lki	ri	-#	-#	-#
o	o	ko	lo	no	vo	ljo	ro	-#	-#	-#
em	em	kem	lem	nem	vem	ljem	rem	-#	-#	-#
im	im	kim	lim	nim	vim	ljim	rim	-#	-#	-#
ih	ih	kih	lih	nih	vih	ljih	rīh	-#	-#	-#
ega	ega	kega	lega	nega	vega	ljega	regā	-#	-#	-#
emu	emu	kemu	lemu	nemu	vemu	ljemu	remu	-#	-#	-#
ima	ima	kima	lima	nima	vima	ljima	rima	-#	-#	-#
imi	imi	kimi	limi	nimi	vimi	ljimi	rimi	-#	-#	-#
blag	piransk-i	slad-ek	svet-el	moč-en	plit-ev	dup-elj	pik-er	slad-ak	svet-al	moč-an

Tabela IX: Nizi pridevniških računalniških končnic za števni

1	2	3	4	5	6	7	8	9
-0	i	en	em	-0	den	a	iјe	je
a	a	na	ma	ta	-#	e	i	i
e	e	ne	me	te	-#	eh	eh	ih
i	i	ni	mi	ti	-#	em	em	im
o	o	no	mo	to	-#	ema	ema	ima
em	em	nem	mem	tem	-#	emi	emi	imi
im	im	nim	mim	tim	-#	emima	emima	#
ih	ih	nih	mih	tih	-#	emimi	emimi	#
ega	ega	nega	mega	tega	-#	-#	-#	#
emu	emu	nemu	memu	temu	-#	-#	-#	#
ima	ima	nima	mima	tima	-#	-#	-#	#
imi	imi	nimi	mimi	timi	-#	-#	-#	#
en	prv-i	enoj-en	os-em	sto	e-den	dv-a	tr-ije	štir-je

Tabela X: Nizi pridevniških računalniških končnic za pridevniške zaimke

1	2	3	4	5	6	7	8	9
-0	i	en	do	a	le	ole	enle	es
a	a	na	a	a	ale	ale	nale	sa
e	e	ne	e	e	ele	ele	nele	se
i	i	ni	i	i	ile	ile	nile	si
o	o	no	o	o	ole	ole	nole	so
em	em	nem	om	em	emle	emle	nemle	sem
im	im	nim	im	ej	imle	ejle	nimle	sej
ih	ih	nih	ih	eh	ihle	ehle	nihle	seh
ega	ega	nega	oga	ega	egale	egale	negale	sega
emu	emu	nemu	omu	emu	emule	emule	nemule	semu
ima	ima	níma	íma	ema	ímale	emale	nímale	sema
imi	imi	ními	ími	emi	ímile	emile	nímile	semi
moj	tist-i	takb-en	nek-do	t-a	tak-le	t-ole	takš-ele	v-es

Pri zaimkih je treba omeniti še računalniški zapis sklanjatev samostalniških zaimkov. Ker večina samostalniških zaimkov sploh nima računalniške osnove (pri sklanjanju se spreminja celotna beseda, npr.: *jaz, mene; on, njega; ona, nje; mi, nas* itd., so v računalniškem slovarju oblike vseh samostalniških zaimkov navedene eksplisitno. Vsaka oblika je opisana s štirimestno kodo: s številom med 5000 in 5999. Prva cifra kodo: »5« signalizira, da je beseda samostalniški zaimek, druge tri pa povedo sklon s katerim se le-ta veže. To pomeni, da so v računalniškem slovarju kot samostojne besede posamično navedeni vsi samostalniški zaimki v vseh sklonih. Za bodočo avtomatsko besedno in stavčno analizo, čemur je opisani računalniški slovar namenjen, je zanesljivo prepoznavanje vseh oblik samostalniških zaimkov ena pomembnejših nalog.

Daleč največ različnih nizov računalniških končnic je pri glagolskih spregatvah. Med vsemi devetinosemdesetimi nizi (tabela XI) je enainosemdeset popolnih in sedem delnih. Večino popolnih nizov (75) sestavljajo končnice spregatev glagolov na *-ti*, ostanek pa šest nizov računalniških končnic spregatev glagolov na *-či*. Ostalih osem delnih nizov vsebuje računalniške končnice izjem in nepravilnosti. V popolnih nizih glagolskih spregatev je 21 različnih računalniških končnic. Poleg nedoločniške končnice (*-ti* ali *-či*) so vse končnice za tvorjenje sedanjikovih oblik (*sem, boš, bo, bova, bosta, bomo, boste, bodo/bojo*), vse oblike deležnikov prihodnika in preteklika (*-l, -la, -le, -li in -lo*), vse računalniške končnice velelnega naklona (5 računalniških končnic) in ena trpniška končnica (*-t*). Zanimivo je, da se velikanska večina glagolov sprega z natanko 21 različnimi računalniškimi končnicami in da je izjem pri tem sorazmeroma malo ne glede na to, ali je glagol pravilni ali nepravilni.

Nizi računalniških končnic so pri glagolih urejeni po nekoliko prirejenem abecednem redu in dolžini nedoločniške končnice (tabela XI). Najprej so nizi za spreganje glagolov na *-ti*. To so: *-ti, -ati, -eti, -iti, -sti, uti*, nato pa še glagoli na *-či* in *-eči*.

Zadnjih osem nizov so končnice pri spregatvah *računalniško* nepravilnih glagolov in izjem. Računalniško nepravilni glagoli so dvojni. Prvi so tisti, ki se pri spreganju spremene v **celoti** in sploh nimajo računalniške osnove, npr.: *biti* (*sem, si, je, ...*), *ne imeti* (*nimam, nimaš, ...*), *gnati* (*ženem, ženeš, ...*) in *scati* (*ščijem,*

ščiješ, ...). Drugi pa imajo alternativne spregatve brez nekaterih oblik, npr.: *iti* (*idem*, *ideš*, ...; z varianto: *grem*, *greš*, ...; in še z drugačnimi deležniki: *šel*, *šla*, ...),.

Posebnost slovenske glagolske spregatve je alternativna možnost računalniške končnice pri tretji osebi sedanjika v množini, npr. glagol *rasti*: (z oblikama *rast-ejo* in *rast-o*). Obe ti dve računalniški končnici (običajna in alternativna) nastopata v tabelah glagolskih nizov vedno na devetem in desetem mestu. Poleg glavne ima alternativno računalniško končnico 30 nizov, ostali pa ne.

Spregatvene oblike pomožnih glagolov *biti* (*sem*, *si*, *je*, *sva*, *smo*, ... *bom*, *boš*, ... *bodo* ...) in *ne biti* (*nisem*, *nisva*, *ni*, ... *niste*, ... *niso*...) so v računalniškem slovarju podane kot nepregibne besede, podobno kot samostalniški zaimki, torej vsaka oblika posebej (zadnja vrsta tabele XII).

Tabela XI: Nizi glagolskih računalniških končnic

1	2	3	4	5	6	7	8	9	10
ti	ti	ti	ti	ti	ti	ti	ti	ti	ti
m	m	m	em	dem	dem	jem	nem	tem	vem
š	š	š	eš	deš	deš	ješ	neš	teš	veš
-0	-0	-0	e	de	de	je	ne	te	ve
va	va	va	eva	deva	deva	jeva	neva	teva	veva
ta	ta	ta	eta	deta	deta	jeta	neta	teta	veta
mo	mo	mo	emo	demo	demo	jejo	nemo	temo	vemo
te	te	te	ete	dete	dete	jemo	nete	tete	vete
jo	jo	jo	ejo	dejo	dejo	jete	nejo	tejo	vejo
#	#	#	o	do	do	jo	#	to	#
I	I	I	el	del	sel	I	I	tel	I
la	la	la	la	dla	šla	la	la	la	la
le	le	le	le	dle	še	le	le	le	le
li	li	li	li	dli	šli	li	li	tli	li
lo	lo	lo	lo	dlo	šlo	lo	lo	tlo	lo
-0	j	j	i	di	di	j	ni	ti	vi
va	jva	jva	iva	diva	diva	jva	niva	tiva	viva
ta	jta	jta	ita	dita	dita	jta	nita	tita	vita
mo	jmo	jmo	imo	dimo	dimo	jmo	nimo	timo	vimo
te	jte	jte	ite	dite	dite	jte	nite	tite	vite
t	t	t	t	t	t	t	t	t	t
cepiti	tacati	dati	nesti	najti	najti	biti	vstati	rasti	pleti

11	12	13	14	15	16	17	18	19	20
ati	ati	ati	ati	ati	ati	cati	dati	dati	dati
em	em	em	im	jem	ljem	ojim	čem	m	dam
eš	eš	eš	iš	ješ	ljš	ojíš	češ	š	daš
e	e	e	i	je	lje	oji	če	-	da
eva	eva	eva	iva	jeva	ljeva	ojiva	čeva	va	dava
eta	eta	eta	ita	jeta	ljeta	ojita	četa	sta	data
emo	emo	emo	imo	jemo	ljemo	ojimo	čemo	mo	damo
ete	ete	ete	ite	jete	ljete	ojite	čete	ste	date
ejo	ejo	ejo	ijo	jejo	ljejo	ojijo	čejo	jo	dajo
o	#	#	e	#	#	oje	#	do	#
al	al	al	al	al	al	cal	dal	dal	dal
ala	ala	ala	ala	ala	ala	cala	dala	dala	dala
ale	ale	ale	ale	ale	ale	cale	dale	dale	dale
ali	ali	ali	ali	ali	ali	cali	dali	dali	dali
alo	alo	alo	alo	alo	alo	calo	dalo	dalo	dalo
-0	i	aj	i	ji	lji	oj	či	j	j
va	iva	ajva	iva	jiva	ljiva	ojva	čiva	jva	jva
ta	ita	ajta	ita	jita	ljita	ojta	čita	jta	jta
mo	imo	ajmo	imo	jimo	ljimo	ojmo	čimo	jmo	jmo
te	ite	ajte	ite	jite	ljite	ojte	čite	jte	jte
at	at	at	at	at	at	at	cat	dat	dat
sijati	žgati	majati	tičati	orati	kopati	stati	klicati	povedati	gledati

21	22	23	24	25	26	27	28	29	30
dati	gati	gnati	hati	jati	kati	skati	lati	lati	rati
jem	žem	ženem	šem	nem	čem	ščem	oljem	erem	
ješ	žeš	ženeš	šeš	neš	češ	ščeš	olješ	ereš	
je	že	žene	še	ne	če	šče	olje	ere	
jeva	ževa	ženeva	ševa	neva	čeva	ščeva	oljeva	ereva	
jeta	zeta	ženeta	šeta	neta	četa	ščeta	eljeta	ereta	
jemo	žemo	ženomo	šemo	nemo	čemo	ščemo	eljemo	eremo	
jete	žete	ženete	šete	nete	čete	ščete	eljete	erete	
jejo	žejo	ženejo	šejo	nejo	čejo	ščejo	eljejo	erijo	
#	-#	ženo	-#	-0	-#	-#	-#	-#	ero
jil	gal	gnal	hal	jal	kal	skal	lal	lal	ral
jila	gala	gnala	halal	jala	kala	skala	lala	lala	rala
jile	gale	gnale	hale	jale	kale	skale	lale	lale	rale
jili	gali	gnali	hali	jali	kali	skali	lali	lali	rali
jilo	galo	gnalo	halo	jalo	kalo	skalo	lalo	lalo	ralo
ji	ži	ženi	ši	ni	či	šči	elji	olji	eri
jiva	živa	ženiva	šiva	niva	čiva	ščiva	eljiva	oljiva	eriva
jita	žita	ženita	šita	nita	čita	ščita	eljita	oljita	erita
jimo	žimo	ženimo	šimo	nimo	čimo	ščimo	eljimo	oljimo	erimo
jite	žite	ženite	šite	nite	čite	ščite	eljite	oljite	erite
dat	gat	gnat	hat	jat	kat	skat	lat	lat	rat
glodati	trgati	gnati	pihati	dejati	jokati	iskati	stlati	klati	prati

31	32	33	34	35	36	37	38	39	40
rati	rati	sati	scati	slati	vati	vati	vati	evati	ovati
erjem	orjem	šem	ščijem	šljem	uem.	ovem	ujem	ujem	ujem
erješ	orješ	šeš	ščiješ	šljesh	ujem.	oveš	uješ	uješ	uješ
erje	orje	še	ščije	šlje	uje	ove	uje	uje	uje
erjeva	orjeva	ševa	ščijev	šljeva	uveva	uveva	uveva	uveva	uveva
erjeta	orjeta	šeta	ščijet	šljeta	ujeta	oveta	ujeta	ujeta	ujeta
erjemo	orjemo	šemo	ščijem	šljemo	ujemo	ovemo	ujemo	ujemo	ujemo
erjete	orjete	šete	ščijet	šljite	ujete	ovete	ujete	ujete	ujete
erjejo	orjejo	šejo	ščijej	šlejo	ujejo	ovejo	ujejo	ujejo	ujejo
#	-#	-#	-#	-#	-#	-#	-#	-#	-#
ral	ral	sal	scal	slal	val	val	val	eval	oval
rala	rala	sala	scala	slala	vala	valala	vala	evala	ovala
rale	rale	sale	scale	slale	vale	uale	vale	eval	ovale
rali	rali	sali	scali	slali	vali	valali	vali	evali	ovali
ralo	ralo	salo	scalo	slalo	valo	valulo	valo	evalo	ovalo
eri	orji	ši	ščij	šlji	uj	ovi	ovi	uj	uj
eriva	orjiva	šiva	ščijva	šljiva	ujva	oviva	ujva	ujta	ujva
erita	orjita	šita	ščijta	šljita	ujta	ovita	ujta	ujmo	ujta
erimo	orjimo	šimo	ščijmo	šljimo	ujmo	ovimo	ujmo	ujmo	ujmo
erite	orjite	šite	ščijte	šljite	ujte	ovite	ujte	ujte	ujte
rat	rat	sat	scat	slat	vat	vat	vat	evat	ovat
srati	prati	risati	scati	poslati	ruvati	rvati	pozvati	ločevati	Strahovati

41	42	43	44	45	46	47	48	49	50
tati	zati	eti	eti	eti	eti	eti	eti	eti	eti
čem	žem	am	em	em	im	jem	mem	amem	nem
čes	žeš	aš	eš	eš	iš	ješ	meš	ameš	neš
če	že	a	e	e	i	je	me	ame	ne
čeva	ževa	ava	eva	eva	iva	jeva	meva	ameva	neva
četa	žeta	ata	eta	eta	ita	jeta	meta	ameta	neta
čemo	žemo	amo	emo	emo	imo	jemo	memo	amemo	nemo
čete	žete	ate	ete	ete	ite	jete	mete	amete	nete
čejo	žejo	ajo	ejo	ejo	ijo	jo	mejo	amejo	nejo
#	-#	-#	-#	-#	-#	-#	-#	-#	-#
tal	zal	el	l	el	el	l	el	el	el
tala	zala	ela	la	ela	eli	la	ela	ela	ela
tale	zale	ele	le	ele	ele	le	ele	ele	ele
tali	zali	eli	li	eli	ela	li	eli	eli	eli
talo	zalo	elo	lo	elo	elo	lo	elo	elo	elo
či	ži	ej	i	i	i	ji	mi	emi	ni
čiva	živa	ejva	iva	iva	ita	jiva	miva	emiva	niva
čita	žita	ejta	ita	ita	imo	jita	mita	emita	nita
čimo	žimo	ejmo	imo	imo	ite	jimo	mimo	emimo	nimo
čite	žite	eje	ite	ite	et	jite	mite	emite	nite
tat	zat	et	et	et	et	t	et	et	et
metati	rezati	imet	zreti	uspeti	pršeti	mreti	oteti	najeti	načeti

51	52	53	54	55	56	57	58	59	60
eti	eti	eti	deti	jeti	leti	reti	reti	teti	
anem	anjem	ojem	m	mem	olnem	arem	arem	čem	
aneš	aneš	oješ	š	meš	olneš	ereš	areš	češ	
ane	anje	oje	-0	me	elje	ere	are	če	
aneva	anjeva	ojeva	va	meva	eljeva	ereva	areva	čeva	
aneta	anjeta	ojetja	sta	meta	eljeta	ereta	areta	četa	
anemo	anjemo	ojemo	mo	memo	eljemo	olnemo	aremo	čemo	
anete	anjete	ojetje	ste	mete	eljete	olnete	arete	čete	
anejo	anjejo	ojejo	jo	mejo	eljejo	olnejo	erejo	čejo	
eno	-#	ojo	do	-#	-#	ero	arejo	-#	
el	el	el	del	jel	lel	rl	rl	tel	
ela	ela	ela	dela	jela	lela	rla	rla	tela	
ele	ele	ele	dele	jele	lele	rle	rle	tele	
eli	eli	eli	deli	jeli	leli	rli	rli	teli	
elo	elo	elo	delo	jelo	lelo	rlo	rlo	telo	
ani	anji	oj	di	mi	elji	olni	ri	ri	-#
aniva	anjiva	ojava	diva	miva	eljiva	olniva	driva	rita	-#
anita	anjita	ojita	dita	mita	eljita	olnita	riva	riva	-#
animo	animo	ojmo	dimo	mimo	eljimo	olnimo	rimo	rimo	-#
anite	anjite	ojetje	dite	mite	eljite	olnite	rite	rite	-#
et	et	et	det	jet	let	ret	ret	ret	tet
meti	zeti	peti	vedeti	prijeti	mleti	klati	dreti	treti	hoteti
61	62	63	64	65	66	67	68	69	70
iti	iti	iti	jti	sti	sti	sti	sti	sti	
em	im	idem	jdem	m	em	dem	dem	tem	
eš	iš	ideš	jdeš	š	eš	deš	deš	teš	
e	i	ide	jde	-0	e	de	de	te	
eva	iva	ideva	jdeva	va	eva	deva	deva	teva	
eta	ita	ideta	jmeta	sta	eta	deta	deta	teta	
emo	imo	idemo	jdemo	mo	emo	demo	demo	temo	
ete	ite	idete	jekte	ste	ete	dete	dete	tete	
ejo	ijo	idejo	jdejo	do	ejo	dejo	dejo	tejo	
#	-#	-#	-#	jo	-#	-#	-#	-#	to
il	il	šel	šel	del	el	l	del	tel	
ila	ila	šla	šla	dla	la	la	dla	tla	
ile	ile	še	še	dle	le	le	dle	tle	
ili	ili	šli	šli	dli	li	li	dli	tli	
ilo	ilo	šlo	šlo	dlo	lo	lo	dlo	tlo	
i	i	idi	jdi	jdi	j	i	di	ti	
iva	iva	idiva	jdiva	jdiva	jva	iva	diva	tiva	
ita	ita	idita	jdita	jdiva	jta	ita	dita	tita	
imo	imo	idimo	jdimo	jdimo	jmo	imo	dimo	timo	
ite	ite	idite	jdite	jdite	jte	ite	dite	tite	
it	it	it	it	st	st	st	st	st	
crkniti	gubiti	zaiti	zaiti	najti	jesti	tepsti	krasti	mesti	mesti
71	72	73	74	75	76	77	78	79	80
sti	lesti	uti	uti	uti	či	či	či	či	
zem	olzem	mem	ovem	pem	čem	rem	rem	žem	
zeš	olzeš	meš	oveš	peš	češ	reš	reš	žeš	
ze	olze	me	ove	pe	če	re	re	že	
zeva	olzeva	meva	oveva	peva	čeva	reva	reva	ževa	
zeta	olzeta	meta	oveta	peta	četa	reta	reta	žeta	
zemo	olzemo	memo	ovemo	pemo	čemo	remo	remo	žemo	
zete	olzete	met	ovete	pete	čete	rete	rete	žete	
zejø	olzejo	mejo	ovejo	pejo	čejo	reje	reje	žejø	
#	-#	me	-#	po	ko	-#	-#	-#	
zel	olzel	mel	ul	spel	kel	gel	gel	gel	
zla	olzla	mela	ula	pela	kla	gla	gla	gla	
zle	olzle	mele	ule	pele	kle	gle	gle	gle	
zli	olzli	meli	uli	pel	kli	gli	gli	gli	
zlo	olzlo	melo	ulo	peло	klo	glo	glo	glo	
zi	olzi	mi	uj	pi	ci	zi	-#	zi	
ziva	olziva	miva	ujva	piva	civa	ziva	-#	ziva	
zita	olzita	mítia	újta	pita	cita	zita	-#	zita	
zimo	olzimo	mimo	újmo	pimo	címo	zimo	-#	zimo	
zite	olzite	mítie	újte	píte	cíte	zite	-#	zite	
st	lest	mít	út	ut	ć	ć	ć	ć	
gristi	mlesti	duti	pluti	vsuti	teći	pomoći	zmoći	vpreči	leči

81	82	83	84	85	86	87	88	89
eči	(eči)	(či)	iti	(iti)(em)	(ti)	(ti)	(ti)	#
žem	#	#	om	m	em	m	#	#
žeš	#	#	oš	š	eš	š	#	#
že	#	#	o	-0	e	-	#	#
ževa	#	#	ova	va	eva	va	#	#
žeta	#	#	osta	sta	eta	ta	#	#
žemo	#	#	omo	mo	emo	mo	#	#
žete	#	#	oste	ste	ete	te	#	#
žejo	#	#	odo	do	ejo	jo	#	#
#	#	#	il	jo	o	#	#	#
gel	#	#	ila	#	#	#	-l	el
gla	#	#	ile	#	#	#	-la	la
gle	#	#	ili	#	#	#	-le	le
gli	#	#	ilo	#	#	#	-li	li
glo	#	#	odem	#	#	#	-lo	lo
zi	zi	či	odeš	#	i	#	#	#
ziva	živa	čiva	odiva	#	iva	#	#	#
zimo	žita	čita	odita	#	ita	#	#	#
zita	žimo	čimo	odimo	#	imo	#	#	#
zite	žite	čite	odite	#	ite	#	#	#
eč	eč	č	it	#	it	#	t	#
vreči	vreči	teči	biti	iti grem	iti pojdem	ne imeti	gnati	iti šel

Nepregibne besedne vrste

Vse ostale slovarske besede ali gesla so nepregibna in zato v računalniškem slovarju nimajo niza končnic. Nepregibne besede so označene s števili, ki povedo besedno vrsto. Oznake nepregibnih vrst so podane v tabeli XII.

Tabela XII: Oznake nepregibnih besed v računalniškem slovarju. Oznaka sklona je označena z drugo do četrto cifro kode. Za kombinacije več kot treh sklonov se uporablja več oznak. Pri predlogih pomeni oznaka sklona s katerim sklonom se vežejo.

	Dodatni kriterij	Oznaka	Oznaka	Oznaka
Prislovi	krajevni časovni vzročni načinovni	2001 2002 2003 2004		
		Predlogi	Sam. zaimki	Pom. glag.
	1. sklon 2. sklon 3. sklon 4. sklon 5. sklon 6. sklon 2 in 5. sklon 2., 4., 6. sklon	3001 3002 3003 3004 3005 3006 3025 3246	5001 5002 5003 5004 5005 5006 5025 5246	9001 9002 9003 9004 9005 9006 9025 9246
Vezniki Kratice in tujke Medmeti Členki		4000 6000 7000 8000		

V računalniškem slovarju je zbranih nekaj več kot 156.000 računalniških osnov in nepregibnih gesel. Vsa gesla omogočajo računalniku, da s pomočjo računalniških

končnic prepozna približno 2 milijona različnih besednih oblik. Tabela XIII kaže podroben pregled vsebine računalniškega slovarja.

Na tem mestu je možna krajsa primerjava z gesli SSKJ, ki jih opisuje Jakopin (1995) in pregled, kje bi se dalo z združitvijo obeh korpusov pridobiti. Oba slovarja se dokaj dobro pokriva, do večjih razlik pride le pri pridevnikih, ki jih je v računalniškem slovarju precej več kot v SSKJ (70.000 proti 21.000). Vzrok je v tem, da ima v računalniškem slovarju skoraj vsak samostalnik tudi pridevniško obliko. Pri samostalnikih ima računalniški slovar približno 60.000 besed, SSKJ pa 51.500. Razlika v prid računalniškega slovarja gre na račun pomanjševalnic in ženskih oblik, ki jih SSKJ nima toliko. Glagolov pa ima SSKJ skoraj 2000 več kot računalniški slovar (16.479 proti 14.760). Menim, da gre razlika največ na račun različnih predpon. Ostale besedne vrste, ki so v glavnem nepregibne, so bistveno manj številčne in so zaradi tega tudi razlike precej manjše.

Glavna razlika med SSKJ v računalniški obliki in med računalniškim slovarjem, opisanim v tem delu, ni v številu obdelanih gesel, ampak v tem, da ima pričajoči slovar pri vsakem geslu implicitno (preko enega od ustreznih 240 nizov končnic) podane vse možne sklanjatvene ali spregatvene oblike gesla.

Tabela XIII: Število posameznih gesel in približno število pregibnih oblik, ki jih prepozna računalnik.

Besedna vrsta	Število besed v slovarju	Povprečno št. različnih računalniških končnic v enem nizu	Približno št. besednih oblik, ki jih prepozna računalniški slovar
samostalniki:			
moški	23.148	9	364.000
ženski	26.686	9	240.000
srednji	12.246	8	98.000
množinski	475	5	2.400
pridevniške besede	72.872	12	875.000
glagoli	14.760	21	310.000
prislovi	5.199		
predlogi	76		
vezniki	52		
samostalniški zaimki	207		
kratice in tujke	79		Vseh nepregibnih besed cca 6.000
medmeti	255		
členki	25		
pom. glagolske oblike	58		
Skupaj	156.138		1,895.400

Dva primera uporabe slovarja z računalniškimi osnovami in nizi končnic

Opisani računalniški slovar se da uspešno uporabiti pri raziskavah različnih slovenskih besedil. Žal ročnega dela tak slovar zaenkrat še ne zmore nadomestiti. Da opravi svojo nalogu, mora računalnik pri vsaki besedi preiskovanega besedila:

1. poiskati vse možne računalniške osnove in končnice te besede,
2. poiskati vse možne nize končnic, ki pripadajo vsaki možni osnovi in

3. kombinirati vse končnice preiskovane besede z vsemi končnicami možnih nizov.

Program mora upoštevati več različnih situacij. V splošnem velja zahteva, da mora biti kombinacija računalniške osnove in računalniške končnice iz ustreznega niza enaka preiskovani besedni obliku. Če tako kombinacijo najde, je to veljavno geslo. V primeru, ko nobena kombinacija ne ustreza preiskovani besedi, jo računalnik proglaši za »neznano«. V primeru, da je ustreznih kombinacij več, je dana beseda lahko nastala iz različnih slovarskih gesel. Ta primer, ki še ni rešen, je za nadaljnji razvoj avtomatične besedne in kasneje tudi stavčne analize najbolj zanimiv, predstavlja glavno smer nadaljnjega razvoja.

Kot prvi primer bom opisal, kako program, ko sreča besedo *bral*, ugotovi, da gre za glagolsko besedo *brati* in hkrati še, da je to njegov deležnik. Program najprej razstavi besedo *bral* na vse možne računalniške osnove in končnice. Te možnosti so štiri:

bral + -0 *bra* + -l *br* + -al in *b* + -ral

Nato pogleda, če so te štiri osnove v slovarju in kateri nizi računalniških končnic so pripisani k vsaki osnovi. Ob osnovah najde program v slovarju naslednje nize končnic:

- ob osnovi *bral*- dva niza:

samostalniški, tabela II, 12. niz – končnice	-ec, -ca, -cu, -ec itd.,
pridevniški, tabela VIII, 5. niz – končnice	-en, -na, -ne, -ni itd.,
- ob osnovah *bra*- *br*- v slovarju ni nobenega niza,
- ob osnovi *b*- so trije nizi:

glagolski, tabela XI, 17. niz: končnice	-ati, -ojim, -ojiš itd.,
glagolski, tabela XI, 30. niz: končnice	-rati, -erem- ereš itd. in
glagolski, tabela XI, 84. niz: končnice	-iti, -om, -oš itd.

V sklepni fazi program kombinira vse osnove in pripadajoče končnice. Pri prvi osnovi *bral* računalnik ugotovi, da niti prvi niti drugi niz ne vsebuje končnice (-0), kar pomeni, da gesli *bral-ec* in *bral-en* ne dasta kombinacije *bral-0*. Zato računalnik pravilno odloči, da beseda *bral* ni samostojno geslo. Ker druga in tretja osnova (*bra*- in *br*-) nimata pridruženega nobenega niza, program ti dve osnovi izpusti. Med preverjanjem zadnjih treh nizov glagolskih končnic (pri osnovi *b*-) ugotovi, da ustreza le drugi niz, ki ima v 11 vrstici končnico *-ral*. Ta končnica da skupaj z osnovo *b*- pravilno vhodno besedo *b-ral*.

Zato da dobi slovarsko geslo, mora program povezati računalniško osnovo *b*- s končnico na prvem mestu 30. glagolskega niza, kar da iskano geslo: *b-rati*. Ker so končnice istih sklonov ali istih spregatvenih oblik v nizih vendno na istih mestih, je enajsto mesto, na kateri se nahaja računalniška končnica *-ral*, hkrati tudi podatek, da gre za deležnik preteklega (ali prihodnjega časa) v moški edminske oblike (torej: *sem*, *si*, *je*, *bom*, *boš*, *bo* ali *bi* *bral*). Točna določitev časa je možna le v kombinaciji z opredelitvijo pomožnega glagola, ki ga računalniški slovar določi pred tem.

Drugi primer uporabe računalniškega slovarja, sestavljenega iz računalniških osnov in pripadajočih nizov računalniških končnic, je iskanje konkordanc.

Če želimo na primer izvedeti, kam in kako je pesnik Janez Menart vtkal v svojo poezijo (Menart 1960; 1963; 1990) besedo *sreča*, moramo med njegovimi verzi poiskati vse t. i. konkordance gesla *sreča*. To storimo tako, da vpišemo zahtevano geslo v imenovalniku ednine. Program iz vpisanega gesla avtomatično sestavi s pomočjo računalniških končnic seznam devetih možnih besed z osnovo *sreč-* (v prvem nizu tabele III je devet različnih končnc) in z njimi primerja vsako besedo pesnikovih poezij. Predlog, da bi se dalo isto delo opraviti z navadnim iskanjem v urejevalniku besedil, je dober le navidezno. Če bi namreč iskali po besedilu samo z računalniško osnovo *sreč-*, bi dobili tudi veliko zvez (konkordanc) s povsem drugimi besedami, kot so: *srečanje, srečnež, srečnik, srečnica, srečka, srečolov, srečen, srečati, srečanje, srečevati, srečavati, srečevanje, srečavanje* in vse njihove izpeljanke.

Kot je pozoren bralec lahko ugotovil iz vseh konkordanc v tabeli XIV, se je nekaj podobnega primerilo tudi našemu računalniškemu slovarju. V Menartovi pesmi *Tristan in Izolda* (šesti primer) je računalnik našel konkordanco besede *srečati* in ne besede *sreča*. Takih napak je pri pravilni uporabi računalniškega slovarja malo in jih zato z lahkoto poiščemo, odstranimo ali prenestimo na ustrezno mesto.

Tabela XV: Vse konkordance besede *sreča*, ki jih je računalniški program našel v 32.000 besed obsegajočem korpusu delčka Menartovih poezij (1960; 1963; 1990)

Naslov pesmi		Poznal ni	sreče	ne gorja: ostale so noči brez
Parizina			sreča	in je beda, so rojstva
Anno Domini	Tam zunaj je življeneje, je	sreča		
Topoli	Rjoveli smo od	sreče,	streljali, tolkli, klali	
Pogreb	ji vzela je življenje, odnesla	srečo	let... Ne misli nanjo	
Jesenski dan	poslušal o junaku, ki je	srečo	šel iskat.	
Tristan in Izolda	boš oči zaprla in	sreča	me prijatelj	
Poetska	sem ga potresal, žal za	srečo,	da sem v kaj verjal	
Nežnost v mraku	blodi mehka bolečina, ki ji	sreča	je ime, ki zaljubljence	
Pričakovanje	in vse se staplja v	srečo:	to je ona.	
Pričakovanje	bohoti se in peni in ko že	sreča	skoraj zakipi	
Otrok	srčeca drobni trepet kmalu te v	sreči	začudi, potlej se odebelim	
Pesnik se popravi	napis vklesan: umrl je od	sreče.	Star sto let.	
Pesnik se popravi	v zgodovino kot vzorec	sreče	za vso domovino.	

Zaključek

Možnosti uporabe računalniškega slovarja so velike. Dobro lahko služi pri večini slovničnih obdelav slovenskih besedil. Posebej je treba poudariti, da mora kljub avtomatizaciji precejšen odstotek dela še vedno opraviti jezikoslovec sam.

Opisani računalniški slovar je seveda potreben še izpopolnjevanja, dopolnjevanja morda boljše sistematike in prevsem preverjanja in popravljanja napak. V delu, ki obsega preko 150,000 ročno vnešenih opredelitev gesel (besedne analize in določitve pravilnega niza računalniških končnic), seveda ne moremo pričakovati, da bi bilo povsem brez napak.



LITERATURA

- P. JAKOPIN, 1995: Nekaj številk iz Slovarja slovenskega knjižnega jezika. *Slavistična revija* 43/3. 341–375.
- P. JAKOPIN, A. BIZJAK, 1997: O strojno podprtrem oblikoslovnem označevanju slovenskega besedila. *Slavistična revija* 47/3–4. 451–580.
- R. L. LENČEK, 1982: *The Structure and History of the Slovene Language*. New York: Columbia.
- J. MENART, 1960: *Parizina*. Ljubljana: DZS.
- 1963: *Semafori mladosti*. Ljubljana: DZS.
- 1990: *Srednjeveške pridige in balade*. Ljubljana: CZ.
- M. POPOVIČ, P. WILLET, 1990: Processing of Documents and Queries in a Slovene Language Free Text Retrieval System. *Literary and Linguistic Comp.* 5/2. 182–190.
- SS – *Slovenski pravopis*, 1962 Ljubljana: DZS.
- J. TOPORIŠIČ, 1975: Main Characteristics of the Slovene Languge. D. Komac, R. Škerlj: *Angleško-slovenski in slovensko-angleški slovar*. Ljubljana: CZ.
- 1984: *Slovenska slovница*. Maribor: Obzorja.
- 1994: *Slovenski jezik in sporočanje*. Maribor: Obzorja.
- J. ZUPAN, 1991: Slonček, program za geslenje slovenskega teksta. *Informatica* 3. 15–21.
- J. ZUPAN, 1999: The Application of Neural Networks in Linguistics. *Lecture Note on Physics*. Vol. 522. Eds. J. W. Clark, T. Lindenau, M. L. Ristig. Berlin: Springer. 1999, 224–241.
- F. ŽAGAR, 1991: *Slovenska slovница in jezikovna vadmica*. Maribor: Obzorja.