



## ZAKLJUČNO POROČILO RAZISKOVALNEGA PROJEKTA

### A. PODATKI O RAZISKOVALNEM PROJEKTU

#### 1. Osnovni podatki o raziskovalnem projektu

<b>Šifra projekta</b>	Z6-3668
<b>Naslov projekta</b>	Jezikovno-neodvisne metode za avtomatsko gradnjo semantičnih leksikonov s pomočjo primerljivih korpusov
<b>Vodja projekta</b>	26294 Darja Fišer
<b>Tip projekta</b>	Zt Podoktorski projekt - temeljni
<b>Obseg raziskovalnih ur</b>	3400
<b>Cenovni razred</b>	A
<b>Trajanje projekta</b>	05.2010 - 04.2012
<b>Nosilna raziskovalna organizacija</b>	581 Univerza v Ljubljani, Filozofska fakulteta
<b>Raziskovalne organizacije - soizvajalke</b>	
<b>Raziskovalno področje po šifrantu ARRS</b>	6 HUMANISTIKA 6.05 Jezikoslovje
<b>Družbeno-ekonomski cilj</b>	13.06 Humanistične vede - RiR financiran iz drugih virov (ne iz SUF)

#### 2. Raziskovalno področje po šifrantu FOS<sup>1</sup>

<b>Šifra</b>	6.02
<b>- Veda</b>	6 Humanistične vede
<b>- Področje</b>	6.02 Jeziki in književnost

### B. REZULTATI IN DOSEŽKI RAZISKOVALNEGA PROJEKTA

#### 3. Povzetek raziskovalnega projekta<sup>2</sup>

SLO

V okviru podoktorske raziskave smo preizkusili pristope avtomatskega luščenja prevodnih ustreznic iz besedil, ki niso vzporedna (izvirnik in prevod), temveč zgolj primerljiva (podobna tema, čas objave, komunikacijski namen). Primerljivi korupsi postajajo vse bolj priljubljen vir jezikovnega znanja, saj jih je z razvojem vsebin na svetovnem spletu vse lažje zbirati, predvsem

pa je primerljivih vsebin na voljo veliko več kot vzporednih, še posebej za jezikovne kombinacije s slovenščino. Raziskava je temeljila na predpostavki, da se besede v izvornem jeziku pojavljajo v podobnih kontekstih kot njihovi prevodi v ciljnem jeziku. Iskanje besed z najbolj podobnimi konteksti smo izvedli tako, da smo za vse besede v izvornem in cilnjem delu korpusa izdelali kontekstne vektorje na podlagi sobesedila, v katerem se pojavljajo. Nato smo s pomočjo dvojezičnega slovarja izvirne kontekstne vektorje prevedli v ciljni jezik in jih primerjali s ciljnimi kontekstnimi vektorji. Vektor tiste besede, ki je v tovrstni primerjavi dobil najboljši rezultat, smo obravnavali kot najverjetnejši prevod besede v izvirniku, saj so si njuni kontekstni vektorji najbolj podobni.

Kolikor nam je znano, raziskav na primerljivih korpusih na področju slovenske leksikalne semantične še ni opravljenih, zato zaključen projekt nedvomno predstavlja pomemben mejnik v slovenskih korpusnih, pa tudi jezikovnotehnoloških raziskavah. Ne samo, da je rezultat projekta utemeljena, preizkušena in jezikovno neodvisna metodologija luščenja prevodnih ustreznic iz primerljivih korpusov, je zaključen projekt prinesel tudi oprijemljive rezultate v obliki semantičnega leksikona sloWNet, ki je poravnal z wordneti za številne druge jezike in tako uporaben za eno- in večjezične računalniške aplikacije. V okviru projekta smo razvili tudi orodje sloWTool za pregledovanje, popravljanje in vizualizacijo wordnetov in orodje sloWCrowd za reševanje leksikalno-semantičnih nalog s pomočjo izkoriščanja množic. Vsi jezikovni viri in orodja, ki so bili razviti v okviru projekta, so objavljeni in javno dostopni v raziskovalne namene pod licenco Creative Commons: <http://nl.ijs.si/slownet/>. Izdelani viri in orodja s tem zapolnjujejo vrzel v jezikovnih virih za slovenščino in postavljajo temelje za širšo, semantično obogateno izrabo slovenskih korpusnih virov (Fišer 2012).

ANG

The main goal of the postdoctoral project was to test and develop approaches to automatic extraction of translation equivalents from texts which are not parallel (original and its translation) but comparable (similar topic, time of publication, communicative purpose). Comparable corpora have become an increasingly popular source of linguistic knowledge because they are much easier to compile directly from the web than parallel corpora, and because many existing monolingual corpora can be used as (weakly) comparable data. The research was based on the premise that words in the source language appear in similar contexts than its translations in the target language. Words with the most similar contexts across languages were identified by constructing context vectors for all the words in the source corpus and all the words in the target corpus. Next, all context vector features in the source language were translated into the the target languages with a seed dictionary, after which the translated source context vectors were compared to the target context vectors. The target word with the most similar context vector for a given source word was considered as its most likely translation equivalent.

To my knowledge, there has been no previous research into comparable corpora in the field of Slovene lexical semantics. This is why the postdoctoral project presents an important milestone in Slovene corpus linguistics as well as human language technologies. Not only is the result of the project be an established, tested and language-independent methodology for the extraction of translation equivalents from comparable corpora; the project has also brought a highly palpable result in the form of a Slovene semantic lexicon that is aligned to wordnets in many other languages and therefore useful for mono- as well as multilingual applications. In this way, the developed wordnet has significantly narrowed the gap in the field of Slovene language resources and has provided the foundations for a broader, semantically-enriched exploitation of Slovene corpus resources.

#### **4. Poročilo o realizacijs predloženega programa dela na raziskovalnem projektu<sup>3</sup>**

Podoktorska raziskava je bila sestavljena iz več faz:

(1) Izdelava primerljivega korpusa

V okviru projekta smo uporabili dva primerljiva korpusa, enega strokovnega, drugega pa splošnejšega v štirih jezikih. Prvi korpus je bil izdelan iz spletnih enciklopedij Wikipedija za slovenščino, angleščino, francoščino in hrvaščino. Kot drugi primerljivi korpus pa smo uporabili zdravstveni podkorpus, ki je bil izdelan iz spletnega korpusa za iste 4 jezike. slWac in hrWac sta bila pridobljena s svetovnega spletja s spletno domeno .si oziroma .hr, lematizirana in oblikoskladenjsko označena (Ljubešić in Erjavec 2011). Angleški ukWac in francoski frWac sta bila razvita v okviru iniciative Wacky (Baroni idr. 2009) in sta prosto dostopna za raziskovalne

namene. V zdravstveni podkorpusu so bila zajeta vsa besedila, ki so vključena v te spletne korpusse in so bila objavljena v revijah o zdravju in zdravem načinu življenja oz. so jim glede na jezikovni model, ki je bil na podlagi zdravstvenih člankov zgrajen, dovolj podobna (Fišer idr. 2011).

(2) Izdelava izhodiščnega leksikona

Za izhodiščne dvojezične leksikone, ki so pri raziskavi potrebni za prevajanje kontekstnih vektorjev, smo preizkusili več variant. Uporabili smo leksikone, zgrajene na podlagi prosto dostopnega spletnega slovarja Wiktionary, pa tudi avtomatsko izdelana leksikona za angleško-slovenski in angleško-francoski jezikovni par, ki smo ju izluščili iz besedno poravnanih vzporednih korpusov iz prejšnjih raziskav (Apidianaki idr. 2012). Ker vzporedni korpus za hrvaško-slovenski jezikovni par ni bil na voljo, smo leksikon zanj avtomatsko izluščili iz identičnih besed in sorodnic med jezikoma, ki smo ju našli v primerljivih korpusih (Fišer in Ljubešić 2011).

(3) Gradnja in primerjava kontekstnih vektorjev

Za gradnjo vektorjev smo preizkusili več statističnih mer, kot najboljši pa se je izkazal logaritem verjetnosti. Za primerjavo vektorjev smo prav tako preizkusili različne statistične mere, pri čemer je v eksperimentih najboljše rezultate dosegla divergenca Jensen-Shannon (Ljubešić idr. 2011). Sistem za vse jezikovne pare deluje za enobesedne izraze brez upoštevanja večpomenskisti, na paru angleščina-slovenščina pa smo razvili tudi pristop za večpomenske besede (Fišer idr. 2012, Apidianaki idr. 2012) ter pokazala, da luščenje po enakem principu deluje tudi za večbesedne terimne (Ljubešić et al. 2012). Posebnost uporabljenega pristopa za luščenje prevodnih ustreznic za jezikovni par slovenščina-hrvaščina je v tem, da za razliko od ostalih jezikovnih parov v tem primeru za prevajanje kontekstnih vektorjev nismo uporabili nobenega izhodiščnega slovarja, temveč smo izkoristili podobnosti med jezikoma in se naslonili zgolj na ortografsko identične besede in sorodnice, ki se pojavljajo v korpusih za oba jezika (Fišer in Ljubešić 2011). S tem je pristop postal povsem neodvisen od katerega koli zunanjega vira znanja, kar je za številne jezikovne pare zelo atraktivno, saj obsežni dvojezični slovarski viri za večino jezikov še vedno niso na voljo za raziskovalne namene.

(4) Luščenje definicij in semantično povezanih besed

Za potrebe slovenskega wordneta smo preizkusili tudi luščenje definicij in semantično povezanih besed iz korpusov, v katerih smo s pomočjo leksiko-semantičnih besedilnih vzorcev v tekočih besedilih prepoznali potencialne definicijske stavke, te pa nato s pomočjo orodja za strojno učenje Weka klasificirali kot prave definicije oz. kot nedefinicije (Fišer idr. 2011).

(5) Identifikacija lažnih prijateljev

Z upoštevanjem osnovne predpostavke distribucijске semantike, ki se glasi, da se besede s podobnim pomenom v različnih jezikih pojavljajo v podobnih kontekstih, ni mogoče avtomatsko identificirati zgolj prevodnih ustreznic, temveč tudi lažne prijatelje, ki so si na videz sicer zelo podobni, vendar so njihove korpusne frekvence in kontekstni vektorji zelo različni. S tem smo pravzaprav razvili učinkovito metodo za avtomatsko prepoznavanje lažnih prijateljev, ki je zelo koristna za jezikovnotehnološke aplikacije, pa tudi v leksikografiji in pri poučevanju tujih jezikov (Fišer in Ljubešić, v tisku).

(6) Vrednotenje rezultatov

Avtomatsko vrednotenje rezultatov je bilo opravljeno s pomočjo zlatih standardov, ki smo jih pripravili za vsak jezikovni par posebej, in sicer tako, da smo iz tradicionalnih slovarskih virov izbrali določeno število naključnih slovarskih vnosov ter nato primerjali, ali se prevodne ustreznice, pridobljene s pristopi, ki smo jih razvili v raziskavi, ujemajo s slovarskimi. Merili smo natančnost, priklic in f-mero. Za vse jezikovne pare, tipe korpusov in eksperimentalne nastavitev smo dosegli najboljše rezultate za samostalnike, ki z najboljšimi parametri celo presega 80 %.

Najvišjo stopnjo izboljšanja smo dosegli z razširtvami avtomatsko izluščenega slovensko-hrvaškega leksikona, na splošno pa najboljše rezultate daje luščenje angleško-slovenskih prevodnih ustreznic iz obsežnih spletnih primerljivih korpusov z uporabo izhodiščnega slovarja, minimalno frekvenco 50 za prevajane besede, logaritmom verjetnosti za gradnjo ter divergenco Jensen-Shannon za primerjavo kontekstnih vektorjev.

Ročno vrednotenje rezultatov smo opravili na naključno izbranem vzorcu prevodnih ustreznic, kjer smo poleg vrednotenja ustreznosti izluščene prevodne ustreznice opravili še klasifikacijo in kvalitativno analizo napak ter identificirali največje pomanjkljivosti uporabljenega pristopa ter možnosti za izboljšave. Rezultati ročnega vrednotenja kažejo, da se najbolje odrežejo konkretni samostalniki, za katere je mogoče pridobiti zadostno količino sobesedila. Slabše se odrežejo abstraktni samostalniki in pridevniki, ki v besedilih pogosto nimajo stabilnega konteksta. Zanimiva ugotovitev ročnega vrednotenja rezultatov je ta, da se med napačnimi prevodnimi

ustreznicami nikoli ne ponavljajo povsem nepovezani kandidati, temveč so s pravilnim vsi v tesni semantični povezavi (nadpomenke, podpomenke, kohiponimi, protipomenke), kar pomeni, da primerjava kontekstnih vektorjev pravzaprav zelo dobro deluje in je uporabna tudi za iskanje elementov določenega pomenskega polja.

Vrednotenje rezultatov s pomočjo aplikacije pa smo izvedli s pomočjo avtomatskega razreševanja večpomenskosti s pomočjo izdelanega wordneta, rezultate pa nato uporabili za izboljšanje strojnega prevajanja večpomenskih besed v prevajalnikih GoogleTranslate in Presis (Vintar idr. 2012). Rezultati vrednotenja z aplikacijo UKB (Agirre in Soroa 2009) so pokazali, da je s pomočjo pravilno razdvoumljenih večpomenskih izvirnih besed v obeh jezikovnih smereh mogoče dobiti boljše prevode, kot jih predlaga Presis, v nekoliko manjši meri pa tudi GoogleTranslate.

Izdelan wordnet smo skušali ovrednotiti s pomočjo ročnega semantičnega označevanja vzporednega korpusa SPOOK (Fišer in Bizjak 2012). Z raziskavo smo skušali ugotoviti, v kolikšni meri slovenski wordnet, ki je bil izdelan na podlagi angleškega, pokriva besedišče iz korpusa, ter ali je uporaben za označevanje pomenov besed različnih zvrsteh literarnih besedil. Ugotovili smo, da je v sloWNetu pogosto besedišče odlično zastopano, redkejše pa je v veliki meri še potrebno vanj dodati. Prav tako smo opazili, da se pri semantičnem označevanju enega dela vzporednega korpusa pojmi ohranijo tudi v prevodu in da s semantičnim označevanjem ni večjih težav, s čimer potrjujemo utemeljenost metodologije, ki je temeljila na prevajanju tujejezičnega leksikalnega vira v slovenščino. Pri tem pa je potrebno poudariti, da moramo slovenske kulturno-specifične pojme, ki v tako nastali semantični mreži zaenkrat manjkajo, čim prej dodati neodvisno od angleškega vira, ki nam je služil kot iztočnica za izdelavo sloWNeta.

#### (7) Primerjava slovenskega wordneta z drugimi leksikalnimi viri

Izdelan wordnet smo s sodelavci projekta Sporazumevanje v slovenskem jeziku na vzorčnem naboru besedišča primerjali in povezali s Slovensko leksikalno bazo, s čimer smo wordnet obogatili s kolokacijami in skladenjskimi informacijami, v leksikalno bazo pa nadgradili s semantičnimi relacijami in angleškimi prevodnimi ustreznicami (Fišer idr. 2012). Izdelan wordnet smo prav tako primerjali s semantično mrežo, ki bi jo dobili, če bi za izdelavo uporabili izključno jezikovne podatke iz slovenskega referenčnega korpusa, ne pa tudi angleškega wordneta in večjezičnih virov, na podlagi katerih smo iskali slovenske ustreznice (Fišer idr. 2012). Pri tem smo sodelovali s sodelavci Politehniko v Wrocławu, ki so na ta način razvili poljski wordnet. Ugotavljamo, da je pristop zelo koristen predvsem za razširitev obstoječega wordneta, saj je z uporabljenim metodo na podlagi korpusnih podatkov mogoče najti najverjetnejše mesto v semantični mreži, kamor se uvršča nova beseda, ki je doslej v wordnetu ni bilo.

#### (8) Vizualizacija rezultatov

Za lažjo uporabo razvitega wordneta za slovenščino smo s sodelavci z Univerze v Mariboru razvili specializiran brskalnik po semantičnem leksikonu sloWTool (Fišer in Novak 2011), ki omogoča eno- in večjezično iskanje, iskanje po posameznih poljih, megleno iskanje in sledenje semantičnim relacijam. sloWTool je kot brskalnik, pa tudi celotna programska koda zanj, prosto dostopen na spletu: <http://nl.ijs.si/slowtool/>. Poleg brskalnika sloWTool omogoča tudi popravljanje in dodajanje sinsetov ter vizualizacijo, ki s pomočjo hiperboličnih grafov besede v wordnetu prikazujejo kot vozlišča, semantične relacije med njimi pa kot povezave med njimi. V sloWTool so integrirane tudi številne podatkovne zbirke, ki so jih razvili na drugih inštitucijah, kot so: področne oznake za sinsete WordNet Domains (Bentivogli idr. 2004), splošna vrhnja ontologija pojmov SUMO/MILO (Niles in Pease 2001), gruče pomenov (Navigli 2006) in povezava na galerijo ImageNet (Deng idr. 2009). Poleg slovenskega in angleškega wordneta so v istem brskalniku na našem strežniku na voljo tudi francoski, poljski in japonski wordnet, v prihodnje nameravamo dodati tudi wordnete za druge jezike, ki so prosto dostopni za raziskovalne namene.

#### (9) Validacija rezultatov

Za vrednotenje rezultatov, dobljenih s preizkušenimi pristopi za luščenje prevodnih ustreznic iz heterogenih večjezičnih virov, ki niso nujno vzporedni, smo s sodelavci z Inštituta Jožef Stefan razvili orodje sloWCrowd (Tavčar idr. 2012), ki je namenjen validaciji pravilno izluščenih prevodnih ustreznic oz. izločanju napak v avtomatsko generiranih semantičnih leksikonih. Orodje je je zasnovano tako, da odgovore za problematične literale omogoča zbirati iz široke množice uporabnikov. Orodje je prosto dostopno in temelji na razširjenih tehologijah, kot sta PHP in MySQL. Sestavljata ga administratorski in uporabniški vmesnik. V administratorskem vmesniku izdelamo projekt, sledimo poteku projekta in izvažamo rezultate, v uporabniškem vmesniku pa reševalci glasujejo o (ne)pravilnosti naključno izbranih literalov. Rezultati prvega eksperimenta, ki smo ga izvedli z orodjem sloWCrowd, so spodbudni, saj so bili uporabniki orodja z njim zadovoljni, odločitev o dokončnem izbrisu nekega literala na podlagi ujemanja njihovih

odgovorov pa enostavna, hitra in zanesljiva. Dodatna prednost razvitega orodja je, da ga je mogoče prilagoditi za najrazličnejše naloge, pri katerih je koristno sodelovanje večjega števila reševalcev. Orodje je prosto dostopno na spletu: <http://nl.ijs.si/slowcrowd/>. (Zaradi prostorskih omejitev je seznam bibliografije v pripomki.)

## **5.Ocena stopnje realizacije programa dela na raziskovalnem projektu in zastavljenih raziskovalnih ciljev<sup>4</sup>**

Ocenujem, da smo zastavljen program v podoktorskem projektu v celoti uresničili. Utemeljenost in uspešnost uporabljenih metod smo potrdili s temeljitim avtomatskim, ročnim in aplikativnim vrednotenjem rezultatov. V zadnji različici izdelanega wordneta za slovenščino je tako 42.722 množic sinonimov, od katerih smo jih skoraj četrtino (9.626) že tudi ročno pregledali in popravili. Program je bil realiziran tudi z objavo znanstvenih prispevkov v številnih monografijsah, revijah in konferenčnih zbornikih (glej seznam bibliografije v prejšnjem razdelku). Že sprejet, a še v tisku, je tudi prispevek za revijo Slovenščina 2.0 "Best friends or just faking it? Corpus-based extraction of Slovene-Croatian translation equivalents and false friends", v recenzentskem postopku pa je tudi prispevek za revijo s faktorjem vpliva Language Resources and Evaluation "Building a Poor Man's Wordnet".

## **6.Utemeljitev morebitnih sprememb programa raziskovalnega projekta oziroma sprememb, povečanja ali zmanjšanja sestave projektne skupine<sup>5</sup>**

Sprememb v programu raziskovalnega projekta ali sestavi projektne skupine ni bilo.

## **7.Najpomembnejši znanstveni rezultati projektne skupine<sup>6</sup>**

Znanstveni dosežek			
1.	COBISS ID	46703714	Vir: COBISS.SI
	Naslov	<i>SLO</i>	Luščenje dvojezičnih leksikonov iz primerljivih korpusov za sorodne jezike
		<i>ANG</i>	Bootstrapping bilingual lexicons from comparable corpora for closely related languages
	Opis	<i>SLO</i>	Predstavitev pristopa za luščenje dvojezičnih leksikonov iz primerljivih korpusov za sorodne jezike
		<i>ANG</i>	Presentation of an approach for bootstrapping bilingual lexicons from comparable corpora for closely related languages
	Objavljeno v	Springer; Text, speech and dialogue; Lecture notes in computer science; 2011; Str. 91-98; Avtorji / Authors: Fišer Darja	
2.	Tipologija	1.01 Izvirni znanstveni članek	
	COBISS ID	50261858	Vir: COBISS.SI
	Naslov	<i>SLO</i>	Jezikovni viri in orodja za semantično obogateno procesiranje slovenščine
		<i>ANG</i>	Language resources and tools for semantically enhanced processing of Slovene
	Opis	<i>SLO</i>	Predstavitev jezikovnih virov in orodij za semantično obdelavo slovenščine
		<i>ANG</i>	Presentation of language resources and tools for semantic processing of Slovene
3.	Objavljeno v	Cambridge Scholars; Multilingual processing in eastern and southern EU languages; 2012; Str. 92-118; Avtorji / Authors: Fišer Darja	
	Tipologija	1.16 Samostojni znanstveni sestavek ali poglavje v monografski publikaciji	
	COBISS ID	47786850	Vir: COBISS.SI
	Naslov	<i>SLO</i>	sloWNet 3.0: Gradnja, razširitev in čiščenje
		<i>ANG</i>	sloWNet 3.0: Development, extension and cleaning

4.	Opis	<i>SLO</i>	Predstavitev pristopov za širitev in čiščenje zadnje različice slovenskega wordneta	
		<i>ANG</i>	Presentation of the approaches for the extension and cleaning of Slovene wordnet	
	Objavljen v	The Global WordNet Association; 6th International Global Wordnet Conference; 2012; Str. 113-117; Avtorji / Authors: Fišer Darja, Novak Jernej, Erjavec Tomaž		
Tipologija		1.08 Objavljeni znanstveni prispevek na konferenci		
COBISS ID		47260258	Vir: COBISS.SI	
Naslov	<i>SLO</i>	Avtomatsko luščenje hrvaško-slovenskega leksikona iz primerljivih korpusov		
	<i>ANG</i>	Automatic extraction of Croatian-Slovene lexicon from comparable corpora		
Opis	<i>SLO</i>	V prispevku predstavljamo metodo za avtomatsko luščenje hrvaško-slovenskega leksikona iz primerljivega časopisnega korpusa s predpostavko, da se besede in njihove prevodne ustreznice pojavljajo v podobnih sobesedilih. Izhodiščni leksikon za primerjavo kontekstnih vektorjev z izkoriščanjem podobnosti med jezikoma zgradimo kar iz korpusa, nato pa opravimo še razvrščanje rezultatov glede na stopnjo sorodnosti med izvorno besedo in njenimi prevodnimi kandidati. Rezultati so zelo spodbudni in odpirajo številne možnosti uporabe za druge sorodne jezike.		
	<i>ANG</i>	In this paper we present a method for extracting a bilingual lexicon for closely related languages from comparable corpora. We take advantage of the similarities between languages to build a seed lexicon to compare context vectors in both languages and use cognates for reranking translation candidates. The results are very encouraging, suggesting that other similar languages could benefit from the same approach.		
Objavljen v		Znanstvena založba Filozofske fakultete; Meddisciplinarnost v slovenistik; 2011; Str. 137-144; Avtorji / Authors: Fišer Darja, Ljubešić Nikola		
Tipologija		1.16 Samostojni znanstveni sestavek ali poglavje v monografski publikaciji		
5.	COBISS ID		50058338 Vir: COBISS.SI	
	Naslov	<i>SLO</i>	Polisemija in luščenje dvojezičnih leksikonov iz primerljivih korpusov	
		<i>ANG</i>	Addressing polysemy in bilingual lexicon extraction from comparable corpora	
	Opis	<i>SLO</i>	Prispevek predstavlja pristop za iskanje prevodnih ustreznih polisemnih samostalnikov.	
		<i>ANG</i>	This paper presents an approach to extract translation equivalents from comparable corpora for polysemous nouns. As opposed to the standard approaches that build a single context vector for all occurrences of a given headword, we first disambiguate the headword with third-party sense taggers and then build a separate context vector for each sense of the headword. Since state-of-the-art word sense disambiguation tools are still far from perfect, we also tried to improve the results by combining the sense assignments provided by two different sense taggers. Evaluation of the resultsshow that we outperform the baseline (0.473) in all the settings we experimented with, even when using only one sense tagger, and that the best-performing results are indeed obtained by taking into account the intersection of both sense taggers (0.720).	
Objavljen v		ELRA; LREC 2012; 2012; Str. 3031-3035; Avtorji / Authors: Fišer Darja, Ljubešić Nikola, Kubelka Ozren		
Tipologija		1.08 Objavljeni znanstveni prispevek na konferenci		

## 8.Najpomembnejši družbeno-ekonomski rezultati projektne skupine<sup>2</sup>

	Družbeno-ekonomski dosežek		
1.	COBISS ID	47343714	Vir: COBISS.SI
	Naslov	<i>SLO</i>	Poročilo o poletni šoli ESSLI 2011
		<i>ANG</i>	Report on ESSLI 2011
	Opis	<i>SLO</i>	Poročilo predsednice organizacijskega odbora 23. poletne šole ESSLI, ki je avgusta leta 2011 potekala v Ljubljani, udeležilo pa se je 400 udeležencev in 80 predavateljev.
		<i>ANG</i>	Report of the president of the organizing committee of the 23rd ESSLI summer school which took place in August 2011 in Ljubljana and was attended by 400 students and 80 lecturers.
	Šifra	B.01 Organizator znanstvenega srečanja	
	Objavljeno v	EACL; EACL Newsletter; 2011; Issue 14; str. 1; Avtorji / Authors: Fišer Darja	
	Tipologija	1.25 Drugi članki ali sestavki	
2.	COBISS ID	25363239	Vir: COBISS.SI
	Naslov	<i>SLO</i>	sloWNet, wordnet za slovenščino
		<i>ANG</i>	sloWNet, a wordnet for Slovene
	Opis	<i>SLO</i>	Baza slovenskega semantičnega leksikona sloWNet
		<i>ANG</i>	The database of the Slovene semantic lexicon called sloWNet
	Šifra	F.15 Razvoj novega informacijskega sistema/podatkovnih baz	
	Objavljeno v	Filozofska fakulteta; 2011; Avtorji / Authors: Fišer Darja, Erjavec Tomaž	
	Tipologija	2.20 Zaključena znanstvena zbirka podatkov ali korpus	
3.	COBISS ID	25364007	Vir: COBISS.SI
	Naslov	<i>SLO</i>	sloWTool, orodje za iskanje, popravljanje in vizualizacijo wordnetov
		<i>ANG</i>	sloWTool, a tool for browsing, editing and visualization of wordnets
	Opis	<i>SLO</i>	Programska koda in namestitvena navodila za sloWTool, orodje za iskanje, popravljanje in vizualizacijo wordnetov
		<i>ANG</i>	The code and installation instructions of sloWTool, a tool for browsing, editing and visualization of wordnets
	Šifra	F.15 Razvoj novega informacijskega sistema/podatkovnih baz	
	Objavljeno v	Filozofska fakulteta; 2011; Avtorji / Authors: Novak Jernej, Fišer Darja, Erjavec Tomaž	
	Tipologija	2.21 Programska oprema	
4.	COBISS ID		Vir: vpis v poročilo
	Naslov	<i>SLO</i>	slowCrowd, orodje za validacijo leksikalno-semantičnih nalog z množicanjem
		<i>ANG</i>	slowCrowd, a crowdsourcing tool for validation of lexico-semantic tasks
	Opis	<i>SLO</i>	orodje za validacijo leksikalno-semantičnih podatkov z izkoriščanjem množic
		<i>ANG</i>	a crowdsourcing tool for tasks in lexical semantics
	Šifra	F.15 Razvoj novega informacijskega sistema/podatkovnih baz	
	Objavljeno v	<a href="http://nl.ijs.si/slowcrowd/">http://nl.ijs.si/slowcrowd/</a>	

	Tipologija	2.21 Programska oprema	
5.	COBISS ID		Vir: vpis v poročilo
Naslov	SLO	Članica uredniškega odbora mednarodne znanstvene revije Journal of Language Modelling	
	ANG	Member of the Editorial Board of the Journal of Language Modelling	
Opis	SLO	Revija Journal of Language Modelling je prosto dostopna, odprta, recenzirana mednarodna revija za interdisciplinarnе raziskave iz teoretičnega jezikoslovja in računalniške obdelave naravnega jezika.	
	ANG	Journal of Language Modelling is a free (no publication fees) open-access peer-reviewed journal aiming to bridge the gap between theoretical linguistics and natural language processing.	
Šifra	C.06	Članstvo v uredniškem odboru	
Objavljeno v	<a href="http://nlp.ipipan.waw.pl/ojs/index.php/JLM/about/displayMembership/4">http://nlp.ipipan.waw.pl/ojs/index.php/JLM/about/displayMembership/4</a>		
Tipologija	3.25	Druga izvedena dela	

## 9.Druži pomembni rezultati projetne skupine<sup>8</sup>

V času trajanja projekta sem bila poleg znanstvenega dela aktivna tudi na uredniškem, recenzentskem in organizacijskem področju. Sem članica Stalnega odbora ESSLLI ter tajnika Slovenskega društva za jezikovne tehnologije. Poleg članstva v uredniškem odboru in recenziranja mednarodne revije Journal of Language Modelling sem tudi članica uredniškega odbora in recenzentka elektronske jezikoslovne revije Slovenščina 2.0. Redno recenziram tudi za revije Journal of Language Resources and Evaluation, International Journal of Corpus Linguistics in Informatica. Vsa ta leta recenziram tudi za številne mednarodne conference: ACL, EACL, RANLP, TSD, \*SEM, GWA, LTC, IS-LTC, eLEX in ITI. Bila sem predsednica organizacijskega obora poletne šole ESSLLI leta 2011, ki se je udeležilo preko 400 udeležencev ter 80 predavateljev. Sodelovala sem pri organizaciji mednarodne conference eLEC 2011 ter poletne sole TransTech 2013.

## 10.Pomen raziskovalnih rezultatov projektne skupine<sup>9</sup>

### 10.1.Pomen za razvoj znanosti<sup>10</sup>

SLO

Glede na to, da na primerljivih korpusih na področju slovenske leksikalne semantike še ni bila opravljena nobena raziskava, pričujoči projekt nedvomno predstavlja pomemben mejnik v slovenskih korpusnih, pa tudi jezikovnotehnoloških raziskavah. Pomen projekta za razvoj znanosti oziroma stroke je dvojen:

(1) projekt je prinesel utemeljeno, preizkušeno in jezikovno-neodvisno metodologijo za luščenje prevodnih ustreznic iz primerljivih korpusov;

(2) zelo oprijemljiv rezultat projekta pa je tudi težko pričakovani semantični leksikon za slovenščino. Ker je izdelan wordnet poravnан z wordneti za številne druge jezike, je tako uporaben tako za eno- kot tudi za večjezične računalniške aplikacije. Izdelan wordnet je s tem zapolnil vrzel v jezikovnih virih za slovenščino in postavil temelje za širšo, semantično obogateno izrabo slovenskih korpusnih virov.

Najpomembnejše ugotovitve opravljene raziskave so:

- za uspešno luščenje prevodnih ustreznic ne potrebujemo primerljivih korpusov, ki so posebej za to nalogu izdelani po strogih kriterijih primerljivosti, temveč zadoščajo obsežni spletni korpsi, ki so za številne jezike že zgrajeni oz. je njihova gradnja precej enostavnejša;
- za uspešno luščenje prevodnih ustreznic ne potrebujemo enake količine podatkov za oba jezika, kar je v praksi razen za nekaj svetovnih jezikov težko doseči, temveč je s pazljivo izbiro statističnih mer za primerjavo kontekstnih vektorjev izvedljiv tudi scenarij, ko imamo za en jezik (npr. angleščino) na voljo bistveno večjo količino jezikovnih podatkov kot za drugega (npr. slovenščino).

- za uspešno luščenje prevodnih ustreznih med sorodnimi jeziki ne potrebujemo izhodiščnega slovarja, nedostopnost katerega je pogost problem, temveč ga lahko z upoštevanjem leksikalnega prekrivanja in drugih podobnosti med jezikoma izluščimo neposredno iz korpusa;
- z upoštevanjem osnovne predpostavke distribucijske semantike, ki se glasi, da se besede s podobnim pomenom v različnih jezikih pojavljajo v podobnih kontekstih, ni mogoče avtomatsko identificirati zgolj prevodnih ustreznih, temveč tudi lažne prijatelje, ki so si na videz sicer zelo podobni, vendar so njihove korpusne frekvence in kontekstni vektorji zelo različni. V skladu s to predpostavko smo razvili učinkovito metodo za avtomatsko prepoznavanje lažnih prijateljev, ki je zelo koristna za jezikovnotehnološke aplikacije, pa tudi v leksikografiji in pri poučevanju tujih jezikov.

Vsi leksikalni viri in orodja, razviti v okviru podoktorske raziskave, so pod licenco Creative Commons prosto dostopni v raziskovalne namene in bodo nedvomno zanimivi tudi za raziskovalce zunaj domače ustanove.

ANG

Since there has been no research into comparable corpora in the field of Slovene lexical semantics, the completed project presents a major milestone in Slovene corpus linguistics as well natural language processing. The importance of the results of the proposed project is two-fold:

- (1) the project resulted in an established, tested and language-independent methodology for the extraction of translation equivalents from comparable corpora; and
- (2) the semantic lexicon for Slovene has been released. It is aligned to wordnets in many other languages and is therefore useful for mono- as well as multilingual applications. In this way, the developed wordnet is narrowing the gap in the field of Slovene language resources and provide the foundations for a broader, semantically-enriched exploitation of Slovene corpus resources.

The key findings based on the completed research are:

- For successful extraction of translation equivalents, custom-made comparable corpora are not required. Instead, web corpora, which already exist for a number of languages or can be build relatively easily, suffice.
- For successful extraction of translation equivalents, the same amount of data for both languages, which is extremely difficult to achieve for most languages, is not required. Instead, given a careful selection of statistical similarity measures, substantially more data may be available for one language (e.g. English) than for the other (e.g. Slovene) with equal success.
- For successful extraction of translation equivalents from closely related languages a seed dictionary, which is unavailable for many language pairs, is not required. Instead, it can be induced directly from the comparable corpus by taking into account lexical overlap and other similarities between the two languages.
- According to the main premise of distributional semantics, words with a similar meaning appear in similar contexts. This allows us not only to identify translation equivalents, but also false friends, which are orthographically very similar in both languages but normally have very different frequencies in corpora and very different context vectors. Based on this principle we have also developed an efficient methodology for automatic identification of false friends, which are useful in human language technologies as well as in lexicography and language pedagogy. The impact of the first semantic lexicon for Slovene, developed within the proposed post-doctoral project, extends beyond the host institution, since all the created resources are freely available for all other researchers under the Creative Commons licence which has so far not been common practice in Slovenia.

## 10.2.Pomen za razvoj Slovenije<sup>11</sup>

SLO

Semantične leksikone tipa wordnet so doslej uporabili v številne namene in se z njihovo pomočjo lotili reševanja zelo različnih nalog tako raziskovalci kot tudi industrijski uporabniki. Med industrijskimi uporabniki, ki wordnet s pridom izkoriščajo za spletno iskanje in ciljno oglaševanje, je najvidnejši predstavnik Google. Njihovemu zgledu bi lahko sledilo tudi katero slovensko podjetje, ki se ukvarja s ponujanjem spletnih storitev.

Neposredna možnost uporabe wordneta, razvitega v okviru predlaganega projekta, bi bila ponudba aplikacije za avtomatsko razreševanje večpomenskosti in pojmovno zasnovanih spletnih storitev, kot so (medjezično) iskanje informacij, odgovarjanje na vprašanja in strojno prevajanje. Tovrstne storitve bi v družbi, temelječi na znanju, ki ima visoko razvito

informacijsko tehnologijo, bile zelo dobrodošle, saj slovenščina v primerjavi z drugimi evropskimi jeziki, na tem področju še precej zaostaja.

ANG

Semantic lexicons such as wordnet have been used in several different tasks and for several different purposes by researchers in the academia as well as by the industry. Among the companies to have gained the most advantage with the use of wordnet is Google. They have used wordnet for refining web searching and targeted advertising, and example that could well be followed by any Slovene company that offers web services. A direct way to use the developed wordnet is its integration into an application for automatic word-sense disambiguation and semantically-aware web services, such as (cross-language) information retrieval, question-answering and machine translation. Such applications would be highly welcome in a society, based on knowledge and with highly evolved information technology because Slovene language is still lagging behind its other European counterparts in this field.

#### **11. Samo za aplikativne projekte in podoktorske projekte iz gospodarstva!**

**Označite, katerega od navedenih ciljev ste si zastavili pri projektu, katere konkretnе rezultate ste dosegli in v kakšni meri so doseženi rezultati uporabljeni**

Cilj		
<b>F.01</b>	<b>Pridobitev novih praktičnih znanj, informacij in veščin</b>	
Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE	
Rezultat	<input type="button" value="▼"/>	
Uporaba rezultatov	<input type="button" value="▼"/>	
<b>F.02</b>	<b>Pridobitev novih znanstvenih spoznanj</b>	
Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE	
Rezultat	<input type="button" value="▼"/>	
Uporaba rezultatov	<input type="button" value="▼"/>	
<b>F.03</b>	<b>Večja usposobljenost raziskovalno-razvojnega osebja</b>	
Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE	
Rezultat	<input type="button" value="▼"/>	
Uporaba rezultatov	<input type="button" value="▼"/>	
<b>F.04</b>	<b>Dvig tehnološke ravni</b>	
Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE	
Rezultat	<input type="button" value="▼"/>	
Uporaba rezultatov	<input type="button" value="▼"/>	
<b>F.05</b>	<b>Sposobnost za začetek novega tehnološkega razvoja</b>	
Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE	
Rezultat	<input type="button" value="▼"/>	
Uporaba rezultatov	<input type="button" value="▼"/>	
<b>F.06</b>	<b>Razvoj novega izdelka</b>	
Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE	
Rezultat	<input type="button" value="▼"/>	

	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.07</b>	<b>Izboljšanje obstoječega izdelka</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.08</b>	<b>Razvoj in izdelava prototipa</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.09</b>	<b>Razvoj novega tehnološkega procesa oz. tehnologije</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.10</b>	<b>Izboljšanje obstoječega tehnološkega procesa oz. tehnologije</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.11</b>	<b>Razvoj nove storitve</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.12</b>	<b>Izboljšanje obstoječe storitve</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.13</b>	<b>Razvoj novih proizvodnih metod in instrumentov oz. proizvodnih procesov</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.14</b>	<b>Izboljšanje obstoječih proizvodnih metod in instrumentov oz. proizvodnih procesov</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.15</b>	<b>Razvoj novega informacijskega sistema/podatkovnih baz</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE

	Rezultat	<input type="text"/>
	Uporaba rezultatov	<input type="text"/>
<b>F.16</b>	<b>Izboljšanje obstoječega informacijskega sistema/podatkovnih baz</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="text"/>
	Uporaba rezultatov	<input type="text"/>
<b>F.17</b>	<b>Prenos obstoječih tehnologij, znanj, metod in postopkov v prakso</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="text"/>
	Uporaba rezultatov	<input type="text"/>
<b>F.18</b>	<b>Posredovanje novih znanj neposrednim uporabnikom (seminarji, forumi, konference)</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="text"/>
	Uporaba rezultatov	<input type="text"/>
<b>F.19</b>	<b>Znanje, ki vodi k ustanovitvi novega podjetja ("spin off")</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="text"/>
	Uporaba rezultatov	<input type="text"/>
<b>F.20</b>	<b>Ustanovitev novega podjetja ("spin off")</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="text"/>
	Uporaba rezultatov	<input type="text"/>
<b>F.21</b>	<b>Razvoj novih zdravstvenih/diagnostičnih metod/postopkov</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="text"/>
	Uporaba rezultatov	<input type="text"/>
<b>F.22</b>	<b>Izboljšanje obstoječih zdravstvenih/diagnostičnih metod/postopkov</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="text"/>
	Uporaba rezultatov	<input type="text"/>
<b>F.23</b>	<b>Razvoj novih sistemskih, normativnih, programskeh in metodoloških rešitev</b>	
	Zastavljen cilj	<input checked="" type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="text"/>
	Uporaba rezultatov	<input type="text"/>

<b>F.24</b>	<b>Izboljšanje obstoječih sistemskih, normativnih, programskih in metodoloških rešitev</b>	
	Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.25</b>	<b>Razvoj novih organizacijskih in upravljačkih rešitev</b>	
	Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.26</b>	<b>Izboljšanje obstoječih organizacijskih in upravljačkih rešitev</b>	
	Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.27</b>	<b>Prispevek k ohranjanju/varovanju naravne in kulturne dediščine</b>	
	Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.28</b>	<b>Priprava/organizacija razstave</b>	
	Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.29</b>	<b>Prispevek k razvoju nacionalne kulturne identitete</b>	
	Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.30</b>	<b>Strokovna ocena stanja</b>	
	Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.31</b>	<b>Razvoj standardov</b>	
	Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>
	Uporaba rezultatov	<input type="button" value="▼"/>
<b>F.32</b>	<b>Mednarodni patent</b>	
	Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="button" value="▼"/>

	Uporaba rezultatov	<input type="text"/>
<b>F.33</b>	<b>Patent v Sloveniji</b>	
	Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="text"/>
	Uporaba rezultatov	<input type="text"/>
<b>F.34</b>	<b>Svetovalna dejavnost</b>	
	Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="text"/>
	Uporaba rezultatov	<input type="text"/>
<b>F.35</b>	<b>Drugo</b>	
	Zastavljen cilj	<input type="radio"/> DA <input type="radio"/> NE
	Rezultat	<input type="text"/>
	Uporaba rezultatov	<input type="text"/>

**Komentar**

**12. Samo za aplikativne projekte in podoktorske projekte iz gospodarstva!**  
**Označite potencialne vplive oziroma učinke vaših rezultatov na navedena področja**

	<b>Vpliv</b>	<b>Ni vpliva</b>	<b>Majhen vpliv</b>	<b>Srednji vpliv</b>	<b>Velik vpliv</b>	
<b>G.01</b>	<b>Razvoj visokošolskega izobraževanja</b>					
G.01.01.	Razvoj dodiplomskega izobraževanja	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.01.02.	Razvoj podiplomskega izobraževanja	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.01.03.	Drugo:	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
<b>G.02</b>	<b>Gospodarski razvoj</b>					
G.02.01	Razširitev ponudbe novih izdelkov/storitev na trgu	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.02.02.	Širitev obstoječih trgov	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.02.03.	Znižanje stroškov proizvodnje	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.02.04.	Zmanjšanje porabe materialov in energije	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.02.05.	Razširitev področja dejavnosti	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.02.06.	Večja konkurenčna sposobnost	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.02.07.	Večji delež izvoza	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.02.08.	Povečanje dobička	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.02.09.	Nova delovna mesta	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.02.10.	Dvig izobrazbene strukture zaposlenih	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.02.11.	Nov investicijski zagon	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	

G.02.12.	Drugo:	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
<b>G.03</b>	<b>Tehnološki razvoj</b>					
G.03.01.	Tehnološka razširitev/posodobitev dejavnosti	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.03.02.	Tehnološko prestrukturiranje dejavnosti	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.03.03.	Uvajanje novih tehnologij	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.03.04.	Drugo:	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
<b>G.04</b>	<b>Družbeni razvoj</b>					
G.04.01	Dvig kvalitete življenja	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.04.02.	Izboljšanje vodenja in upravljanja	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.04.03.	Izboljšanje delovanja administracije in javne uprave	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.04.04.	Razvoj socialnih dejavnosti	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.04.05.	Razvoj civilne družbe	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.04.06.	Drugo:	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
<b>G.05.</b>	<b>Ohranjanje in razvoj nacionalne naravne in kulturne dediščine in identitete</b>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
<b>G.06.</b>	<b>Varovanje okolja in trajnostni razvoj</b>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
<b>G.07</b>	<b>Razvoj družbene infrastrukture</b>					
G.07.01.	Informacijsko-komunikacijska infrastruktura	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.07.02.	Prometna infrastruktura	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.07.03.	Energetska infrastruktura	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
G.07.04.	Drugo:	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
<b>G.08.</b>	<b>Varovanje zdravja in razvoj zdravstvenega varstva</b>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	
<b>G.09.</b>	<b>Drugo:</b>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	

**Komentar**

--

**13.Pomen raziskovanja za sofinancerje<sup>12</sup>**

Sofinancer	
1.	Naziv
	Naslov
	Vrednost sofinanciranja za celotno obdobje trajanja projekta je znašala:
	Odstotek od utemeljenih stroškov projekta:
	Najpomembnejši rezultati raziskovanja za sofinancerja
	Šifra
	1.
	2.

	3.	
	4.	
	5.	
Komentar		
Ocena		

## 14. Izjemni dosežek v letu 2012<sup>13</sup>

### 14.1. Izjemni znanstveni dosežek

FIŠER, Darja. Language resources and tools for semantically enhanced processing of Slovene. V: VERTAN, Cristina (ur.), HAHN, Walther von (ur.). Multilingual processing in eastern and southern EU languages : low-resourced technologies in translation. [S.l.]: Cambridge Scholars, 2012, str. 92-118.

V poglavju predstavimo metode, jezikovne vire in orodja, ki smo jih razvili za semantično obogateno procesiranje slovenščine. Za izdelavo 1. semantičnega leksikona za slovenščino smo uporabili heterogene večjezične jezikovne vire. S pomočjo izdelanega wordneta smo 1. za slovenščino semantično označili korpus. Razvili smo tudi orodje za pregledovanje in vizualizacijo semantične mreže, s katerim je mogoče proučevati leksikalno-semantične lastnosti slovenščine v primerjavi z drugimi jeziki, wordnet pa smo prav tako uporabili za izboljšanje strojnega prevajanja večpomenskih besed. Zadnja različica slovenskega wordneta vsebuje 42722 sinsetov, od katerih smo jih 25 % že ročno pregledali in popravili.

### 14.2. Izjemni družbeno-ekonomski dosežek

TAVČAR, Aleš, FIŠER, Darja, ERJAVEC, Tomaž. sloWCrowd: orodje za popravljanje wordneta z izkoriščanjem moči množic. V: ERJAVEC, Tomaž (ur.), ŽGANEC GROS, Jerneja (ur.). Zbornik Osme konference Jezikovne tehnologije, 8. do 12. oktober 2012, [Ljubljana, Slovenia] : zbornik 15. mednarodne multikonference Informacijska družba - IS 2012, zvezek C : proceedings of the 15th International Multiconference Information Society - IS 2012, volume C, (Informacijska družba). Ljubljana: Institut Jožef Stefan, 2012, str. 197-202.

Za hitrejši razvoj leksikalnih virov smo izdelali orodje sloWCrowd, ki je zasnovano tako, da nam odgovore omogoča zbirati iz široke množice uporabnikov. Zanesljivost zbranih rezultatov dosežemo z večkratnim ponavljanjem istega vprašanja pri različnih uporabnikih, odgovore uporabnikov z nizko stopnjo natančnosti glede na zlati standard pa izločimo. Trenutno št. registriranih uporabnikov orodja je 280, doslej pa smo zbrali 30000 odgovorov za 6500 besed.

## C. IZJAVE

Podpisani izjavljjam/o, da:

- so vsi podatki, ki jih navajamo v poročilu, resnični in točni
- se strinjam z obdelavo podatkov v skladu z zakonodajo o varstvu osebnih podatkov za potrebe ocenjevanja ter obdelavo teh podatkov za evidence ARRS
- so vsi podatki v obrazcu v elektronski obliki identični podatkom v obrazcu v pisni obliki
- so z vsebino zaključnega poročila seznanjeni in se strinjajo vsi soizvajalci projekta

### Podpisi:

zastopnik oz. pooblaščena oseba  
raziskovalne organizacije:

in

vodja raziskovalnega projekta:

Univerza v Ljubljani, Filozofska  
fakulteta

Darja Fišer

**ŽIG**

Kraj in datum: Ljubljana | 14.3.2013

**Oznaka prijave: ARRS-RPROJ-ZP-2013/266**

<sup>1</sup> Opredelite raziskovalno področje po klasifikaciji FOS 2007 (Fields of Science). Prevajalna tabela med raziskovalnimi področji po klasifikaciji ARRS ter po klasifikaciji FOS 2007 (Fields of Science) s kategorijami WOS (Web of Science) kot podpodročji je dostopna na spletni strani agencije (<http://www.arrs.gov.si/sl/gradivo/sifranti/preslik-vpp-fos-wos.asp>). [Nazaj](#)

<sup>2</sup> Napišite povzetek raziskovalnega projekta (največ 3.000 znakov v slovenskem in angleškem jeziku) [Nazaj](#)

<sup>3</sup> Napišite kratko vsebinsko poročilo, kjer boste predstavili raziskovalno hipotezo in opis raziskovanja. Navedite ključne ugotovitve, znanstvena spoznanja, rezultate in učinke raziskovalnega projekta in njihovo uporabo ter sodelovanje s tujimi partnerji. Največ 12.000 znakov vključno s presledki (približno dve strani, velikost pisave 11). [Nazaj](#)

<sup>4</sup> Realizacija raziskovalne hipoteze. Največ 3.000 znakov vključno s presledki (približno pol strani, velikost pisave 11) [Nazaj](#)

<sup>5</sup> V primeru bistvenih odstopanj in sprememb od predvidenega programa raziskovalnega projekta, kot je bil zapisan v predlogu raziskovalnega projekta oziroma v primeru sprememb, povečanja ali zmanjšanja sestave projektne skupine v zadnjem letu izvajanja projekta, napišite obrazložitev. V primeru, da sprememb ni bilo, to navedite. Največ 6.000 znakov vključno s presledki (približno ena stran, velikost pisave 11). [Nazaj](#)

<sup>6</sup> Navedite znanstvene dosežke, ki so nastali v okviru tega projekta. Raziskovalni dosežek iz obdobja izvajanja projekta (do oddaje zaključnega poročila) vpisete tako, da izpolnite COBISS kodo dosežka – sistem nato sam izpolni naslov objave, naziv, IF in srednjo vrednost revije, naziv FOS področja ter podatek, ali je dosežek uvrščen v A'' ali A'. [Nazaj](#)

<sup>7</sup> Navedite družbeno-ekonomske dosežke, ki so nastali v okviru tega projekta. Družbeno-ekonomski rezultat iz obdobja izvajanja projekta (do oddaje zaključnega poročila) vpisete tako, da izpolnite COBISS kodo dosežka – sistem nato sam izpolni naslov objave, naziv, IF in srednjo vrednost revije, naziv FOS področja ter podatek, ali je dosežek uvrščen v A'' ali A'.

Družbeno-ekonomski dosežek je po svoji strukturi drugačen kot znanstveni dosežek. Povzetek znanstvenega dosežka je praviloma povzetek bibliografske enote (članka, knjige), v kateri je dosežek objavljen.

Povzetek družbeno-ekonomskega dosežka praviloma ni povzetek bibliografske enote, ki ta dosežek dokumentira, ker je dosežek sklop več rezultatov raziskovanja, ki je lahko dokumentiran v različnih bibliografskih enotah. COBISS ID zato ni enoznačen, izjemoma pa ga lahko tudi ni (npr. prehod mlajših sodelavcev v gospodarstvo na pomembnih raziskovalnih nalogah, ali ustavnovitev podjetja kot rezultat projekta ... - v obeh primerih ni COBISS ID). [Nazaj](#)

<sup>8</sup> Navedite rezultate raziskovalnega projekta iz obdobja izvajanja projekta (do oddaje zaključnega poročila) v primeru, da katerega od rezultatov ni mogoče navesti v točkah 7 in 8 (npr. ker se ga v sistemu COBISS ne vodi). Največ 2.000 znakov, vključno s presledki. [Nazaj](#)

<sup>9</sup> Pomen raziskovalnih rezultatov za razvoj znanosti in za razvoj Slovenije bo objavljen na spletni strani: <http://sicris.izum.si/> za posamezen projekt, ki je predmet poročanja [Nazaj](#)

<sup>10</sup> Največ 4.000 znakov, vključno s presledki [Nazaj](#)

<sup>11</sup> Največ 4.000 znakov, vključno s presledki [Nazaj](#)

<sup>12</sup> Rubrike izpolnite / prepisite skladno z obrazcem "izjava sofinancerja" <http://www.arrs.gov.si/sl/progproj/rproj/gradivo/>, ki ga mora izpolniti sofinancer. Podpisani obrazec "Izjava sofinancerja" pridobi in hrani nosilna raziskovalna organizacija – izvajalka projekta. [Nazaj](#)

<sup>13</sup> Navedite en izjemni znanstveni dosežek in/ali en izjemni družbeno-ekonomski dosežek raziskovalnega projekta v letu 2012 (največ 1000 znakov, vključno s presledki). Za dosežek pripravite diapositiv, ki vsebuje sliko ali drugo slikovno gradivo v zvezi z izjemnim dosežkom (velikost pisave najmanj 16, približno pol strani) in opis izjemnega dosežka (velikost pisave 12, približno pol strani). Diapositiv/-a priložite kot príponko/-i k temu poročilu. Vzorec diapositiva je objavljen na spletni strani ARRS <http://www.arrs.gov.si/sl/gradivo/>, predstavitev dosežkov za pretekla leta pa so objavljena na spletni strani <http://www.arrs.gov.si/sl/analize/dosez/>. [Nazaj](#)

APIDIANAKI, Marianna, LJUBEŠIĆ, Nikola, FIŠER, Darja. Disambiguating vectors for bilingual lexicon extraction from comparable corpora. V: ERJAVEC, Tomaž (ur.), ŽGANEC GROS, Jerneja (ur.). *Zbornik Osme konference Jezikovne tehnologije*, 8. do 12. oktober 2012.

FIŠER, Darja, BRODA, Bartosz, PIASECKI, Maciej. Weaving sloWNet using window-based co-occurrence features. V: ERJAVEC, Tomaž (ur.), ŽGANEC GROS, Jerneja (ur.). Zbornik Osme konference Jezikovne tehnologije, 8. do 12. oktober 2012.

FIŠER, Darja, GANTAR, Polona, KREK, Simon. Using explicitly and implicitly encoded semantic relations to map Slovene wordnet and Slovene lexical database. V: 8th International Conference on Language Resources and Evaluation, 21-27 May 2012, Istanbul, Turkey.

FIŠER, Darja, LJUBEŠIĆ, Nikola, KUBELKA, Ozren. Addressing polysemy in bilingual lexicon extraction from comparable corpora. V: 8th International Conference on Language Resources and Evaluation, 21-27 May 2012, Istanbul, Turkey.

FIŠER, Darja, LJUBEŠIĆ, Nikola, VINTAR, Špela, POLLAK, Senja. Building and using comparable corpora for domain-specific bilingual lexicon extraction. V: 4th Workshop on BUCC, 24 June, 2011, Portland, Oregon. *Comparable Corpora and the Web : proceedings of the workshop*. Portland: Association for Computational Linguistics, 2011.

FIŠER, Darja, LJUBEŠIĆ, Nikola. Avtomatsko luščenje hrvaško-slovenskega leksikona iz primerljivih korpusov. V: KRANJC, Simona (ur.). *Meddisciplinarnost v slovenistiki*, (Obdobja, Simpozij, = Symposium, 30). 1. natis. Ljubljana: Znanstvena založba Filozofske fakultete, 2011.

FIŠER, Darja, LJUBEŠIĆ, Nikola. Best friends or just faking it? Corpus-based extraction of Slovene-Croatian translation equivalents and false friends (v tisku).

FIŠER, Darja, NOVAK, Jernej. Visualising sloWNet. V: KOSEM, Iztok (ur.), KOSEM, Karmen (ur.). *Electronic lexicography in the 21st century : new applications for new users : proceedings of eLex 2011, 10-12 November 2011, Bled, Slovenia*. Ljubljana: Trojina, Institute for Applied Slovene Studies, 2011.

FIŠER, Darja, POLLAK, Senja, VINTAR, Špela. Samodejno luščenje definicij iz specializiranih besedil. V: KRANJC, Simona (ur.). *Meddisciplinarnost v slovenistiki*, (Obdobja, Simpozij, = Symposium, 30). 1. natis. Ljubljana: Znanstvena založba Filozofske fakultete, 2011, str. 145-150.

FIŠER, Darja. Language resources and tools for semantically enhanced processing of Slovene. V: VERTAN, Cristina (ur.), HAHN, Walther von (ur.). *Multilingual processing in eastern and southern EU languages : low-resourced technologies in translation*. [S.l.]: Cambridge Scholars, 2012, str. 92-118.

FIŠER, Darja. Semantično označevanje korpusov. V: VINTAR, Špela (ur.). *Slovenske korpusne raziskave*, (Zbirka Prevodoslovje in uporabno jezikoslovje). 1. natis. Ljubljana: Znanstvena založba Filozofske fakultete, 2010, str. 110-130.

LJUBEŠIĆ, Nikola, FIŠER, Darja, VINTAR, Špela, POLLAK, Senja. Bilingual lexicon extraction from comparable corpora : a comparative study. V: First International Workshop on Lexical Resources, An ESSLLI 2011 Workshop, Ljubljana, Slovenia - August 1-5, 2011.

LJUBEŠIĆ, Nikola, VINTAR, Špela, FIŠER, Darja. Multi-word term extraction from comparable corpora by combining contextual and constituent clues. V: 8th International Conference on Language Resources and Evaluation, 21-27 May 2012, Istanbul, Turkey.

TAVČAR, Aleš, FIŠER, Darja, ERJAVEC, Tomaž. sloWCrowd: orodje za popravljanje wordneta z izkoriščanjem moči množic. V: ERJAVEC, Tomaž (ur.), ŽGANEC GROS, Jerneja (ur.). *Zbornik Osme konference Jezikovne tehnologije, 8. do 12. oktober 2012.*

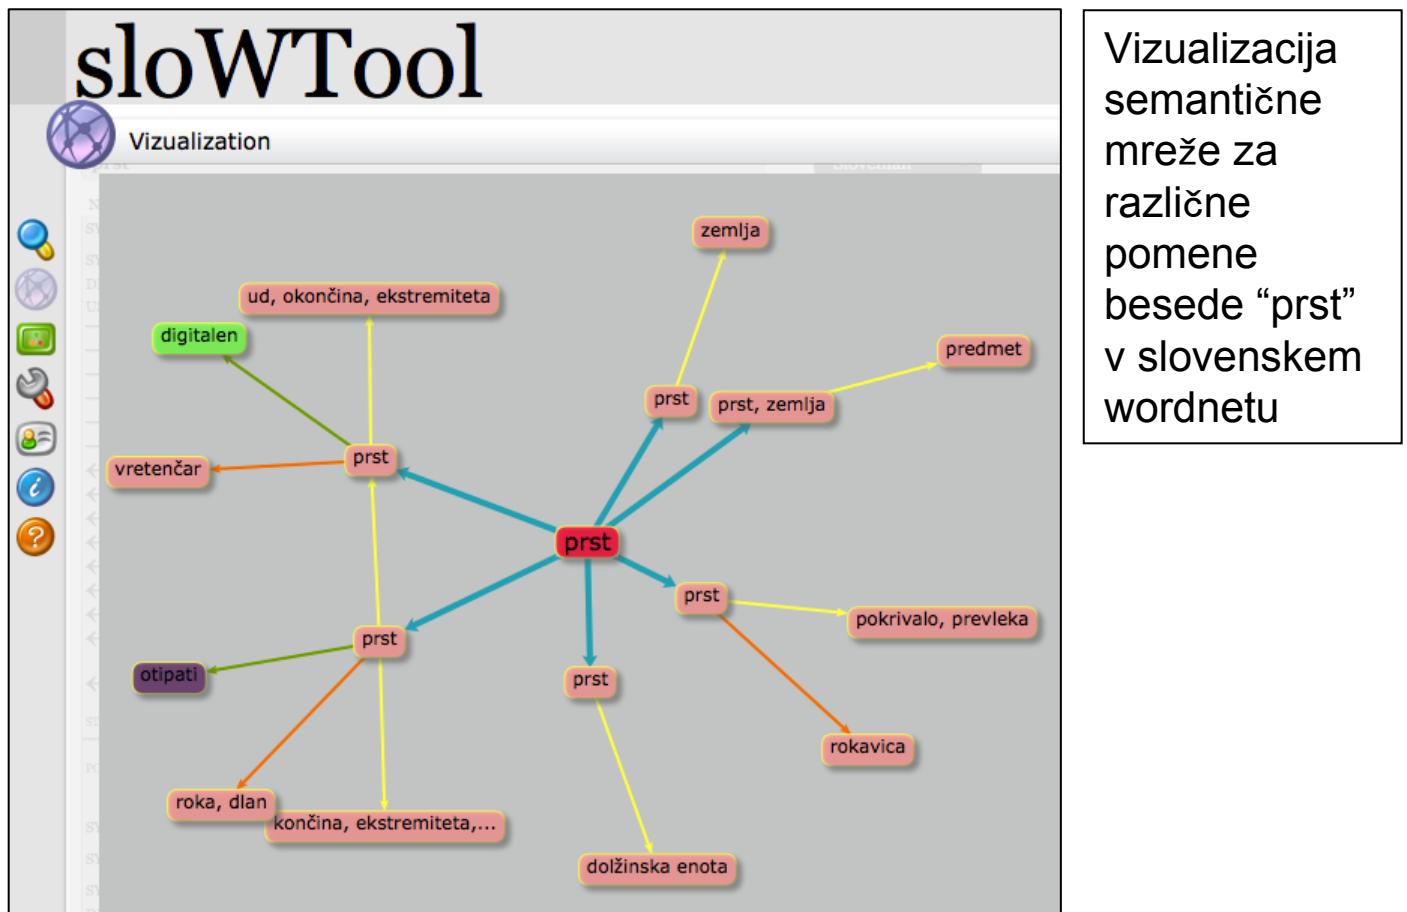
VINTAR, Špela, FIŠER, Darja, VRŠČAJ, Aljoša. Were the clocks striking or surprising? Using WSD to improve MT performance. V: 13th Conference on the European Chapter of the Association for Computational Linguistics, Avignon, April 23-17 2012. *Proceedings of the workshop*. Avignon: ACL, 2012, str. 87-92.

VEDA: Humanistične vede

Področje: 6.05.00 - Jezikoslovje

## Izjemni znanstveni dosežek: Razvoj virov in orodij za semantično obogateno procesiranje slovenščine

Vir: FIŠER, Darja. Language resources and tools for semantically enhanced processing of Slovene. V: VERTAN, Cristina (ur.), HAHN, Walther von (ur.). Multilingual processing in eastern and southern EU languages : low-resourced technologies in translation. [S.l.]: Cambridge Scholars, 2012, str. 92-118.



V poglavju predstavimo metode, jezikovne vire in orodja, ki smo jih razvili za semantično obogateno procesiranje slovenščine. Za izdelavo prvega semantičnega leksikona za slovenščino smo uporabili heterogene večjezične jezikovne vire, kot so slovarji, enciklopedije, vzporedni in primerljivi korpusi. S pomočjo izdelanega wordneta smo semantično označili dele korpusov JOS in SPOOK, ki sta tako prva korpusa za slovenščino, označena na pomenski ravni. Poleg virov smo razvili tudi orodje za iskanje po wordnetu in vizualizacijo semantične mreže, s katerim je mogoče proučevati leksikalno-semantične lastnosti slovenščine v primerjavi z drugimi jeziki, izdelan wordnet pa smo prav tako uporabili za izboljšanje strojnega prevajanja večpomenskih besed. Zadnja različica slovenskega wordneta vsebuje 42722 množic sinonimov, od katerih smo jih skoraj četrtino (9626) že tudi ročno pregledali in popravili.

VEDA: Humanistične vede  
Področje: 6.05.00 - Jezikoslovje

## Izjemni družbeno-ekonomski dosežek: Čiščenje leksikalnih virov z množicanjem

Vir: TAVČAR, Aleš, FIŠER, Darja, ERJAVEC, Tomaž. sloWCrowd: orodje za popravljanje wordneta z izkoriščanjem moči množic. V: ERJAVEC, Tomaž (ur.), ŽGANEC GROS, Jerneja (ur.). Zbornik Osme konference Jezikovne tehnologije, 8. do 12. oktober 2012, [Ljubljana, Slovenia] : zbornik 15. mednarodne multikonference Informacijska družba - IS 2012, zvezek C : proceedings of the 15th International Multiconference Information Society - IS 2012, volume C, (Informacijska družba). Ljubljana: Institut Jožef Stefan, 2012, str. 197-202.

**sloWCrowd**  
Popravimo slovenski wordnet

ZAČETNA STRAN POTRJEVANJE GESEL LESTVICA UPORABNIKOV INFO

**Potrjevanje gesel**  
Ali je avtomatsko preveden izraz "cilj" ustrezno poimenovanje pojma "purpose; the phrase 'with a view to' means 'with the intention of' or 'for the purpose of'"?

Preveden izraz:  
**cilj**

Angleške sopomenke:  
**view**

Angleška definicija:  
**purpose; the phrase 'with a view to' means 'with the intention of' or 'for the purpose of'**

DA  NE  Ne vem

**Validacija/zavračanje avtomsatko generiranih literalov v orodju sloWCrowd**

**Prijava v sistem**  
Prijavljeni ste kot:  
**darja**  
 Odjava

**Prislužene točke**  
Z reševanjem ste zbrali: 1236 točk

**Ocenjeni literali**  
Ocenjenih 6365 literalov od 7000  
Vseh podanih odgovorov 28936

Za hitrejše in cenejše čiščenje leksikalnih virov z množicanjem smo razvili orodje sloWCrowd, ki je zasnovano tako, da nam odgovore na leksikalno-semantična vprašanja omogoča zbirati iz široke množice uporabnikov. Orodje je prosto dostopno in temelji na razširjenih tehnologijah, kot sta PHP in MySQL. Zanesljivost zbranih rezultatov dosežemo z večkratnim ponavljanjem istega vprašanja pri različnih uporabnikih, odgovore uporabnikov z nizko stopnjo natančnosti glede na zlati standard pa izločimo. Trenutno število registriranih uporabnikov orodja je 280, doslej pa smo zbrali skoraj 30000 odgovorov za okoli 6500 besed. Dodatna prednost razvitega orodja je, da ga je mogoče prilagoditi za najrazličnejše naloge, kar že preizkušamo v sodelovanju z inštitutom INRIA iz Francije za popravljanje francoskega wordneta WOLF in s sodelavci projekta Sporazumevanje v slovenskem jeziku za Slovensko leksikalno bazo.