

Slovensko-hrvatski paralelni korpus

Vesna Požgaj Hadži*, Marko Tadić**

*Odsjek za slavenske jezike i književnosti, Filozofski fakultet, Sveučilište u Ljubljani
Aškerčeva 2, 1000 Ljubljana, Slovenija
vesna.pozgaj-hadzi@ff.uni-lj.si

**Odsjek za lingvistiku, Filozofski fakultet, Sveučilište u Zagrebu
Ivana Lučića 3, 10000 Zagreb, Hrvatska
marko.tadic@ffzg.hr

Abstract

The Slovene-Croatian Parallel Corpus is a project that was launched together with about twenty others within the framework of bilateral academic and research co-operation between Slovenia and Croatia. The corpus will contain one million words (500,000 for each language) and will comprise texts of various functional styles – both Croatian originals and their Slovene translations and vice versa. We are choosing texts that were created after 1990 in order to represent the languages to be contrasted in their present state. The need for the compilation of this type of corpus was initiated by various fields simultaneously: the teaching of both languages at university level, translation studies, lexicographic research, contrastive studies, and also by the translators of these languages themselves. Particularly the latter as well as other language professionals will be able to use the parallel corpus as an additional source of information, even more valuable in view of the fact that at present we do not have a proper Croatian-Slovene (Slovene-Croatian) dictionary. This contribution is trying to show preliminary statistical results of text alignment illustrated on the test sample which includes eight bilateral agreements between both states.

1. Uvod

Slovensko-hrvatski paralelni korpus (Ministarstvo znanosti i tehnologije R. Slovenije: J6-7802-0581-99 i Ministarstvo znanosti i tehnologije R. Hrvatske: 130821) jedan je od projekata s područja humanističkih znanosti u okviru Sporazuma o bilateralnoj slovensko-hrvatskoj suradnji u području znanosti i tehnologije za 1999., 2000. i 2001. godinu. "Težinu" projektu *Slovensko-hrvatski paralelni korpus* daje činjenica da je jedan od 28 prihvaćenih projekata (od ukupno 70 prijavljenih) koji je odobrio zajednički slovensko-hrvatski odbor krajem lipnja 1999. u trajanju od 2 godine. Riječ je zapravo o drugom dvojezičnom korpusu za slovenski jezik (prvi je Slovensko-engleski korpus *Elan*, usp. Erjavec, 1999c). Rad na projektu započeo je početkom šk. god. 1999/2000. a završetak se očekuje s polovicom 2001.

Kao partneri projekta pojavljuju se Filozofski fakulteti u Ljubljani i Zagrebu. Projekt vode V. Požgaj Hadži i M. Tadić; u njemu s hrvatske strane sudjeluju I. Pranjković, V. Muhić-Dimanovski, B. Bekavac, S. Fulgoši, K. Šojat; na slovenskoj strani na projektu rade V. Gorjanc, A. Skubic i Š. Vintar.

2. Cilj i svrha projekta

Slovensko-hrvatski paralelni korpus bit će ishodištem za suvremena kontrastivna istraživanja dvaju genetski srodnih i susjednih jezika koji su uspostavljanjem novih država doživjeli određene preinake, između ostaloga i zbog promjene državnoga statusa. Ciljevi su projekta ovi:

- sastaviti usporedni korpus (parallel) slovenskih i hrvatskih orginala te odgovarajućih prijevoda (obostrani prijevodi),
- korpus sravniti (*align*) na razini rečeničnih prijevodnih ekvivalenta,

- omogućiti pristup korpusu ponajprije na Internetu putem WWW servisa.

Istraživanja korpusne lingvistike, koja posljednjih desetljeća nadmašuju ostale lingvističke discipline, osobito u području leksikografije (jednojezičnih, višejezičnih i paralelnih korpusa kojima pripada i naš projekt) temelj su za niz proučavanja. Rezultati našega projekta našli bi svoju primjenu u:

- a) kontrastivnim proučavanjima (strukturnim i tipološkim) slovenskoga i hrvatskoga jezika na svim jezičnim razinama.
- b) leksikografskim proučavanjima
 - zbog zastarjelih slovensko-hrvatskih (srpskohrvatskih) rječnika (Jurančič 1986, 1989)¹ projekt je zapravo temelj i poticaj za dvojezičnu leksikografiju. Slovensko-hrvatski rječnik i obratno danas postaje nužnim normativnim priručnikom, čega su svjesni i mnogi izdavači.
 - slovensko-hrvatski paralelni korpus također je temelj za različita leksikografska i leksikološka proučavanja, npr. proučavanja "lažnih" prijatelja (rječnik slovensko-hrvatskih homonima), proučavanja terminologije (terminološki rječnici), proučavanja kolokacija itd.
- c) znanosti o prevodenju
 - izrađeni korpus, objavljen na Internetu, bit će dragocjen priručnik studentima za vježbe iz prevodenja (slovensko-hrvatski i obratno) na Filozofskim fakultetima u Ljubljani i Zagrebu, naročito zbog aktualnosti tekstova koje će korpus sadržavati. Naime, korpus obuhvaća tekstove nastale posljednjih desetak godina koji u oba

¹ O nedostacima Jurančičevih rječnika v. Požgaj Hadži (1998).

- jezika prikazuju današnju jezičnu situaciju, a za razliku od rječnika nude i kontekst.
- dobro će doći i prevodiocima obju država kao dopunski izvor informacija, posebice u posljednje vrijeme, kada se ponovo pojavljuju potrebe za kvalitetnim prijevodima, a kao što smo već rekli, dvojezični su nam rječnici zastarjeli i gotovo neupotrebljivi.
- d) didaktičkim/metodičkim proučavanjima
- usustavljanju razlika između dvaju srodnih jezika koje su najčešće uzrokom grešaka u nastavi/učenju obaju jezika.
 - klasifikaciji interferencijskih grešaka u nastavi/učenju hrvatskog i slovenskog jezika kao stranih/drugih, prije svega mislimo na fakultetsku razinu u obje zemlje te osnovnoškolsku u Sloveniji, u kojoj se u 7., 8. i 9. razredu osnovne škole uvodi hrvatski kao izborni drugi strani jezik.
 - u izradi didaktičkih izvora (kontrastivnih udžbenika, priručnika, gramatika itd.) za sve razine i sve stupnjeve učenja obaju jezika.
- e) razvoju jezičnih tehnologija
- (automatsko) traženje termina i njihovih prijevodnih ekvivalenta,
 - strojno (potpomognuto) prevođenje.

3. Sastavljanje korpusa

3.1. Korpusni parametri

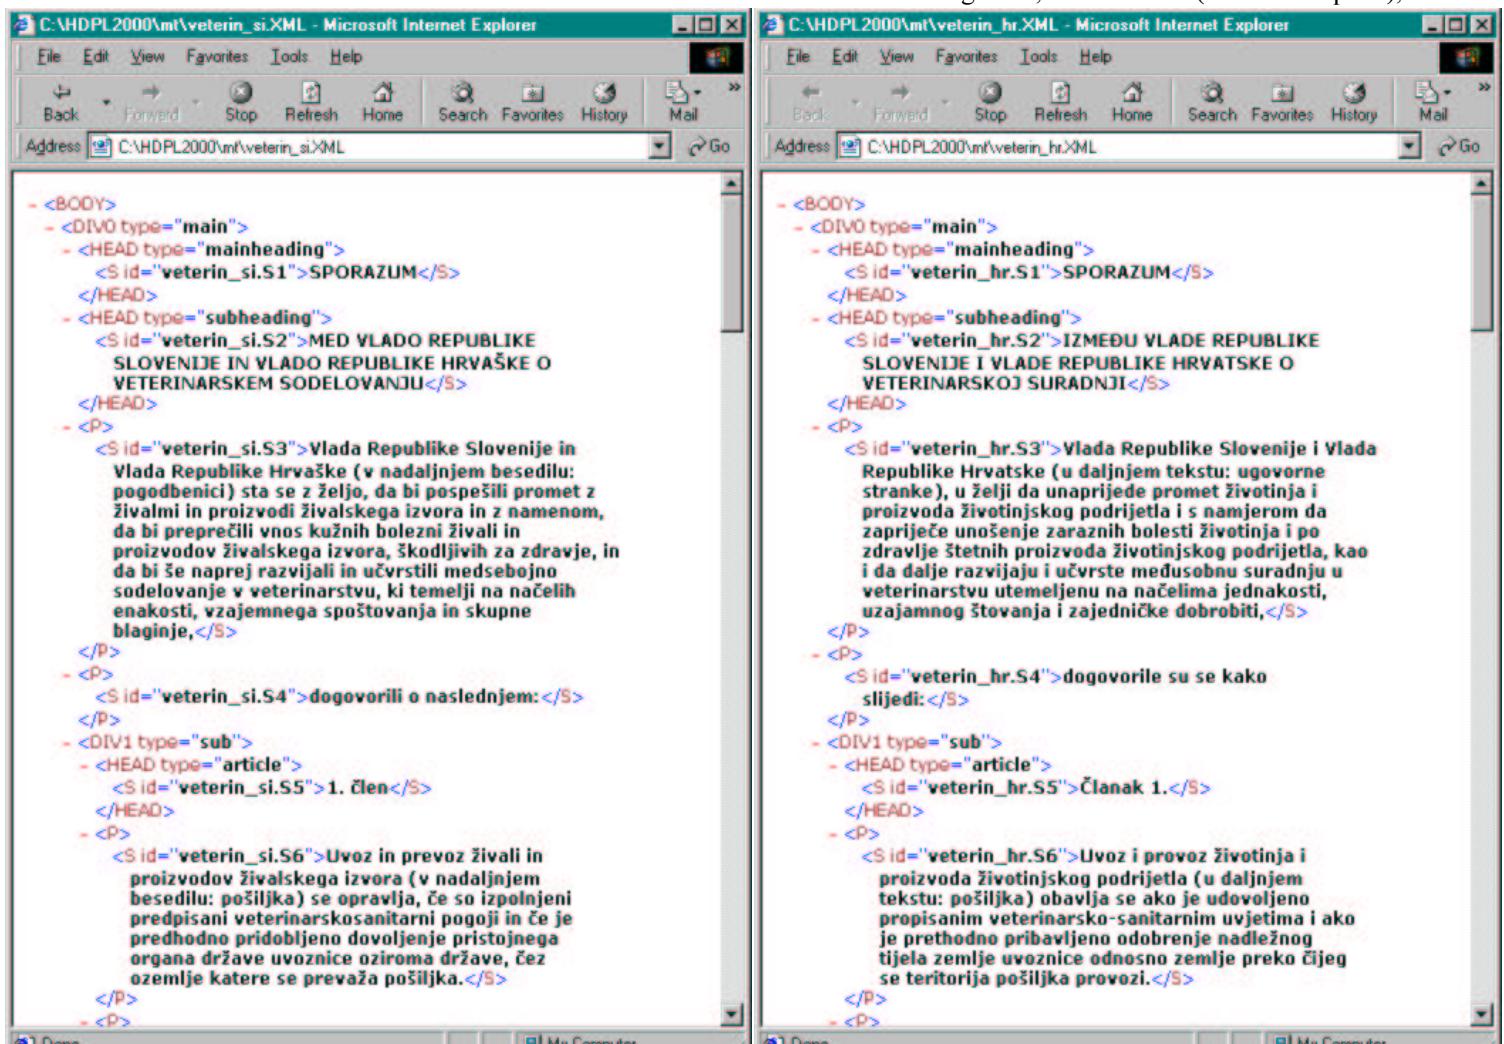
Veličina korpusa definirana je na milijun pojavnica (po 500.000 pojavnica za svaki jezik). Vremenski raspon korpusa obuhvaća tekstove nastale u najnovijem razdoblju, tj. od 1990. do 2001. čime se pokušava približiti reprezentativnosti suvremene jezične situacije u oba jezika.

Struktura korpusa po žanrovima raspoređena je na ovaj način:

beletristica	15%	75.000 pojavnica
publicistika	30%	150.000 pojavnica
stručni tekstovi	40%	200.000 pojavnica
znanost	15%	75.000 pojavnica

Tablica 1: Osnovna žanrovska struktura korpusa

U početnim fazama prikupljanja tekstova za korpus preuzimali su se tekstovi isključivo u digitalnom zapisu. Ubrzo smo naišli na "tehničku prepreku" i shvatili da digitalnih tekstova žanrovske strukture koja nama treba nema dovoljno. Za sada je ulaz tekstova pohranjenih u digitalnom zapisu zadovoljavajući, no pretpostavljamo da će dio tekstova morati biti utipkan pri kraju sastavljanja korpusa kada se budu morale popunjavati praznine u žanrovskoj strukturi. Do sada sakupljena građa obuhvaća međudržavne ugovore, beletristku (romane i priče),²



Slika 1: Izgled XML dokumenata u oba jezika

tehničku dokumentaciju i priručnike (promet, kulinarstvo, farmaceutika, elektrotehnika...) te turističke brošure.

3.2. Obrada

Nad dijelom sakupljene građe probno je obavljena cijela obrada, koja se sastoji od konverzije teksta u jedinstven XML zapis, priređivanja XML dokumenata za sravnjivanje i konačno sam postupak sravnjivanja. Konverzija teksta iz polaznih oblika zapisa (najčešće MS Word 97) obavljena je programom 2XML,³ koji je razvijen u Zavodu za lingvistiku Filozofskoga fakulteta Sveučilišta u Zagrebu u sklopu rada na Hrvatskome nacionalnom korpusu. Smjer je konverzije najčešće bio iz RTF u XML.

Nakon konverzije u XML sama se obrada dokumenta sastojala od segmentacije na rečenice <s> uz dodavanje ID oznaka rečenicama te provjere istovjetnosti broja odlomaka <p> kao pripreme za sravnjivanje.

3.3. Sravnjivanje

Za sravnjivanje je korištena DOS inačica programa Vanilla Aligner (Danielsson & Ridings, 1997), koja se pokazala posve dostatnom za potrebe manjega paralelnog korpusa kao što je ovaj slovensko-hrvatski. Kako sam program i nema dovoljno fleksibilan ulaz, XML dokumenti morali su mu se prilagoditi. U tom su procesu međutim zadržane XML oznake koje su i same ušle u postupak sravnjivanja. Time je program dobio više redundantnih podataka i mogao je obaviti sravnjivanje na kvalitetniji način.

Probni uzorak sačinjava osam međudržavnih sporazuma i ugovora između Republike Slovenije i Republike Hrvatske.⁴ Sami se XML dokumenti mogu vidjeti na slici 1.

3.4. Rezultati

Preliminarna je statistika probnoga uzorka po XML

The screenshot shows a Windows Notepad window titled "veterin_a1.txt - Notepad". The content displays a comparison of two XML documents, one from Slovenia and one from Croatia, using the Vanilla Aligner tool. The output includes several sections of XML code with color-coded syntax highlighting for tags and attributes. The code is primarily in black and red, with some blue and green elements. The text is in a monospaced font, and the Notepad interface is visible at the top with standard menu options like File, Edit, Search, and Help.

```
<HEAD type="main"> <HEAD type="mainheading"> <S id="veterin_hr.S1"> SPORAZUM </S> </HEAD> .EOS
<HEAD type="main"> <HEAD type="mainheading"> <S id="veterin_si.S1"> SPORAZUM </S> </HEAD> .EOS

.EOP

*** Lämk: 1 - 1 ***
<HEAD type="subheading"> <S id="veterin_hr.S2"> IZME&#272;U ULADE REPUBLIKE SLOVENIJE I ULADE REPUBLIKE
HRVATSKE O VETERINARSKOJ SURADNJI </S> </HEAD> .EOS
<HEAD type="subheading"> <S id="veterin_si.S2"> MED ULADO REPUBLIKE SLOVENIJE IN ULADO REPUBLIKE
HRVA&#352;KE O VETERINARSKEM SODELOVANJU </S> </HEAD> .EOS

.EOP

*** Lämk: 1 - 1 ***
<P> <S id="veterin_hr.S3"> Ulada Republike Slovenije i Ulada Republike Hrvatske (u dalnjem tekstu:
ugovorne stranke), u &#382;elji da unaprijede promet &#382;ivotinja i proizvoda &#382;ivotinjskog
podrijetla i s namjerom da zaprije&#269;e uno&#353;enje zaraznih bolesti &#382;ivotinja i po zdravlje
&#353;tetnih proizvoda &#382;ivotinjskog podrijetla, kao i da dalje razvijaju i u&#269;vrste
me&#273;usobnu suradnju u veterinarstvu utemeljenu na na&#269;elima jednakosti, uzajamnog &#353;tovanja
i zajedni&#269;ke dobrobiti, </S> </P> .EOS
<P> <S id="veterin_si.S3"> Ulada Republike Slovenije in Ulada Republike Hrv&#352;ke (v nadalnjem
besedilu: pogodbenici) sta se z &#382;eljo, da bi pospe&#353;ili promet z &#382;ivalmi in proizvodi
&#382;ivalskega izvora in z namenom, da bi prepre&#269;ili vnos ku&#382;nih bolezni &#382;ivali in
proizvodov &#382;ivalskega izvora, &#353;kodljivih za zdravje, in da bi &#353;e naprej razvijali in
u&#269;vrstili medsebojno sodelovanje v veterinarstvu, ki temelji na na&#269;elih enakosti, vzajemnega
spo&#353;tovanja in skupne blaginje, </S> </P> .EOS

.EOP

*** Lämk: 1 - 1 ***
<P> <S id="veterin_hr.S4"> dogovorile su se kako slijedi: </S> </P> .EOS
<P> <S id="veterin_si.S4"> dogovorili o naslednjem: </S> </P> .EOS

.EOP

*** Lämk: 1 - 1 ***
<DIV1 type="sub"> <HEAD type="article"> <S id="veterin_hr.S5"> &#268;lanak 1. </S> </HEAD> .EOS
<DIV1 type="sub"> <HEAD type="article"> <S id="veterin_si.S5"> 1. &#269;len </S> </HEAD> .EOS
```

Slika 2: Sravnjivanje Vanilla alignerom

³ Sam se program i njegovo funkcioniranje dijelom prikazuje u Tadić (2000).

⁴ Sporazumi su bili ovi: o znanstvenoj i tehnološkoj suradnji, o veterinarskoj suradnji, o socijalnom osiguranju, o uređivanju vodnogospodarskih odnosa, o zaštiti od prirodnih i civilizacijskih katastrofa, Suradnja na području obrazovanja za

elementima iznesena u Tablici 2.

	HR	SI
odломaka <p>	522	522
реџеница <s>	891	891
појавница <w>	13.549	13.307

Tablica 2: Broj <p>, <s> i <w> elemenata u probnom uzorku od 8 međudržavnih ugovora

Valja uočiti identičnost broja odlomaka i реџеница koja se pojavljuje zbog prirode pravnoga teksta. Tekstovi na oba jezika objavljeni su kao originalni i uskladieni već u izvorniku. Stoga su sva strojna sravnjivanja u ovom probnom uzorku oblika 1-1. Gotovo identično ponašanje može se naći u drugim paralelnim korpusima pravnih tekstova (v. Gamper, 2000). Dapače, kad se god pri pregledu sravnjivanja naišlo na 2-1 ili 1-2 sravnjivanje, to je redovito bio znak greške u ulaznim podacima, tj. greške u modulu za segmentaciju реџениca.

Rezultat sravnjivanja Vanillom mogu se uočiti na slici 2 odnosno, slici 3 u sažetijem zapisu.

```

<-> <body>
<link xtargs="veterin_hr.S1 veterin_si.S1" />
<link xtargs="veterin_hr.S2 veterin_si.S2" />
<link xtargs="veterin_hr.S3 veterin_si.S3" />
<link xtargs="veterin_hr.S4 veterin_si.S4" />
<link xtargs="veterin_hr.S5 veterin_si.S5" />
<link xtargs="veterin_hr.S6 veterin_si.S6" />
<link xtargs="veterin_hr.S7 veterin_si.S7" />
<link xtargs="veterin_hr.S8 veterin_si.S8" />
<link xtargs="veterin_hr.S9 veterin_si.S9" />
<link xtargs="veterin_hr.S10 veterin_si.S10" />
<link xtargs="veterin_hr.S11 veterin_si.S11" />
<link xtargs="veterin_hr.S12 veterin_si.S12" />
<link xtargs="veterin_hr.S13 veterin_si.S13" />
<link xtargs="veterin_hr.S14 veterin_si.S14" />
<link xtargs="veterin_hr.S15 veterin_si.S15" />
<link xtargs="veterin_hr.S16 veterin_si.S16" />
<link xtargs="veterin_hr.S17 veterin_si.S17" />
<link xtargs="veterin_hr.S18 veterin_si.S18" />
<link xtargs="veterin_hr.S19 veterin_si.S19" />
<link xtargs="veterin_hr.S20 veterin_si.S20" />
<link xtargs="veterin_hr.S21 veterin_si.S21" />
<link xtargs="veterin_hr.S22 veterin_si.S22" />
<link xtargs="veterin_hr.S23 veterin_si.S23" />
<link xtargs="veterin_hr.S24 veterin_si.S24" />
<link xtargs="veterin_hr.S25 veterin_si.S25" />
<link xtargs="veterin_hr.S26 veterin_si.S26" />
<link xtargs="veterin_hr.S27 veterin_si.S27" />
<link xtargs="veterin_hr.S28 veterin_si.S28" />
<link xtargs="veterin_hr.S29 veterin_si.S29" />
<link xtargs="veterin_hr.S30 veterin_si.S30" />
<link xtargs="veterin_hr.S31 veterin_si.S31" />
<link xtargs="veterin_hr.S32 veterin_si.S32" />
<link xtargs="veterin_hr.S33 veterin_si.S33" />
<link xtargs="veterin_hr.S34 veterin_si.S34" />
<link xtargs="veterin_hr.S35 veterin_si.S35" />
<link xtargs="veterin_hr.S36 veterin_si.S36" />
<link xtargs="veterin_hr.S37 veterin_si.S37" />
<link xtargs="veterin_hr.S38 veterin_si.S38" />
</body>

```

Slika 3: Sažet zapis sravnjivanja u kojem se navode samo vrijednosti id-atributa za <S>-ove

4. Zaključak

U radu je prikazan početak rada na projektu *Slovensko-hrvatski paralelni korpus* koji je odobrilo i finansijski podržalo slovensko i hrvatsko Ministarstvo znanosti i tehnologije. Korpus je time omogućio suradnju stručnjaka dvaju istovrsnih fakulteta. Do sada su sakupljeni tekstovi različitih funkcionalnih stilova i različitih područja (terminološka raznovrsnost). Oni zapravo predstavljaju kompromis između očekivane uporabnosti korpusa s jedne strane i same dostupnosti tekstova u digitalnom zapisu s druge strane. Naime, posljednjih desetak godina uočljivo je nepostojanje prijevoda sa slovenskog ili na slovenski i/ili hrvatski (osobito u digitalnom obliku), što je prouzročilo značajne teškoće oko prikupljanja građe za korpus. *Slovensko-hrvatski paralelni korpus* omogućit će niz različitih jezikoslovnih istraživanja: kontrastivnih, leksikografskih, didaktičko/metodičkih, a posebice znanost o prevodenju te razvitak jezičnih tehnologija za oba jezika. Potencijalni su korisnici korpusa osim istraživača i studenti zagrebačke slovenistike i ljubljanske kroatistike te prevoditelji kojima će korpus biti dostupan putem WWW-a kao dopunski izvor informacija, osobito u situaciji kada dvojezičnih hrvatsko-slovenskih (i obratno) rječnika zapravo nema.

5. Literatura

- Ahrenberg, Lars; Merkel, Magnus; Ridings, Daniel; Sígvall Hein, Anna & Tiedemann, Jörg, (1999). Automatic processing of parallel corpora: A swedish perspective. (<http://numerus.ling.uu.se/~corpora/plug/>)
- Danielsson, Pernilla & Ridings, Daniel. 1997, Practical presentation of a “vanilla” aligner, Presented at the TELRI Workshop on Alignment and Exploitation of Texts. Institute Jožef Stefan, Ljubljana (<http://svenska.gu.se/PEDANT/workshop/workshop.html>).
- Erjavec, Tomaž, 1999a. Making the ELAN Slovene/English Corpus. In Špela Vintar (Ed.), Proceedings of the workshop Language technologies — Multilingual Aspects, (pp. 23–30). Ljubljana: Department of Translation and Interpreting, Faculty of Arts, University of Ljubljana.
- Erjavec, Tomaž, 1999b. A TEI encoding of aligned corpora as translation memories. In Proceedings of the EACL-99 Workshop on Linguistically Interpreted Corpora (LINC-99), Bergen: ACL.
- Erjavec, Tomaž, 1999c. Slovensko-angleški korpus *Elan. Slavistična revija*, 47, 4:515-522. (<http://nl.ijs.si/elan>)
- Gamper, Johann, 2000. “A Parallel Corpus of Italian/German Legal Texts” u: LREC2000 Proceedings, Athens 2000-05-29–2000-06-02, Pariz-Atena 2000, 531-538.
- Juranić, Janko, 1986. Srbskohrvatsko-slovenski slovar, 3. izdaja, DZS, Ljubljana.
- Juranić, Janko, 1989. Slovensko-srbskohrvatski slovar, 2, popravljena izdaja, DZS–Školska knjiga, Ljubljana-Zagreb.
- Požgaj Hadži, Vesna, 1998. Razumijevanje znanstvenog diskursa u studenata slovenistike. *Filologija*. knj. 30-31, 509-518.
- Tadić, Marko, 2000. “Building the Croatian-English Parallel Corpus” u: LREC2000 Proceedings, Athens 2000-05-29–2000-06-02, Pariz-Atena 2000, str. 523-530.

Tiedemann, Jörg, 1998. Parallel corpora in Linköping,
Uppsala and Göteborg (PLUG). Work package 1.
Department of Linguistics, Uppsala University.
(<http://numerus.ling.uu.se/~corpora/plug/>)

6. Zahvala

Zahvaljujemo *Službenom listu Republike Slovenije* za
ustupljene digitalne oblike međudržavnih ugovora između
Republike Slovenije i Republike Hrvatske.