

OpenMT-2: Wikipedia eta Itzulpen Automatikoa biak elkarri laguntzen

Iñaki Alegria*, Unai Cabezón*, Unai Fernandez de Betoño*, Galder Gonzalez*, Mikel Iturbe*, Gorka Labaka*, Aingeru Mayor*, Kepa Sarasola*, Arkaitz Zubiaga*
(*) Ixa taldea (EHU) <http://ixa.si.ehu.es/openmt2>
(+) eu.wikipedia <http://eu.wikipedia.org>



GIZARTE-SAREAK

Jakina da Euskal Wikipediaren tamaina askoz txikiagoa dela gure inguruko erdarena baino. Itzulpen automatikoa ikertzen duen [OpenMT-2](#) proiektuaren¹ barruan informatikari buruzko Wikipediako 50 artikulu luze gehitzeko iniziatiba bat martxan jarri dugu. Matxin itzulpen-sistemak sortuko ditu lehen zirriborroak espanierako Wikipediatik itzulita, eta ondoren hainbat boluntarioren artean, eta eu.wikipedia elkarteak koordinatuta, zirriborro horiek zuzendu eta argitaratuko dituzte.

Esperimentzia aberasgarria izango da bi norabideetan. Wikipediarentzat esperimentzia onuragarria izango da 50 artikulu berri sortuko direlako, eta itzulpen automatikoarentzat ere bai, eskuz posteditatutako itzulpenekin 100.000 hitzeko corpusa batuko delako. Corpus hori, itzulpen-sistema automatikoen kalitatea hobetzeko funtsezko baliabide izango da, teknika estatistikoak erabiliz.

Lankidetza 2010ko hasieran hasi zen, orduan finkatu genituen proiektuaren nondik-norakoak. Geroago 2010 urtean zehar lau lan burutu ditugu:

- Aztertu ditugu antzeko proiektuak; adibidez: Kanadako talde batek (Simard et al., 2007) emaitza ederrak lortu zituen 100.000 hitzeko postedizio-corpusa eta teknika estadistikoak erabiliz. Ixa taldean ere, Gorka Labakaren tesi-lanean (Labaka, 2010), esperimentu batean egiaztatu dugu teknika horrek hobekuntza dakarrela espaniera-euskara sistema batean (Labaka, 2010).
- Itzuli nahi ditugun wikipedia sarreren zerrenda zehaztu dugu. Gaztelaniazko Wikipedian bai baina euskaraz ez dauden hainbat artikulu luze hautatu ditugu lehen urrats baterako. [Wikiproiektu bat](#)² abiatu da dagoeneko horretarako, bertan ikus daiteke sarrera aukeratuen lista.
- Interfaze bat egokitu dugu boluntarioek postedizioan erosoa lan egin dezaten. Lehenago hiru aukera posible aztertu ditugu:
 - World Wide Lexicon Translator ([WWL](#)³), Firefox-erako gehigarri bat webguneak itzulita ikusi ahal izateko, konbinatzen du giza-itzulpena eta itzulpen automatikoa, baina posteditatzeko intefazea ez dabil oso ondo;
 - Google Translation Toolkit tresnak Wikipediako sarrerak itzultzea laguntza eskaintzen du baina software libre eta irekia ez denez ezin izan dugu moldatu gure beharretara;
 - [OmegaT](#)⁴ software libreko itzulpen memoria erabiltzeko tresna bat.

OmegaT software librea denez, moldatzeko aukera eman digu eta horregatik aukeratu dugu.

- Informatikako gaietan hobeto itzultzea Matxin_Inf_2010 bertsio berri bat prestatu dugu.

Ikerketa honen azken esperimentua 2011ko bukaeran bukatu nahi dugu, bi urratsetan:

1. Wikipediako 5 sarrera (~5.000 hitz) itzuli euskarara hiru modutan:
 - Itzulpen automatikoa erabili gabe.
 - Matxin_Inf_2010 bertsio erabilita
 - Matxin_Inf_2010 eta postedizioko corpusa erabilita.
2. Konparatzea hiru sistemek emaitzak, eta identifikatzea gero ea zein baldintzetan b eta c aukerak diren hoherenak.

Gure hipotesia da baietz, hobekuntza lortuko dugula Matxin itzulpen-sisteman esperimentu honen emaitzei esker. Baino esperimentuarekin egiaztatu beharko dugu hipotesi hori. Bitartean lortuko dugu, batetik, 50 sarrera luze gehiago sortzea euskal Wikipedian, eta bestetik, Matxin sistemaren erabilgarritasunaren azterketa praktikoa, hainbat boluntarioren laguntzarekin. Emaitzak onak balira Wikipediako beste alorretan ere aplikatu ahal izango da teknika hau.

1 <http://ixa.si.ehu.es/openmt2>

2 http://eu.wikipedia.org/wiki/Wikiproiektu:OpenMT2_eta_Euskal_Wikipedia

3 <https://addons.mozilla.org/en-US/firefox/addon/13897>

4 <http://www.omegat.org/>

Erreferentziak

- Alegria I., Díaz de Ilarza A., Labaka G., Lersundi M., Sarasola K. 2008. [Itzulpen automatikoa: aukerak, arazoak eta erronkak. Bat Soziolinguistika.](#) 66. zenb. 107-122 orr. ISSN:1130-8435
- Alegria I., Arregi X., Díaz de Ilarza A., Labaka G., Lersundi M., Mayor A., Sarasola K. 2008. [Strategies for sustainable MT for Basque: incremental design, reusability, standardization and open-source.](#) Proceedings of the IJCNLP-08, pp: 235-243. Hyderabad, India.
- Labaka, G. EUSMT: Incorporating Linguistic Information into SMT for a Morphologically Rich Language. Its use in SMT-RBMT-EBMT hybridation. Doktorego-tesia. *Lengoia eta Sistema Informatikoak Saila (UPV-EHU). Donostia. 2010* <http://ixa.si.ehu.es/Ixa/Argitalpenak/Tesiak/1271852575/publikoak/GorkaLabaka.Thesis.pdf>
- Simard, M., Ueffing, N., Isabelle, P., and Kuhn, R. 2007. Rule-based translation with statistical phrase-based post-editing Proceedings of the Second Workshop on Statistical Machine Translation. pp:203-206. Prague, Czech Republic.
- Díaz de Ilarza A., Labaka G., Sarasola K. 2008. Statistical Post-Editing: A Valuable Method in Domain Adaptation of RBMT Systems MATMT2008 workshop: Mixing Approaches to Machine Translation. pp.35-40.