

# OPENMT-2: Traducción automática híbrida y evaluación avanzada

---

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

TIN2009-14675-C03-01 y 02

Kepa Sarasola

Ixa Group. Euskal Herriko Unibertsitatea

Lluís Márquez

TALP, Universitat Politècnica de Catalunya

Jornadas de Seguimiento de Proyectos MICINN

5 de Septiembre de 2011, A Coruña

# ● ● ● | Grupo Ixa (UPV-EHU)

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

Grupo Ixa de procesamiento de la lengua

Universidad del País Vasco / Euskal Herriko Unibertsitatea

- Doctores: 7
- No doctores: 4
- Funcionarios ó profesorado permanente : 5
- Otro profesorado: 4
- Becarios FPI: 0
- Otros becarios: 2




# NLP Research Group, TALP, UPC



<http://nlp.lsi.upc.edu>

Universidad Politécnica de Cataluña

- Doctores: 7
- No doctores: 4
- Funcionarios: 3
- Otro profesorado: 3
- Becarios FPI: 1
- Otros becarios: 4



# Objetivos (Goals)


Machine Translation (MT) technology to generate:

- robust, high-quality combined MT systems.
- improved evaluation metrics and methodologies.

5 main areas:

- Collection, annotation and exploitation of multilingual corpora.
- Further development of the current single-paradigm translation systems.
- Pre-edition, post-edition and system improving based on collaboration with a web2.0 community.
- Combining and hybridizing MT paradigms.
- Advanced evaluation for MT.


Four different languages: English, Spanish, Catalan and Basque.



# Objetivos (Goals)

The main innovative points of the proposal are:

- Design of hybrid systems combining traditional linguistic rules, example-based methods and statistical methods
- Use of advanced morphological, syntactic and semantic processing in MT
- Research taking advantage of a web community of posteditors (2.0 oriented)
- Use of more realistic metrics in MT evaluation, improving its reliability
- Creation of a web-based suite of MT systems and tools for evaluation and error analysis




# Objetivos (Goals)

The consortium is composed by two universities:

- University of the Basque Country (UPV/EHU)
- Technical University of Catalonia (UPC)


Several companies and foundations with activities in closely related areas serve as supervision EPOs for the project:

- Foundations: Elhuyar. i2CAT, eu.wikipedia.
- Companies: Eleka, Imaxin, Semantix, Translendum SL



# Objetivos alcanzados

- Collection, annotation and exploitation of multilingual corpora (**%100**).
  - 10 corpora and tools available in the project website  
[http://ixa.si.ehu.es/openmt2/baliabideak\\_html](http://ixa.si.ehu.es/openmt2/baliabideak_html)
- Further development of the current single-paradigm translation systems. (**%100**)
  - <http://ixa2.si.ehu.es/openmt-demo>
- Combining and hybridizing MT paradigms. (**%70**)



## Objetivos parcialmente alcanzados

- Pre-edition, post-edition and system improving based on collaboration with a web2.0 community. (**%50**)
  - Ongoing [Wikiproject](#) (openmt2 - eu.wikipedia) to collect 100.000 words corpus with hand made corrections for MT outputs (2011 December).
  - Experimentation in 2012.
- Advanced evaluation for MT (**%50**)
  - Creation of [Asiya](#) opensource evaluation system.  
<http://www.lsi.upc.edu/~nlp/Asiya/>
  - Adaptation to enable its use with Basque (2012)
  - The main researcher is working now at Google



# Producción Científica

Número de JCR y Número de congresos CORE aceptados.

2010 y 2011

**59 publicaciones en total:**[http://ixa.si.ehu.es/openmt2/argitalpenak\\_html](http://ixa.si.ehu.es/openmt2/argitalpenak_html)

24 sobre Traducción Automática + 35 sobre Tecnología de la Lengua

**Número de JCR/Scopus:** 4

(Machine Translation Journal,  
Natural Language Engineering, Applied soft computing)

**Número de congresos CORE aceptados:** 16

(ACL, Coling, EAMT, MT-Summit,  
AMTA, EMNLP, Interspeech)

Número de artículos en revistas o libros: 8

Número de artículos en congresos  
con 3 evaluadores y (admisión<%50) : 16

Número de otras publicaciones : 15



# Producción Científica

Listado de las 5 publicaciones más relevantes.

Aingeru Mayor, Iñaki Alegria, Arantza Díaz de Ilarraz, G. Labaka, M. Lersundi, K. Sarasola 2011.  
**Matxin, an open-source rule-based machine translation system for Basque.**  
Machine Translation Journal. volume 25, number 1, July 2011.

Jesús Giménez and Lluís Márquez. 2010.  
**Linguistic Measures for Automatic Machine Translation Evaluation.**  
Machine Translation Journal, volume 24, numbers 3-4, December 2010.

Jesús Giménez and Lluís Márquez. 2010.  
**Asiya: An Open Toolkit for Automatic Machine Translation (Meta-)Evaluation.**  
The Prague Bulletin of Mathematical Linguistics, No. 94, 2010.

Cristina España, Gorka Labaka, Lluís Márquez, Arantza Díaz De Ilarraz and Kepa Sarasola 2011.  
**Hybrid Machine Translation Guided by a Rule-Based System.**  
XIII Machine Translation Summit, Xiamen, China

Pighin, Daniele, and Márquez Lluís 2011.  
**Automatic Projection of Semantic Structures: an Application to Pairwise Translation Ranking.**  
Fifth Workshop on Syntax, Semantics and Structure in Statistical Translation (SSST-5),  
ACL, Portland, Oregon, 2011.

Para más información: [http://ixa.si.ehu.es/openmt2/argitalpenak\\_html](http://ixa.si.ehu.es/openmt2/argitalpenak_html)

# Producción Científica

## Eventos organizados

Organización conjunta de un workshop internacional

“Using Linguistic Information for Hybrid Machine Translation”

Barcelona, 18-Noviembre- 2011.

<http://ixa2.si.ehu.es/lihmt2011/>

Colaboración con investigadores punta en Traducción Automática a nivel mundial:

- Comité de programa.

**David Farwell**, Josep M. Crego (LIMSI/CNRS, France), Chris Dyer (Carnegie Mellon University, US), **Marcello Federico** (Fondazione Bruno Kessler, Italy), **Mikel Forcada** (University of Alacant, Alicante), **Adrià de Gispert** (University of Cambridge, UK), **Kevin Knight** (Information Sciences Institute, US), **Philipp Koehn** (University of Edinburgh, UK), Patrik Lambert (Université du Maine, France), **José B. Mariño** (Technical University of Catalonia, TALP, Barcelona), **Hermann Ney** (RWTH-Aachen, Germany), Aarne Ranta (Chalmers University of Technology, Gothenburg, Sweden), Marta R. Costa-jussà (Barcelona Media, Barcelona), Felipe Sánchez-Martínez (University of Alacant, Alicante), **Dekai Wu** (Hong Kong University of Science and Technology, China)...

- Ponentes invitados.

- **Ondřej Bojar** (Charles University, Czech Republic)

- **Alon Lavie** (Carnegie Mellon University, Pennsylvania)

- **Lucia Specia** (University of Wolverhampton, UK)

# Transferencia


Uso de resultados del proyecto en la industria.

**Matxin.** Software registrado (SS-0409-2008)

1589 descargas del motor de traducción Matxin en Sourceforge.

<http://sourceforge.net/projects/matxin/files/stats/timeline?dates=2006-01-24+to+2011-07-19>

matxin Beta by gorka\_lab, ialegria, murgilduta



# Transferencia

Uso de resultados del proyecto en la industria.

**Matxin.** Software registrado (SS-0409-2008)

Traducción en web castellano-euskara (Matxin-Opentrad, <http://www.opentrad.com/es>)

**Opentrad**  
machine translation

GL ES CA EU EN PT FR

Traductor Opentrad Planes y precios Actualidad Partner Danos tu opinión

**TRADUCTOR GRATUITO ONLINE**

Introduce el texto  
Quiero ir a Galicia.

Selección del idioma de origen y el de destino  
Español Euskera

Marcar palabras desconocidas

Galiziara joan nahi dut.

Síguenos

Usuarios de MATXIN-OPENTRAD año 2010.  
2.777 sesiones únicas (con 2,5 llamadas de media)

Nº de usuarios

Mes (en 2010)	Nº de usuarios
Ene	~220
Feb	~400
Mar	~420
Abr	~150
May	~150
Jun	~500
Jul	~150
Ago	~100
Sep	~200
Oct	~250
Nov	~250
Dic	~200

Introduce la dirección de la página web  
http://

yesterday - reply - retweet - favorite

Revistas de Traducción (via calusTRA) <http://t.co>

# Transferencia

Uso de resultados del proyecto en la industria.

**Matxin.** Software registrado (SS-0409-2008)

Uso del traductor Matxin dentro de un [Wikiproyecto](#) web2.0 para incrementar la *Wikipedia en euskara* con 100 artículos nuevos en el 2011 (100.000 palabras)

The screenshot shows a section of the Euskara Wikipedia titled "Kode ireki". A red oval highlights an information box containing text about the OpenMT-2 project. The text reads:

Artikulu hau itzulpen automatikoaren laguntzaz egin da,  
OpenMT-2 wikiproiektuaren barnean.  
Artikulua hobe dezakezu, baina proiektua bukatu arte  
(2012an) txantiloi hau ez ezabatu, mesedez.

Below the box, there is a summary of the "Kode ireki" concept and a sidebar with links to "Eduki-taula" and a list of 5 items. To the right, there is a box for the "Open Source" logo.

**Kode ireki**

Artikulu hau hobe dezakezu... bada

**Kode ireki** modu askean banatu eta garatu den softwarea definitzen duen terminoa da. Kode irekiak orientazio handiago du partekatzeko onura praktikoetara **software libreak** azpimarratzen duen aspektu moral edota filosofikoien baino

**Eduki-taula [ezkutatu]**

- 1 Historia
- 2 Ideia baten kronologia
- 3 "Kode irekiko" mugimendua
- 4 Erreferentziak
- 5 Ikus, gainera

Open Source-ko Logotipoa

# Transferencia

Uso de resultados del proyecto en la industria.

*Asiya. Sistema de evaluación de código abierto.*

<http://www.lsi.upc.edu/~nlp/Asiya/>

## The Asiya Open Toolkit for Automatic MT (Meta-)Evaluation

Asiya has been designed to assist both system and metric developers by offering a rich repository of metrics and meta-metrics. Asiya has been developed at [TALP Research Center NLP group](#), in [Universitat Politècnica de Catalunya](#), as an evolution, extension, refactoring, and finally a replacement for its predecessor, [IQMT](#).

### Download

Latest development version may be downloaded through subversion.

- svn co <http://svn-rdlab.lsi.upc.edu/subversion/asiya/public> asiya

~~Everyone is allowed to check out (User: reader, Password: reader).~~

Asiya is also open to public contribution. If you feel like helping us in the development, please, e-mail us at [jgimenez](#) so we grant you with the necessary permissions.

The Asiya framework is released under the [GNU Lesser General Public License \(LGPL\)](#) of the [Free Software Foundation](#). This means that it may be linked to and used by commercial software packages. But the license also enforces that any changes or improvements made to the library must be redistributed under LGPL terms.

# Resultados: Formación

Tesis de doctorado leídas (2010-2011)

Gorka Labaka (Marzo 2010, Doctorado europeo)

**EUSMT: Incorporating Linguistic Information into SMT for a Morphologically Rich Language. Its use in SMT-RBMT-EBMT hybridation.**

Kepa Sarasola y Arantza Diaz de ilarrazia.

Beñat Zapirain (Febrero 2011, Doctorado europeo).


**Semantic Role Labeling: Role Inventories and Selectional Preferences / Rol Semantikoen Etiketatze Automatikoa: Rol Multzoak eta Hautapen Murriztapenak**

Eneko Agirre Bengoa y Lluís Màrquez Villodre

Bertol Arrieta (Enero 2010)

**Azaleko sintaxiaren tratamendua ikasketa automatikoko tekniken bidez: euskarako kateen eta perpausen identifikazioa eta bere erabilera komazuzentzaile batean.**

Iñaki Alegria y Arantza Diaz de Ilarrazia



# Resultados: Formación

## Tesis de máster o PFC

- **Itzulpen-sistema desberdinaren irteera bistaratzeko interfazea.**  
Aritz Sala Mayor  
2010-04-15
- **Postedizio-interfazearen diseinua eta implementazioa itzulpen automatikoko sistemek ebaluaziorako.**  
Mireia Lecea Urrutia.  
2010-09-17. Matrícula de honor
- La FPI del proyecto Eva Martínez ha completado los cursos de Máster satisfactoriamente durante el curso académico 2010-2011. Ahora está empezando la tesis de máster con finalización prevista para Febrero de 2012: “**Robust POS tagging for Machine Translation**”

# Colaboraciones internacionales

Grupo Ixa (EHU) <http://ixa.si.ehu.es/Ixa/Nazioarteko%20harremanak>

international relations



University of Bari



Centro de Lingüística Aplicada,  
Santiago de Cuba



PATHS project



University of Helsinki



Europeana

VUNET



University of Amsterdam




University of Tromsø



CLARIN project



Dublin City University



# Colaboraciones internacionales

## Grupo TALP (UPC)

Personas y universidades con las que se colabora

- **Grupo de Investigación del DISI de la Universidad de Trento (Alessandro Moschitti) y la Fondazione Bruno Kessler de Trento (profesor Marcello Federico).** Lluís Màrquez realizó una estancia corta en Agosto-Septiembre de 2010. Como consecuencia de esta relación el grupo UPC ha incorporado en octubre de 2010 un investigador post-doctoral proveniente de estos grupos, Daniele Pighin.
- Contactos con los investigadores **Lucia Specia (University of Wolverhampton) y Mikel Forcada (Universidad de Alicante)** han propiciado las visitas en la primavera de 2011 de un estudiante de doctorado (Mariano Felice, 5 meses) y un investigador post-doctoral (Felipe Sánchez, 3 meses) que presumiblemente se unirán al grupo en la línea de investigación sobre medidas de evaluación y su aprendizaje.
- Los grupos de investigación de los proyectos europeos FAUST y MOLTO. Sobre todo **University of Cambridge (Bill Byrne), Charles University, Prague (Jan Hajic) y University of Gothenburg (Aarne Ranta)**.



# Colaboraciones internacionales


## Proyectos internacionales financiados

Proyectos europeos con temática de MT

- **FAUST**: Feedback Analysis for User Adaptive Statistical Translation (FP7-ICT-2009-4-247762, 2010-2012). <http://www.faust-fp7.eu/>
- **MOLTO**: Multilingual On-Line Translation (FP7-ICT-2009-4-247914, EC, 2010-2012). <http://www.molto-project.eu/>

Otros proyectos europeos


- **PATHS** - Personalised Access To cultural Heritage Spaces (STREP, ICT-2011-270082, 2011-2012, <http://www.paths-project.eu> )
- **KYOTO**: knowledge yielding ontologies for transition-based organizations (STREP, ICT-2007-211423, 2007-2010, <http://www.kyoto-project.eu>)



# COORDINACIÓN

## Evaluación de la coordinación


- Creación de sitio web público del proyecto.  
<http://ixa.si.ehu.es/openmt2>
- Creación de sitio web privado del proyecto.
- Cuatro reuniones de coordinación
- Estancia de 6 meses del IP de la UPC en Donostia.
  - => Creación de un prototipo híbrido de traducción
  - => Dos publicaciones conjuntas
- Organización conjunta de un workshop internacional.  
“Using Linguistic Information for Hybrid Machine Translation”  
Barcelona 2011.  
<http://ixa2.si.ehu.es/lihmt2011/>



# COORDINACIÓN


## Publicaciones conjuntas

- **Hybrid Machine Translation Guided by a Rule-Based System.**  
C. España, G. Labaka, L. Marquez, A. Diaz de Ilarrazo, K. Sarasola  
MT-summit. China 2011.
- **Divergences between manual and automatic evaluation.**  
C. España, G. Labaka, L. Marquez, A. Diaz de Ilarrazo, K. Sarasola  
Submitted to the LIHMT Workshop. Barcelona 2011.



# Previsión de desarrollos futuros

- Combining and hybridizing MT paradigms. (**%30**)
  - Experimenting with new features to improve the results of the hybrid system.
  - Use of manual evaluation to optimize hybridization.
- Pre-edition, post-edition and system improving based on collaboration with a web2.0 community. (**%50**)
  - Ongoing Wikiproject (openmt2 - eu.wikipedia) to collect 100.000 words corpus with hand made corrections for MT outputs. (December 2011)
  - Experimentation with statistical postedition.
- Advanced evaluation for MT (**%50**)
  - Extension of the Asiya suite with evaluation measures for Basque.
  - Asiya Interface (graphical and web-based) for error analysis.
  - Adequacy-based confidence estimation measures by projecting syntactic/semantic structures.



# OPENMT-2: Traducción automática híbrida y evaluación avanzada

<http://ixa.si.ehu.es/openmt2>  
(TIN2009-14675-C03-01 y 02)

Kepa Sarasola

Ixa Group. Euskal Herriko Unibertsitatea  
kepa.sarasola@ehu.es

Lluís Márquez

TALP, Universitat Politècnica de Catalunya  
lluism@lsi.upc.edu