

**La technologie de la langue  
comme un outil efficace pour la promotion  
des langues avec peu de ressources.  
Le cas de la langue basque.**



Iñaki Alegria, Xabier Artola, Arantza Diaz de Ilarraza  
et **Kepa Sarasola**

Groupe de recherche Ixa (*Ixa taldea*)  
Faculté de Informatique  
Université du Pays Basque

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



Paris, 19-02-2015

# Contenu de la présentation

- Les langues dans le contexte des technologies de l'information et des communications (TIC), et de la technologie du langage (TL).
- Le groupe de recherche Ixa.
  - Stratégie de développement : le traitement de la langue basque dans le groupe Ixa.
- Conclusions

# Les langues dans le contexte des TIC et de la TL

- Réseau d'Excellence META-NET.
  - Les langues dans le Web, les technologies de la langue, des opportunités que ces technologies peuvent nous offrir.
  - Résultats pour le basque (comparés au français et à l'anglais)
- Comment les langues font-elles face aux défis des TIC et de la TL ?
  - Certains paramètres pour classer les langues.
  - Quelles sont les langues avec « moins de ressources » ? Six niveaux différents.

# META-NET

- META-NET, l'Alliance Technologique pour une Europe multilingue : réseau d'excellence soutenu par la Commission Européenne.
- 50+ laboratoires de recherche du domaine des sciences et technologies de la langue, dans une trentaine de pays.
- Collection de livres blancs sur les technologies de la langue : analyse de l'état des ressources et des technologies de la langue pour 31 langues européennes.


# META-NET

- META-NET, l'Alliance Technologique pour une Europe multilingue : réseau d'excellence soutenu par la Commission Européenne.
- 50+ laboratoires de recherche du domaine des sciences et technologies de la langue, dans une trentaine de pays.
- Collection de livres blancs sur les technologies de la langue : analyse de l'état des ressources et des technologies de la langue pour 31 langues européennes.



# META-NET: Conclusions et résultats pour le basque

- Dans le domaine des technologies de la langue, la langue basque montre un certain nombre de produits, de technologies et de ressources.
- Le basque est l'une des langues de l'UE qui ont besoin encore des recherches plus poussées pour que les solutions technologiques soient prêtes pour une utilisation quotidienne.
- Le développement de technologie de haute qualité pour le basque est urgent et d'une importance capitale pour la préservation de la langue.
- On va pas entrer dans des détails sur les produits et technologies recensés dans le rapport...



# META-NET: résultats pour le basque

	Quantity	Availability	Quality	Coverage	Maturity	Sustainability	Adaptability
<b>Language Technology: Tools, Technologies and Applications</b>							
Speech Recognition	2	1	1	1	4	3	2
Speech Synthesis	2	3	4	4	4	3	3
Grammatical analysis	4	2.5	4	4	4	2.5	2.5
Semantic analysis	1	1.5	2	1	1	1	1
Text generation	1	0	0	0	0	0	0
Machine translation	3	5	2	3	3	2	2
<b>Language Resources (Resources, Data and Knowledge Bases)</b>							
Text corpora	2	4	3	2	3	4	2.5
Speech corpora	3	2	3	2	3	3	2
Parallel corpora	2	4	2	2	2	2	1
Lexical resources	4	4	4	5	5	4	3
Grammars	2	2	2	2	2	2	2

7: State of language technology support for Basque

# META-NET: résultats pour le français

	Quantité	Disponibilité	Qualité	Couverture	Maturité	Pérennité	Adaptabilité
<b>Technologies de la langue</b>							
Reconnaissance de la parole	4	3	4	4	4	3	3
Synthèse vocale	4	3	4	4	4	3	3
Analyse grammaticale	4	4	4	4	4	3	3
Analyse sémantique	3	3	3	3	3	2	2
Génération de texte	3	2	3	3	3	2	2
Traduction Automatique	5	4	4	4	4	3	3
<b>Ressources linguistiques</b>							
Corpus de textes	4	3	4	4	4	4	3
Corpus de parole	4	3	4	4	4	4	3
Corpus parallèles, Mémoires de traduction	4	3	4	4	4	4	3
Ressources lexicales	4	3	4	4	4	4	3
Grammaires, Modèles de langage	3	3	4	4	3	3	3

14 : Tableau réduit de la situation estimée des technologies de la langue et des ressources linguistiques pour le français.

# META-NET: résultats pour l'anglais

	Quantity	Availability	Quality	Coverage	Maturity	Sustainability	Adaptability
Language Technology: Tools, Technologies and Applications							
Speech Recognition	5	3	5	5	4	2	3
Speech Synthesis	5	3	4.5	5.5	4	2	3
Grammatical analysis	5	5	5.5	4.5	4.5	3	4
Semantic analysis	3	2	3	3	2.5	2	2
Text generation	3	3	3.5	2.5	2.5	2	2.5
Machine translation	4	4	3.5	4	4	2	2
Language Resources: Resources, Data and Knowledge Bases							
Text corpora	5	4	5.5	4	5	2.5	4
Speech corpora	5	2	6	5.5	5	3	3
Parallel corpora	4.5	4.5	5	5	3.5	3	3
Lexical resources	4	6	5	5	4.5	4.5	4.5
Grammars	3.5	2.5	4	4	2.5	4	1.5

8: State of language technology support for English

# Comment les langues font-elles face aux défis des TIC et des TL ?


- Il n'est pas facile à obtenir des chiffres concernant les quantités de ressources pour les différentes langues sur l'Internet.
- On devra utiliser des données publiques plus spécifiques :
  - nombre d'utilisateurs
  - nombre de documents sur l'Internet
  - nombre d'articles dans la Wikipedia
  - etc.

# Comment les langues font-elles face aux défis des TIC ?

## Nombre d'usagers [Internet World Stats 2010]

- Anglais :
  - 536 millions d'usagers
  - 27%
- Top 10 langues :
  - 1.616 millions d'usagers
  - 82%
- Le reste des langues :
  - 351 millions d'usagers
  - 17,8% des usagers

Top Ten Languages in the Internet  
2010 - in millions of users



Source: Internet World Stats - [www.internetworldstats.com/stats7.htm](http://www.internetworldstats.com/stats7.htm)  
Estimated Internet users are 1,966,514,816 on June 30, 2010  
Copyright © 2000 - 2010, Miniwatts Marketing Group

# Comment les langues font-elles face aux défis des TIC ?

- Nombre de documents sur le Web
  - Il y peu de statistiques fiables pour les différentes langues
  - Une étude sur la présence des langues romanes (Latin Union, 2007) indiquait :
  - 45% des pages Web sont écrites en anglais
  - 7,80% en espagnol
  - 5,9% en allemand
  - 4,41% en français
  - 2,66% en italien
  - 1,39% en portugais
  - 0,28% en roumain
  - 0,14% en catalan
  - ...

# Comment les langues font-elles face aux défis des TIC ?

## Nombre d'entrées dans Wikipedia

[http://meta.wikimedia.org/wiki/List\\_of\\_Wikipedias](http://meta.wikimedia.org/wiki/List_of_Wikipedias)

- Articles en 286 langues (Juin 2014).
- *Top 10* :
  - Anglais: 4,54 millions d'articles
  - Hollandais : 1,78 M
  - Allemand : 1,73 M
  - Suédois : 1,63 M
  - Français : 1,52 M
  - Italien, russe, espagnol, polonais et waray-waray.
- Après:
  - 14ème: Portugais (830 K)
  - 17ème: Catalan (429 K)
  - 35ème: Basque (181 K)
  - 54ème: Occitan (87 K)
  - 71ème: Breton (50 K)
  - ...

# Comment les langues font-elles face aux défis des TL ?

- Plusieurs référentiels publics (ressources et outils) :
  - ELRA : *European Language Resources Association*
  - LDC : *Linguistic Data Consortium*
  - ACLWiki : *Association for Computational Linguistics*
  - NLSR : *Natural Language Software Registry (DFKI)*
  - *yourdictionary.com* : site web de dictionnaires
  - ...

# Comment les langues font-elles face aux défis des TL ?

- Ces sources d'information ne sont pas toujours complètes
  - les référentiels mentionnent toujours les produits qu'ils offrent
  - ils gèrent les ressources et vendent certains d'entre eux
  - les sites du type wiki sont gérés par des volontaires (valables juste pour consultation)
- On peut trouver des ressources et d'outils pour le basque dans ces référentiels : 6 dans ELRA, 15 dans ACLWiki, 3 dans NLSR, 9 dicos dans *yourdictionary.com*...

# Comment les langues font-elles face aux défis des TL ?




## ***ELRA European Language Resources Association***

- 1000+ ressources pour 60 langues.
- Ressources distribuées par l'agence ELRA  
(certains produits sont gratuits pour la recherche).
- 6 produits pour le basque.
- *The Universal Catalogue* :
  - Récemment ajouté par ELRA.
  - Enrichissement collaboratif, collecte d'information.
  - Il y en a d'autres produits non distribués par ELRA.
  - Le catalogue n'offre pas de fonctionnalité *Recherche par langue*.

# Comment les langues font-elles face aux défis des TL ?

## **LDC *Linguistic Data Consortium***

- 500+ ressources pour 82 langues.
- La recherche par langue est possible.
- Pas de produits pour le basque.




The screenshot shows the LDC Catalog website. At the top left is the LDC logo. A navigation bar contains links: About LDC, Members, Catalog (highlighted), Projects, Papers, LDC Online, Search / Help, Contact Us, UPenn, and Home. Above the main content area, there are links: Obtaining, Using, Providing, and Creating Data. Below the navigation bar, there are links: [LDC Catalog](#) | [By Type and Source](#) | [By Year](#) | [Top Ten](#) | [Projects](#) | [Catalog Search](#). The main heading is "The LDC Corpus Catalog". Below this, a paragraph states: "The LDC's Catalog contains hundreds of corpora of language data. You can use the navigation bar above or the links below to explore the various views of the catalog:"

# Comment les langues font-elles face aux défis des TL ?

## ***ACLwiki Association for Computational Linguistics***

- Ressources pour 73 langues.
- La recherche par langue est possible.
- 15 produits pour le basque.




The screenshot shows a Wikipedia-style page layout. On the left is a navigation sidebar with a red logo and a list of links: Main page, Community portal, Current events, Recent changes, Random page, and Help. The main content area has tabs for 'page', 'discussion', 'view source', and 'history'. The title is 'List of resources by language'. Below the title is a description: 'List of pages which give links and commentary on compu'. Under 'Quick Links:', there are two items: 'Resources for English' and 'Resources for Multilingual Applications'. A section header 'A' is visible. At the bottom, a 'Contents' box lists links for 'Top - 0-9 A B C D E F G H I J K L M N O P Q R S'.

# Comment les langues font-elles face aux défis des TL ?

## **NLSR *Natural Language Software Registry* (DFKI)**

- Ressources pour 30 langues.
- La recherche par langue est possible.
- 3 produits pour le basque.
- 59 produits pour n'importe quelle langue.



The image shows a screenshot of the NLSR website. On the left, there is a vertical navigation menu with five wooden-style buttons labeled 1 through 5: '1 info', '2 sections', '3 queries', '4 submit', and '5 faq'. The main content area has a light beige background. At the top right of this area, the title 'What is the Natural Language Software Registry?' is displayed in a bold, italicized serif font. Below the title, there are two columns of text. The left column begins with 'The Natural Language Software Registry (NLSR) is a concise summary of the capabilities and sources of a large amount of natural language processing (NLP) software available to the NLP'. The right column begins with 'While the NLSR concentrates on listing NLP software, it does not exclude the listing of Natural Language Resources (NLR), since we would also like to include resources which are strongly related to'.

# Comment les langues font-elles face aux défis des TL ?

## *yourdictionary.com*

- Ressources lexicales en ligne pour 300+ langues.
- La recherche par langue est possible.
- 9 liens vers des dictionnaires du basque (même s'il y a > 50).



[Dictionary Home](#) » [Languages](#) » [Foreign Language Online Dictionaries and Free Translation links](#)

## Foreign Language Online Dictionaries and Free Translation links

There are [6,800 known languages](#) spoken in the 200 countries of the world. 2,261 have writing systems (the others are only spoken) and about 300 are represented by on-line [dictionaries](#) as of May 11, 2004. Below are the ones we currently list. New [languages](#) and dictionaries are constantly being added to [yourDictionary.com](#); as a result, we have the widest and deepest set of dictionaries, grammars, and other language resources on the web.


# Comment les langues font-elles face aux défis des TL ?

- Présence/absence des TL dans des services les plus populaires :
  - traitement de texte
  - moteurs de recherche
  - traduction automatique
  - ...
- Traitement de texte : le basque est présent dans les deux programmes les plus utilisés (vérification et correction d'orthographe, notamment).
  - *MS Word* : 91 langues
  - *Libreoffice* : 104 langues
- Moteurs de recherche :
  - *Google* : ~50 langues sont identifiées
- Systèmes de traduction automatique :
  - *Babelfish* : 14 langues
  - *Google Translate* : ~80 langues (y compris le basque)

# Les langues du monde et leurs ressources langagières

Quelles sont les langues avec « moins de ressources » ?

- La réponse est relative
- On peut distinguer six niveaux différents



# Les langues du monde et leurs ressources langagières

- Premier niveau : l'anglais.
  - 27% des usagers de l'Internet.
  - 45% des pages web.
  - 62% des ressources langagières dans le LDC.
  - 51% des ressources langagières dans ELRA.
  - Pratiquement tous les types d'applications du langage existent pour l'anglais.

# Les langues du monde et leurs ressources langagières

- Deuxième niveau : *top 10* langues dans le Web
  - 82% des usagers de l'Internet (y compris l'anglais).
  - Le développement actif de ressources langagières continue.
  - La plupart des applications de la TL y sont représentées.
  - La plupart des ressources décrites dans LDC ou ELRA sont disponibles pour ces langues :
  - 45,79% pour l'allemand, 41,27% pour le français, 40,76% pour l'espagnol, 36,24% pour l'italien, 31,31% pour le portugais...
  - Streiter *et al.* (2006) utilisent le terme *central languages* pour se référer à cet ensemble de langues.

# Les langues du monde et leurs ressources langagières

- Troisième niveau : les langues qui possèdent une ou plusieurs applications de technologie langagière
  - 60 langues dans ELRA
  - 82 dans LDC
  - 73 dans ACLWiki
  - 30 dans NLSR

# Les langues du monde et leurs ressources langagières

- Quatrième niveau : des langues qui possèdent des ressources lexicales, voire des dictionnaires, en ligne
  - 307 langues in *yourdictionary.com*
  - Pratiquement le même ensemble de langues présentes dans la Wikipedia (286 langues).


# Les langues du monde et leurs ressources langagières

- Cinquième niveau : des langues qui possèdent de système d'écriture (Borin, 2009)
  - 2.000+ langues
- Sixième niveau : des langues non-écrites
  - 4.500+ langues

# Les langues du monde et leurs ressources langagières

Quelles sont les langues avec « moins de ressources » ?

- La réponse est relative
- On peut distinguer six niveaux différents



# Les langues du monde et leurs ressources langagières

- Cette typologie de 6 niveaux nous donne une définition relative de « langue avec peu de ressources » :
  - En comparant avec l'anglais, on peut considérer toutes les autres langues comme ayant peu de ressources.
  - Ou... sauf les *top 10* langues, le reste peut être considéré comme ayant peu de ressources.
  - Les langues des niveaux 3ème et 4ème sont des langues considérées comme ayant peu de ressources dans le domaine des TL.
  - On peut considérer que les langues des niveaux 5ème et 6ème sont vraiment en danger (du point de vue de leur utilisation dans les TIC).

# Les langues du monde et leurs ressources langagières

- Cette classification n'est pas stricte...
- ...mais elle peut être utile pour reconnaître des domaines d'application et pour dessiner d'éventuelles stratégies pour le développement des ressources langagières.

# Les langues du monde et leurs ressources langagières

- Et il y a des risques en ce qui concerne l'application de ces indicateurs :
  - Langues avec des promoteurs très actifs peuvent avoir une grande visibilité sur Wikipedia, n'étant pas cependant significative de la présence de la langue sur l'Internet en général, ou du nombre et de la qualité des ressources langagières.
  - Par exemple, le catalan apparaît dans une bonne position dans le classement du nombre d'articles de la Wikipedia, mais il s'agit d'une langue généralement considérée comme ayant peu de ressources.
  - Néanmoins, l'indicateur Wikipedia est très accessible, car il est mis à jour automatiquement pour toutes les langues, et utile lorsqu'il est utilisé en conjonction avec d'autres indicateurs.

# Stratégie de développement des TL pour le basque (groupe Ixa)

- Nous avons présenté, déjà en 1998 (Aduriz *et al.*, 1998) une proposition ouverte pour faire des progrès dans les TL.
- Idée principale: *ne pas mettre la charrue avant les bœufs!*
  - **d'abord, les fondations => après, les applications**
- Les mesures proposées ne se correspondent pas exactement à celles observées dans l'histoire du traitement automatique de l'anglais. Les ressources langagières dans le cas de l'anglais...
  - n'ont pas évolué à la suite d'un plan unique et coordonné
  - beaucoup d'efforts indépendants ont produit ces ressources, à fin de répondre aux besoins spécifiques de projets concrets
- Les ressources pour le traitement du basque ont été développées d'une façon différente, plus planifiée (au sein du groupe).

# Ixa : groupe de recherche en TALN

- Groupe Ixa : groupe de recherche créé en 1988, à la Faculté d'Informatique de Saint-Sébastien (UPV / EHU) <http://ixa.si.ehu.es>
- Objectif principal : faire face au défi de l'adaptation du basque aux technologies de la langue, établir une infrastructure (ressources et outils) pour le traitement automatique du basque
  - 1988 : 5 enseignants d'université (informatique)
  - 2014 : équipe interdisciplinaire
  - 45+ informaticiens, 15+ linguistes et 3 assistants de recherche
  - ~30 enseignants de l'université




# Stratégie de développement des TL pour le basque (groupe Ixa)

- Conception et développement des bases de la technologie langagière, des outils et des applications
  - d'une manière progressive et planifiée
  - afin d'en tirer le meilleur bénéfice
- Normalisation des ressources afin de les utiliser:
  - dans des recherches variées
  - pour développer des outils divers
  - dans des applications et produits différents
  - adoption de TEI et de standards comme XML comme base pour l'étiquetage linguistique aux différents niveaux de traitement (méthodologie générale pour l'annotation des corpus)


# Stratégie de développement des TL pour le basque (groupe Ixa)

- En prenant comme référence notre expérience dans la conception et le développement de ressources et d'outils :
  - nous proposons un stratégie général à quatre phases pour le développement d'une infrastructure du traitement automatique d'une langue (Alegria *et al.*, 2011)


# La priorité stratégique: de la recherche fondamentale vers le développement d'applications




# Phase I: pose des fondations



# Phase II: premiers outils basiques et applications



# Phase III: des outils et des applications plus avancées



Phonetics


Lexicon

Morphology

Syntax

Semantics

# Phase IV: applications multilingues et générales



Phonetics

Lexicon

Morphology

Syntax

Semantics

# Groupe Ixa : création de ressources, outils et applications

- 1988-1996
  - *EDBL* : base de données lexicales d'usage général
  - Description de la morphologie du basque (*two-level morphology*)
  - *Morfeus* : analyseur morphosyntaxique
  - *Xuxen* : vérificateur et correcteur d'orthographe

# Groupe Ixa : création de ressources, outils et applications

- 1997-2005
  - *Euskal WordNet* : wordnet du basque
  - *EPEC* : (petit) corpus général de référence
  - *Erreus* : corpus d'erreurs (apprentissage de la langue)
  - *PATR-IXA* : grammaire computationnelle, syntaxe (constituants)
  
  - *Eustagger (EusLem)* : lemmatiseur/tagger
  - *Ixati (Zatiak)* : *chunker*, identificateur de syntagmes et chaînes verbales
  - *Eihera*: identificateur/classeur d'entités nommées (noms, prénoms, dates...)
  
  - Intégration de *Xuxen* dans de divers environnements (traitement de texte, navigateurs, etc.) et version en ligne
  - Dictionnaires électroniques intégrés dans des traitement de textes (Elhuyar-Word, *eu-es*, *eu-fr*; UZEI-Word, synonymes)
  - *Multimeteo* : génération automatique des prévisions météorologiques

# Groupe Ixa : création de ressources, outils et applications

## ○ 2006-

- *ZTc* : Corpus de Science et Technologie (usager final)
- *LB* : Observatoire du Lexique (corpus, usager final)
- *MCR* : Multilingual Central Repository (EuroWordnet)
- *EPEC-EuSemCor* : *EPEC* étiqueté avec des sens des mots (wordnet du basque)
- *EPEC-AnCora* : *EPEC* intégré dans AnCora, avec des corpus es et ca, étiqueté syntaxiquement (dépendances)
- *EDGK* : grammaire de dépendances (règles)
- *Basyque* : Base de Données Syntaxique Basque (usager final)
- *e-ROLda* : outil de consultation de verbes (arguments, rôles)
- *Euskal RST Treebank* : petit corpus annoté au niveau du discours

# Groupe Ixa : création de ressources, outils et applications

- 2006-
  - *Maltixa* : analyseur syntaxique de dépendances (statistique)
  - *libiXaml* : librairie basique d'annotation linguistique
  - *UKB* : collection de programmes pour la désambiguïsation des sens des mots (indépendante de la langue)
  - *WSD-IXA* : système de désambiguïsation des sens des mots pour le basque (en ligne)
  - *Eulia / Armiarma* : outils de consultation et traitement du corpus (étiquetage, désambiguïsation)
  - *lexKit* : environnement d'édition de dictionnaires

# Groupe Ixa : création de ressources, outils et applications

- 2006-
  - *Anhitz* : expert virtuel (3D) en science et technologie (*Question Answering, MT, IE/IR*)
  - *Matxin (KBMT) / EusMT (SMT)* : traduction automatique es-eu (basée sur la connaissance / statistique)
  - *Ihardetsi* : système de réponse aux questions en langage naturel (*Question Answering*)
  - *BertsolariXa* : système de recherche de mots rimés
  - *Berbatek Tutor* : tuteur personnel pour l'enseignement de la langue (exercices de grammaire et de compréhension à la lecture)
  - *Berbatek Dubbing* : doublage automatiques de documentaires

# Sans quoi on ne peut pas se passer...

...si on veut traiter la langue écrite :

- Base de données lexicales
- Lemmatiseur/tagger
- Corpus

et (après) ils viendront :

- l'analyse syntaxique, sémantique...
- l'identification des entités nommées
- ...
- et les applications et produits, bien sûr!

Une question importante : existe-t-il de langue standard?

# Groupe Ixa : lignes de recherche actuelles

- Recherche fondamentale en lexicographie, morphologie, syntaxe et sémantique computationnelles
- Recherche sur le discours et les aspects pragmatiques de la langue (coréférence, structure rhétorique du discours)
- Recherche fondamentale sur les aspects opérationnels du traitement du langage : traitement de grands collections de textes, traitement parallèle...
- Annotation linguistique des corpus
- Récupération et extraction d'informations: réponse aux questions, résumé automatique de textes... sur domaines divers (médecine, tourisme, financier...)
- Traduction automatique
- Apprentissage des langues

# Groupe Ixa : recherche, résultats et projets

- ~50 publications annuelles (congrès et revues).
- Impliqué dans la création de la société *spin-off Eleka*, de la Fondation Elhuyar (2002).
- Collabore actuellement avec plusieurs entreprises du Pays Basque et de l'étranger.
- On travaille sur le basque, mais aussi sur d'autres langues (notamment sur l'anglais).
- Projets actifs :
  - Communauté Européenne : 6
  - *Ministerio de Economía y Competitividad* (Espagne) : 3
  - *Eusko Jaurlaritza* (Gouvernement Basque):
    - 1 projet ETORTEK (2012-2014) : recherche stratégique dans la CAPV
  - Groupe de recherche consolidé (2010-2015)
  - Avec d'autres entités : 2

# Groupe Ixa : Project actifs importants

- **Communauté Européenne:**  
Quality Translation by Deep Language Engineering Approaches.

(Premier project Européen qui developpe TL pour le basque)



**qt leap**

quality translation by deep language engineering approaches

## Gouvernement Espagnol:

- *TACARDI: Traducción automática en contexto y aumentada con recursos dinámicos de internet.*



## Eusko Jauriaritza

## Gouvernement Basque:

- Berbatek: recherche stratégique dans la CAPV. (Consortium)

berbatek



- HOME
- INTRODUCTION
- CONSORTIUM MEMBERS
  - Elhuyar
  - IXA
  - Aholab
  - Vicomtech
  - Tecnalia
- RESEARCH AREAS
- PREVIOUS PROJECTS
- DISSEMINATION
- TRAINING
- INTERNATIONAL COOPERATION
- LANGUAGE SPEECH AND MULTIMEDIA

Consortium members



vicomtech  
visual interaction  
communication  
technologies



# Enseignement

- Degrée en Informatique : *Traitement du langage naturel* (matière facultative, depuis 1994)
- Masters
  - Hiztek (Diplôme spécialisé en Technologie de la Langue; UPV/EHU + UEU): années 2001/2005
  - HAP, master sur le TALN : années 2005/2014
  - Erasmus Mundus master on *Language and Communication Technologies* + HAP/LAP master on *Language Analysis and Processing* (basque et anglais) : à partir de 2014
- Programmes de doctorat sur le TALN : 11 thèses soutenues dans les cinq dernières années

# En promouvant la coopération entre les divers acteurs liés aux Industries de la Langue



- **Langune**, association d'entreprises créée en 2010 (35+ entreprises):  
[www.langune.com](http://www.langune.com)
  - Encourager, renforcer et fournir un cadre cohérent à l'Industrie de la Langue en Euskal Herria (Pays Basque), afin principalement d'améliorer la compétitivité et la visibilité de ses associés.
- L'industrie linguistique est le secteur d'activité chargé de concevoir, produire et commercialiser des produits et des services en rapport avec le traitement des langues.

# En promouvant la coopération entre les divers acteurs liés aux Industries de la Langue

- On parle ici de:
  - Entreprises de traduction, localisation de logiciel, doublage et sous-titrage...
  - Apprentissage de la langue: enseignement en ligne, certifications sur la connaissance et l'usage des langues, etc.
  - Multilinguisme et gestion de contenus, ressources langagières...
- Défis stratégiques
  - Création et développement de l'association
  - Coopération et compétitivité des entreprises associées
  - Internationalisation
  - Développement technologique et innovation
- En 2012, le Département de l'Industrie, l'Innovation, le Commerce et le Tourisme du Gouvernement Basque a concédé *Langune* le titre de *Cluster* des Industries de la Langue.

# Conclusions

- De notre expérience, nous défendons que la recherche et le développement pour les langues avec « moins de ressources » devraient suivre ces points:
  - conception et développement progressifs : *bottom up*
  - réutilisation des fondations, des ressources et des outils
  - normalisation
  - *open-source* (code source ouvert): si on est peu, il faut partager!
- Nous pensons que notre stratégie visant à développer des technologies de la langue pourrait être utile pour d'autres langues : celles qui possèdent une norme écrite? celles qui ont déjà quelques ressources lexicales initiales?

# Conclusions

- Nous pensons que si le basque est maintenant dans une assez bonne position dans le domaine des technologies de la langue est parce que pendant les 25 dernières années ces lignes directrices ont été appliquées...
  - même quand il était plus facile de construire des ressources et des outils « jouet », utiles pour obtenir de « bons résultats académiques » à court terme, mais pas toujours réutilisables dans des développements futurs
- Il y a des expériences similaires avec d'autres langues : le cas du tchèque, par exemple, est une autre exception : il y a un bon nombre de ressources langagières pour le tchèque, grâce aux efforts coordonnés de certains chercheurs ambitieux et productifs.

# Conclusions

- La recherche ciblée sur chaque langue et sur l'application des techniques générales au traitement de chaque langue sont nécessaires; par ailleurs, elle contribue à la recherche générale sur le TALN.
- Un langage qui cherche à survivre dans la société de l'information exige des produits de technologie de la langue.

# Quelques références

- Aduriz, I., Agirre, E., Aldezabal, I., Alegria, I., Ansa, O., Arregi, X., Arriola, J.M., Artola, X., Díaz de Ilarraza, A., Ezeiza, N., Gojenola, K., Maritxalar, M., Oronoz, M., Sarasola, K., Soroa, A., Urizar, R.. A framework for the automatic processing of Basque. In: *Proceedings of Workshop on Lexical Resources for Minority Languages* (1998).
- Alegria I., Aranzabe M., Arregi X., Artola X., Díaz de Ilarraza A., Mayor A., Sarasola K.. Valuable Language Resources and Applications Supporting the Use of Basque. In: Z. Vetulani (Ed.) : LTC 2009, LNAI 6562, pp. 327–338, 2011. Springer-Verlag, Berlin Heidelberg : 2011.
- Borin, L.. Linguistic diversity in the information society. In: *SALTMIL 2009 Workshop: IR-IE-LRL Information Retrieval and Information Extraction for Less Resourced Languages*. Université du Pays Basque (2009).
- Krauwer, S.. The Basic Language Resource Kit (BLARK) as the First Milestone for the Language Resources Roadmap. In: *International Workshop Speech and Computer*, Moscou, Russia (2003).
- META-NET, La collection des livres blancs : <http://www.meta-net.eu/whitepapers/overview>
- Streiter, O., Scannell, K., Stuflessner, M.. Implementing NLP projects for non-central languages: instructions for funding bodies, strategies for developers. *Machine Translation* 20 (4), 267–289 (2006).

merci de votre attention  
*mercés hèra hòrt*  
*eskerrik asko*

Kepa.sarasola@ehu.es  
[ixa.si.ehu.es](http://ixa.si.ehu.es)