

# Corpora and Applied Linguistics (IT-FR)

Marie-Pierre Escoubas Benveniste  
Academic Researcher and Lecturer  
Language and Translation studies-French language L-LIN/04

DIPARTIMENTO DI METODI E MODELLI  
PER L'ECONOMIA IL TERRITORIO E LA FINANZA  
MEMOTEF



SAPIENZA  
UNIVERSITÀ DI ROMA

XII GIORNATE della RICERCA

May 31°2022- June 1°2022

Piazza Cavalieri di Malta n. 2, Roma

# Corpora and Applied Linguistics (IT-FR)

1. A brief foreword
2. Defining corpus and applied linguistics
3. What corpus linguistics is applied to?
4. Some research areas of interest
5. Open questions and suggestions

# Corpora and Applied Linguistics (IT-FR)

## 1. A brief foreword

“the actual enjoyment of fundamental rights (expression, education, participation in cultural life, benefiting from scientific progress) is highly conditioned by linguistic factors. Languages thus provide an **essential medium** for exercising those rights.”

(Unesco, 2007)

“beaucoup de **langues européennes** pourraient être coupées de la communication numérique et devenir sans importance dans une **société en réseau**”

(*Livre blanc*, 2012, CNRS)

“...research has revealed positive impacts of multilingualism, including **greater cognitive flexibility and language control**, more **complex understanding of words**, [...] From an economic perspective, several studies [...] reveal that knowledge of more than one national language can have an **economic advantage** [...]”

(Unesco, 2019)

As an academic institution, Dipartimento Memotef promotes multilingualism :

**4 european languages : Italiano, Español, Deutsch, Français + English**

# Corpora and Applied linguistics (IT-FR)

## 2. Defining Corpus and Applied linguistics

- **Language “data” in digital form.** Usually large amounts but **not necessarily “big (amount of) data”**.
- **Corpus :** a set of (subsets of) **selected items** (texts, text + sound, text + image, text + video) displayed in digital format and structure.  
=> WWWeb ≠ Corpus
- **Applied linguistics :** when social needs encounter AL => acquiring new insights (language process vs language system)  
=> virtuous loop : applied and theoretical ling. “feed” each other

# Corpora and Applied Linguistics (IT-FR)

## 3. What is Corpus linguistics applied to?

- LSP empirical description
- Terminology Studies (monolingual/bilingual/multilingual)
  - Terminology
  - Term Variation (over time, text-genre, domain, users)
- Translation Studies (i.e. *Translationese* features)
- Teaching/Learning how to translate
- Language Teaching/Learning (L1, L2, L3)
- Understanding Language Risk (Health, Industry, ...)
- Fine tuning of resources and Computer Assisted Tools
- ...

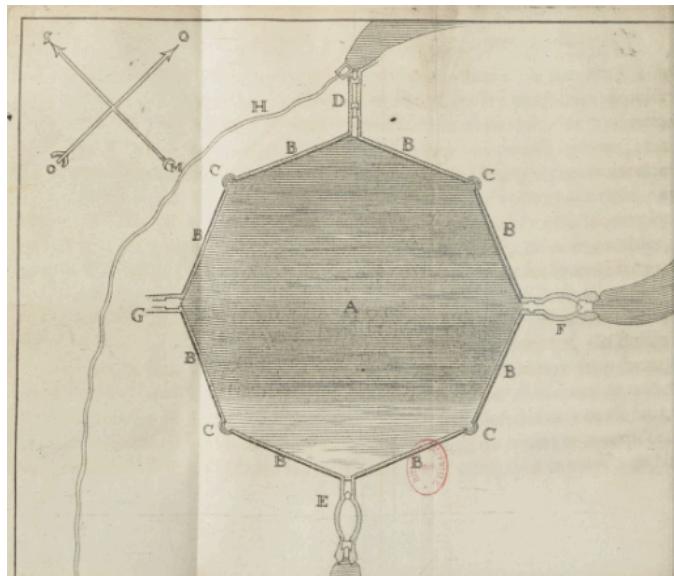
# Corpora and Applied Linguistics (IT-FR)

## 4. Some research areas and projects

- **Monolingual corpus based term analysis**

2022: L' “épanchoir” of the Two Sees Channel (Occitany, FR), a term of high cultural content.

1681 (H: *L'épanchoir de la rigole*)



Marie-Pierre Escoubas Benveniste

L'épanchoir des Patiasses © J.F. Benne, 2022



May 31°2022- June 1°2022

Pagina 6

# Corpora and Applied Linguistics (IT-FR)

## 4. Some research areas and former projects

- **Monolingual LSP corpus**

2009: “La définition dans le discours économique de vulgarisation savante”

- **Textual data analysis (JADT 2010 Roma, JADT 2012 Liegi)**

2010: Le “Grenelle de l’Environnement” (Le Monde)

Corpus based semantic analysis of a new term (cf. Sarkozy’s mandate)

2012: with O. Floquet (Dip. SEAI) and S. Bolasco (Dip. Me.Mo.T.E.F.)

Corpus based comparative quantitative and qualitative analysis in written contemporary French (gerund / present participle)

- **Comparable Corpora**

2013 Spoken and written French corpora for differential analysis (TIPA)

2016-2018- LSP : Comunicazione aziendale (IT FR) ongoing research

# Corpora and Applied Linguistics (IT-FR)

## 4. Some research areas and projects

- **Bilingual corpora (FR-IT)**

2008 A bilingual corpus for LSP teaching (=> train-the-trainer)

2012 Contrastive analysis of a bilingual corpus of judgments  
of the European Court of Justice (=> train-the translator)

**2018-2022: Studying how a bilingual corpus (FR-IT) may contribute to terminology network building (CA method)**

# Corpora and Applied Linguistics (IT-FR)

## 4. Some research areas

- **Learner Corpora and error analysis (=> train-the-trainer)**

2017 « La dictée de français et les étudiants italophones.  
Analyse préliminaire des erreurs de morphologie verbale ».

⇒ **2019 Corpus design**

⇒ **2020 NoVerFra Project** (prot. RP120172B88FC1FA)

Ongoing: **Building a digital resource for researchers and trainers interested in a better understanding of the acquisition of bi-modal French L2 verbo-nominal morphosyntax**, with Paolo G. Bottoni (Dip. Informatica)

# Corpora and Applied Linguistics (IT-FR)

## 5. Open questions & suggestions

- **Research enhancement and orientation: suggestions**
  - from **bi-** to **multilingual** applied linguistic research ?  
(cf. CorMusT Project, with Di Vito )
  - **Computer linguists skills** needed for data extraction & processing
  - **Statistical analysis** : expertise needed in methodology
  - **Domain experts collaboration needed** for validation/validation of textual data interpretations provided by corpus linguists  
=> building reliable multilingual terminologies for translation
- **Research product valorisation : where and how?**
  - Product = **resources** (i.e. train-the-trainer platform, data sets, ...)
  - **Hosting on academic server** (where?)
  - **Resource access** policy (of what sort?)

# Corpora and Applied Linguistics (IT-FR)

## Related bibliography

(submitted) coauthor with Condamines & Federzoni "Apport d'un corpus de presse spécialisé aligné français/italien à l'analyse des marqueurs et de la relation de méronymie" Actes du congrès ONELA Numéro spécial de ELA (Etudes de Linguistique appliquée) Amélie Josselin-Leray & Denyze Toffoli (eds.)

**2022** "L' "épanchoir" du Canal des Deux Mers, un terme de haute teneur" in F. Attruia, A. Naccarato, A. Orlandi, C.Preite (éds), « *Nous plongions nos mains dans le langage* ». Hommage à Paola Paissa, Coll. Au coeur des textes n°42, Editions Academia, Louvain-la-Neuve. pp. ISBN: 978-2-8061-0661-2

**2021** coauthor with Condamines & Federzoni. Apport de la traduction dans l'étude des marqueurs de relations conceptuelles. Une étude en corpus aligné français-italien" In Cécile Frérot et Mojca Pecman (coord.) Des corpus numériques à la modélisation linguistique en langues de spécialité, `Collection « Langues, Gestes, Paroles » co-dirigée par Jean-Marc Colletta et Anne Vilain aux Éditions UGA (Université Grenoble Alpes).

**2020** La fraseologia nella traduzione francese del Visconte dimezzato (1952) di Italo Calvino: verso un'analisi bidirezionale / Escoubas, Marie Pierre. - (2020), pp. 573-618. in Koesters at laii (a cura di) Si dice in molti modi - STUDI E RICERCHE STUDI UMANISTICI - ANTICHISTICA.Sapienza - Editrice

**2019** « L'apprentissage de la morphologie du nom et du verbe français par des italophones : un corpus de contextes pour l'expérimentation », *Repères DoRiF*, n. 20 – Modèles linguistiques et cognitifs et didactique des langues, DoRiF Università, Roma, dicembre 2019

**2018** with Condamines & Federzoni. (2018) Usare i corpora allineati per migliorare la constituzione di "reti terminologiche" e l'insegnamento della traduzione. *International Conference of the Italian Association of Applied Linguistics*, Feb 2018, Università degli studi di Roma Tre, Rome, Italy

# Corpora and Applied Linguistics (IT-FR)

## Related Bibliography

2017 with S. Di Domenico « La dictée de français et les étudiants italophones. Analyse préliminaire des erreurs de morphologie verbale ». In Gerolimich et al. (éds.), *Comment les apprenants étrangers s'approprient-ils la morphologie verbale du français ?*, Bulletin suisse de linguistique appliquée, N° 105, 2017, pp. 77-94, ISSN 1023-20442013

2012: Prédicats juridiques et schémas d'arguments dans les textes des arrêts de la Cour : approche bilingue français-italien“

2013 « Usages du gérondif et du participe présent en français parlé et écrit : étude comparée basée sur corpus », *TIPA. Travaux interdisciplinaires sur la parole et le langage* [En ligne], 29 | 2013. URL : <http://tipa.revues.org/908>

2010 “Repérer et s'approprier le lexique spécialisé grâce aux TIC: défense et illustration “, in *Multimedialità e linguaggi specialistici: riflessioni teoriche e iniziative didattiche*, In Rita Salvi (a cura di) RILA, p. 247-262.

2010 “Le Monde et le « Grenelle de l’Environnement » : pistes pour l’analyse sémantique assistée par ordinateur d’un corpus de presse“, In *Proceedings of 10th International Conference Journées d’Analyse statistique des Données Textuelles*, JADT 2010, Sapienza, University of Rome. Roma, 9-11 giugno 2010, a cura di Sergio Bolasco et al., Milano: Edizioni universitarie di Lettere Economia Diritto, vol. 1/2010, p. 409-422.

2009 “La définition dans le discours économique de vulgarisation savante”, In Micaela Rossi (coord.) *Autour de la définition* 6, Publif@rum, Università degli Studi di Genova. ISSN 1824-7482, codice: E186699, Rivista: PUBLIF@RUM

[http://publifarum.farum.it/ezine\\_articles.php?id=146](http://publifarum.farum.it/ezine_articles.php?id=146)

2008 “Le corpus français-italien LSSEE (Langue Spécialisée du domaine “Systèmes éducatifs européens”), Marie Hédiard (a cura di ), *Corpus et logiciels pour la linguistique*, [CD-Rom], Centro editoriale di Ateneo, Università degli Studi di Cassino.

2003 “(-)mener ou (-)porter ? Avantages d'une approche lexicale de la traduction de portare, verbe de déplacement à sens concret”, RILA-Rassegna Italiana di Linguistica Applicata XXXV, 1-2, Milano: Bulzoni Editore, 2003, pp.127-149. ISSN 0033-9725.

2002 “An ou année ? Un exemple d’analyse contextuelle guidée par corpus comme aide à la sélection lexicale pour les apprenants italophones”, in Marie Hédiard (coord.) *Le nuove tecnologie nella ricerca in linguistica e glottodidattica*, Pubblicazioni dell’Università degli Studi di Cassino, pp.41-74.