

French collocations of cross-disciplinary scientific lexicon



agnes.tutin@u-grenoble3.fr; Thi-Thu-Hoai.Tran@e.u-grenoble3.fr; olivier.kraif@u-grenoble3.fr; sylvain.hatier@u-grenoble3.fr

Aim

Ongoing project of lexical resources of French cross-disciplinary scientific lexicon in the framework of the Termith ANR project (<http://www.atilf.fr/ressources/termith/>)

- Freely available
- Specific lexicon: deals with words which cannot be used as terms but refer to methods, arguments, opinions and metatext, *for example hypothesis, that is why, surprisingly ...* (for English, see Kosem 2010; Granger & Paquot 2010)

COLLOCATIONS

- ✓ In line with Explanatory and Combinatorial Lexicology (Mel'čuk, 1998), collocations are compositional and prefabricated binary multiword expressions.
- ✓ Each component will receive a semantic tag and be stored within the database entry (e.g. s.v. *hypothèse* for *réfuter une hypothèse* ('to disprove a hypothesis') or *hypothèse valide* ('valid hypothesis').
- ✓ Fully frozen MWE expressions (e.g. *mettre en évidence* 'highlight') will be stored as single units.

Definition

SYNTACTIC TYPES OF COLLOCATIONS

- ✓ N prep N : *hypothèse de travail* (work hypothesis), *formulation d'une hypothèse* (formulation of hypothesis)
- ✓ N Adj : *hypothèse valide* (valid hypothesis)
- ✓ N V : *les résultats confirment* ... (results confirm...)
- ✓ V (prep) N : *faire une hypothèse* (to make a hypothesis...)
- ✓ V ADV : *assumer pleinement* (fully assume)
- ✓ Adv Adj : *totalement absent* (totally absent), *significativement différent* (significantly different)

COLLOCATION EXTRACTION

- ✓ Corpus : 500 research articles in 10 disciplines of human sciences
- ✓ Core cross-disciplinary scientific lexicon of ~1200 words (Hatier 2013)
- ✓ Syntax-based extraction of collocations (Seretan 2011) with the help of the Lexicoscope (Kraif & Diwersy 2014)
- ✓ Several statistical thresholds are used: frequency over 7 occurrences, log-likelihood ratio > 10.7 and a dispersion in at least 3 disciplines.
- ✓ Manual checking of results

Le lexicoscope (Kraif & Diwersy 2014) (<http://emolex.u-grenoble3.fr/emoBase>)

Example : extraction of V-obj-hypothèse collocations

Pivots (lemme ⚡ Forme ⚡) : Catégorie Traits :
hypothèse

Relations ~OBJ

~OBJ signifie que le pivot est en position de dépendant

Définition du contexte des pivots :

Concordances | Cooccurrences

I	I2	f.depcls	f	f1	f2	N	f.disp	am.log.likelihood	r.log.likelihood
hypothèse_*	faire_VERB	-OBJ	120	571	8939	280230	10	270,1137	1
hypothèse_*	tester_VERB	-OBJ	38	571	239	280230	8	246,8283	2
hypothèse_*	émettre_VERB	-OBJ	20	571	116	280230	8	142,2757	3
hypothèse_*	rejeter_VERB	-OBJ	23	571	213	280230	4	140,8877	4
hypothèse_*	avancer_VERB	-OBJ	20	571	166	280230	9	126,9839	5
hypothèse_*	formuler_VERB	-OBJ	17	571	135	280230	7	109,4272	6
hypothèse_*	valider_VERB	-OBJ	13	571	115	280230	7	80,8485	7
hypothèse_*	confirmer_VERB	-OBJ	19	571	478	280230	5	78,1058	8
hypothèse_*	vérifier_VERB	-OBJ	14	571	260	280230	5	65,7744	9
hypothèse_*	accepter_VERB	-OBJ	10	571	296	280230	3	37,8284	10
hypothèse_*	poser_VERB	-OBJ	9	571	705	280230	5	18,0858	11

PERSPECTIVES: INFORMATION ON SYNTACTIC PROPERTIES OF COLLOCATIONS

Collocation	Faire-hypothèse	Examples
Determiners	I' (91%), des (8%), une (0,5%).	
Syntactic alternations	92% Direct objet 2% Passive	<i>Nous avons fait l'hypothèse</i> <i>Ainsi, aucune hypothèse n' est faite sur le caractère ...</i>
	5% Reduced passive	<i>les conséquences des hypothèses générales faites sur l'allocutoire</i>
External subcategorialization	Que-P (with I') : 58% Prep-de (with I') : 12%	<i>On peut faire également l'hypothèse que c'est au cours de la Belle Epoque que s'opère la transition</i> <i>On peut faire l'hypothèse d'une forte homogénéité des sujets ...</i>

References

- Evert, S. (2008). Corpora and collocations, in Anke Lüdeling/Merja Kyö (eds.), *Corpus Linguistics. An International Handbook*. Berlin: Mouton/de Gruyter, 1212–1248.
- Hatier, S. (2013). Extraction des mots simples du lexique scientifique transdisciplinaire dans les écrits de sciences humaines : une première expérimentation. Dans *Actes de Recital'2013* (p. 138–149). Les Sables d'Olonne, France.
- Kraif, O., & Diwersy, S. (2014). Exploring combinatorial profiles using lexicograms on a parsed corpus: a case study in the lexical field of emotions. In P. Blumenthal, I. Novakova, & D. Siepmann (eds.), *Actes Du Colloque International Nouvelles Perspectives En Sémantique Lexicale Et En Organisation Du Discours*. Osnabrück, Allemagne: Peter Lang.
- Mel'čuk, I. (1998). Collocations and Lexical Functions. In A. P. Cowie (ed), *Phraseology. Theory, Research and Applications*, 23–53. Oxford : Clarendon Press.
- Seretan, V. (2011). *Syntax-based collocation extraction*. Vol. 44. Springer Science & Business Media, 2011.
- Tran, T. T. H. (2014). Les séquences lexicalisées à fonction discursive comme outil d'aide à l'écriture auprès des étudiants étrangers. Dans P. Blumenthal, I. Novakova, & D. Siepmann (éd.), *Actes Du Colloque International Nouvelles Perspectives En Sémantique Lexicale Et En Organisation Du Discours*. Osnabrück, Allemagne: Peter Lang.
- Tutin, A. (2014). La phraséologie transdisciplinaire des écrits scientifiques : des collocations aux routines sémantico-rhétoriques. Dans A. Tutin & F. Grossmann (éd.), *L'écrit Scientifique : Du Lexique Au Discours. Autour De Scientext* (p. 27–44). Rennes: Presses Universitaires de Rennes.