



Construction automatique d'une ressource de synonymes désambiguïsés pour l'aide à la lecture

Mokhtar Boumedyen BILLAMI

LIF-CNRS UMR 7279, Aix-Marseille Université

mokhtar.billami@lif.univ-mrs.fr

27 Juin 2016

Sommaire

- 1 Ressources proposant des synonymes désambiguïsés
- 2 Filtrage de sens
- 3 Données de ReSyf

BabelNet et Jeux De Mots (JDM)

BabelNet

Source [Navigli et Ponzetto, 2012]

Data sens provenant de différentes sources (Wikipédia, Wiktionnaire, Wikidata, Omega wiki, Open Multilingual WordNet et WordNet [Fellbaum, 1998])

Avantages (1) très bonne couverture des mots polysémiques; (2) différenciation entre concepts et entités nommées

JDM

Source [Lafourcade, 2007]

Data prise en compte de la relation de raffinement sémantique et de synonymie

Avantage représentation des sens d'un mot donné sous la forme d'un arbre [Lafourcade et Joubert, 2009]

Difficultés de désambiguïsation lors de l'utilisation de BabelNet et JDM

BabelNet

- Granularité de sens trop fine
 - *Souris* a 9 sens, parmi lesquels: '*espèce de petit rongeur*', '*genre de rongeur*' et '*rongeur*'
- Existence de mots techniques et mots provenant de langues étrangères

JDM

- Faible couverture de raffinements sémantiques et de liens entre sens et synonymes
- L'impossibilité d'utiliser des méthodes de désambiguïsation à base de traits sémantiques ([Billami et Gala, 2016, Billami, 2015])

NASARI : a Novel Approach to a Semantically-Aware Representation of Items

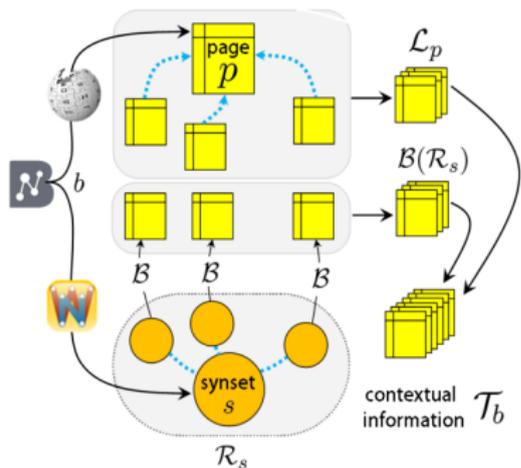


Figure 1: Processus d'obtention de l'information contextuelle provenant des sens de WordNet et des articles de Wikipédia [Camacho-Collados et al., 2015]

b sens (p, s) décrit par un synset et/ou un article de Wikipédia

L_p page décrivant le sens b et les pages ayant un lien sortant vers b

\mathcal{R}_s ensemble de sens de WordNet : le sens b et tous les sens représentant un voisinage direct de b y compris les sens désambiguïsés de la glose de s

β fonction de mapping entre un synset s' de WordNet et sa page p

$\beta(\mathcal{R}_s) \cup_{s' \in \mathcal{R}_s} \beta(s')$

\mathcal{T}_b information contextuelle (pages de Wikipédia) $\mathcal{T}_b = L_p \cup \beta(\mathcal{R}_s)$

Algorithme de filtrage

– Utilisation de BabelNet comme base de connaissances :

- 1 Tri décroissant des sens selon leur nombre de connexions sémantiques dans le réseau
- 2 Mesurer la similarité (forte vs faible) entre chaque paire de sens par utilisation de la fonction *Weighted Overlap (WO)* [Pilehvar et al., 2013]
 - *Seuil* = 0.5, sens le plus fort est gardé et le plus faible est supprimé

$$WO(Sens_1, Sens_2) = \frac{\sum_{q \in O} (r_q^1 + r_q^2)^{-1}}{\sum_{i=1}^{|O|} (2i)^{-1}} \quad (1)$$

– Un vocabulaire commun avec JDM y compris Lexique3 [New et al., 2007].

L'exemple de « toile »

Numéro	ID BabelNet	CS ¹	Vecteur de synonymes
1	bn:00019980n	1665	[tenue, tissu, toile, linge, matière, étoffe, chiffon, matériau, textile]
2	bn:00080772n	1413	[réseau, toile, web, internaute, toile d'araignée mondiale, world wide web, www]
3	bn:00073342n	325	[toile, toile d'araignée]
4	bn:00051362n	323	[toile, lin, toile de lin, lin textile]
5	bn:00015381n	298	[toile (peinture), toile]
6	bn:00062749n	114	[toile]
7	bn:00070989n	111	[toile]
8	bn:00015386n	11	[toile]
9	bn:00007787n	7	[bureau, milieu, fond, toile, origine, arrière-plan]
10	bn:04976972n	6	[toile (armure)]
11	bn:00051363n	4	[toile, lin]
12	bn:00015382n	3	[toile]

Table 1: Sens de "toile" selon BabelNet + précisions sur le filtrage avec NASARI, JDM et Lexique3 (En préparation : [Gala et al., 2017])

¹Nombre de connexions sémantiques (avec les voisins directs)

ReSyf – ressource lexicale de synonymes désambiguïsés pour le français et triés selon leur niveau de difficulté



POS	Nombre de lemmes	Proportion (%)
Noms	15 494	79,88 %
Adjectifs	1 741	8,97 %
Verbes	1 516	7,82 %
Adverbes	646	3,33 %
Total	19 397	100 %

Table 2: Distribution des entrées de ReSyf selon leur catégorie grammaticale

– *Nombre de sens* = 11 166

En vous remerciant pour votre attention

Références



BILLAMI M. B. et Gala N. (2016)

Approches d'analyse distributionnelle pour améliorer la désambiguïstation sémantique.

Actes des Journées internationales d'Analyse statistique des Données Textuelles (JADT), Nice, pages 707 – 717.



BILLAMI M. B. (2015)

Désambiguïstation lexicale à base de connaissances par sélection distributionnelle et traits sémantiques.

Actes de la 22e conférence en Traitement Automatique des Langues Naturelles, session RECITAL, Caen, France, pages 13 – 24.



Camacho-Collados J., Pilehvar M. T. et Navigli R. (2015)

NASARI: a Novel Approach to a Semantically-Aware Representation of Items.

Proceedings of the 2015 NAACL:HLT Conference, Denver, Colorado, pages 567 – 577. <http://www.aclweb.org/anthology/N15-1059>



Fellbaum C. (1998)

WordNet: an Electronic Lexical Database.

MIT Press.

Références



Gala N., François T., Billami M. B. et Bernhard D. (2017)

ReSyf : a lexical resource with difficulty levels for reading assistance and automated text simplification (en préparation).

Behavior Research Methods, Instruments, and Computers, Springer Journals, xx.



Lafourcade M. et Joubert A. (2009)

Similitude entre les sens d'usage d'un terme dans un réseau lexical.

Journal du Traitement Automatique des Langues, 50(1), pages 179 – 200.



Lafourcade M. (2007)

Making people play for Lexical Acquisition with the JeuxDeMots prototype.

SNLP'07: 7th International Symposium on NLP, Pattaya, Chonburi, Thaïlande.

<http://hal-lirmm.ccsd.cnrs.fr/lirmm-00200883/file/MLF-snlp2007-v5.pdf>



Navigli R. et Ponzetto S. (2012)

BabelNet: The Automatic Construction, Evaluation and Application of a Wide-Coverage Multilingual Semantic Network.

Artificial Intelligence, 193, Elsevier, pages 217 – 250.



New B., Brysbaert M., Veronis J. et Pallier C. (2007)

The use of film subtitles to estimate word frequencies.

Applied Psycholinguistics, **28**(04), pages 661 – 677.



Pilehvar, M. T., Jurgens, D. et Navigli, R. (2013)

Align, Disambiguate and Walk: a Unified Approach for Measuring Semantic Similarity.

Proceedings of the 51st ACL Conference, Sofia, Bulgarie, pages 1341 – 1351.