



Apporter des connaissances sémantiques à un jeu de pictogrammes destiné à des personnes en situation de handicap : Un ensemble de liens entre Princeton WordNet et Arasaac, Arasaac-WN

Didier Schwab, Pauline Trial, Vaschalde Céline, Loïc Vial, Benjamin Lecouteux

► To cite this version:

Didier Schwab, Pauline Trial, Vaschalde Céline, Loïc Vial, Benjamin Lecouteux. Apporter des connaissances sémantiques à un jeu de pictogrammes destiné à des personnes en situation de handicap : Un ensemble de liens entre Princeton WordNet et Arasaac, Arasaac-WN. 26e Conférence sur le Traitement Automatique des Langues Naturelles, 2019, Toulouse, France. pp.619-622. hal-02568308

HAL Id: hal-02568308

<https://hal.science/hal-02568308>

Submitted on 10 Jun 2020

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons Attribution - NonCommercial - NoDerivatives 4.0 International License

Apporter des connaissances sémantiques à un jeu de pictogrammes destiné à des personnes en situation de handicap : un ensemble de liens entre *WordNet* et *Arasaac*, *Arasaac-WN*

Didier Schwab, Pauline Trial, Céline Vaschalde, Loïc Vial, Benjamin Lecouteux

Univ. Grenoble Alpes, CNRS, Grenoble INP, LIG, 38000 Grenoble, France

{loic.vial, benjamin.lecouteux, didier.schwab}@univ-grenoble-alpes.fr

RÉSUMÉ

Cet article présente une ressource qui fait le lien entre *WordNet* et *Arasaac*, la plus grande base de pictogrammes librement disponible. Cette ressource est particulièrement intéressante pour la création d'applications visant l'aide aux personnes en situation de handicap cognitif.

ABSTRACT

Giving semantic knowledge to a set of pictograms for people with disabilities : a set of links between *WordNet* and *Arasaac*, *Arasaac-WN*

This article presents a resource that links *WordNet* and *Arasaac*, the largest freely available database of pictograms. This resource is particularly interesting for the creation of applications aimed at helping people with cognitive disabilities.

MOTS-CLÉS : Outils d'assistance pour les personnes en situation de handicap, Pictogrammes, Communication Alternative et Augmentée.

KEYWORDS: Assistive Technology for people with disabilities, Pictograms, Alternative and Augmented Communication.

1 Introduction

Communiquer lorsque le langage oral et signé est inaccessible ou mis en difficulté est une véritable épreuve pour les individus en situation de polyhandicap et leur entourage. L'utilisation d'un code de communication alternatif dans les activités quotidiennes peut être freinée par des difficultés d'apprentissage, des représentations négatives de la communication non orale, ou un coût trop important des outils d'aide à la communication, engendrant d'importantes frustrations pour les interactants. Pour permettre aux individus en situation de handicap langagier de communiquer, il existe plusieurs méthodes de Communication Alternative et Améliorée (CAA) (Nègre, 2017). Ces méthodes sont dites « alternatives » lorsqu'elles remplacent totalement les moyens d'expression orale et sont dites « améliorées » lorsqu'elles permettent de suppléer les capacités de communication déjà présentes, pouvant même aider à l'émergence de l'oralisation ou de la graphie pour certains individus (Beukelman and Mirenda, 2017).

Pour de nombreuses personnes en situation de polyhandicap, les gestes et la parole sont impossibles et seule la communication par pictogrammes est possible. Le pictogramme peut être défini comme un signe graphique schématique dont le signifiant entretient un rapport de ressemblance plus au moins fort avec le signifié, au contraire des signes linguistiques phoniques ou graphiques dont la forme du stimulus est arbitraire et indépendante de celle du référent. Il permet une représentation plus iconique de l'information et est plus facilement interprétable. Le développement de ce type d'outil correspond également à une demande sociale de plus en plus forte pour développer l'accessibilité : il s'agit alors de présenter une certaine image pour demander à boire, d'en présenter une autre pour demander à

manger (parfois en désignant du regard par l'intermédiaire d'un oculomètre (Schwab et al., 2018)).

Le cœur de cette démonstration pose des bases pour de futurs outils liés aux pictogrammes comme, par exemple, l'automatisation de la communication par pictogrammes (voir vidéo).

2 Du pictogramme à la langue naturelle

Actuellement, il n'existe pas de base de connaissance permettant de lier des pictogrammes issus d'Arassac de manière formelle à leur représentation sémantique. Généralement, les utilisateurs de pictogrammes vont les choisir en fonction d'une description textuelle, d'une représentation graphique, d'un mode d'emploi ou encore suite à une formation. Cette association entre un pictogramme et une représentation sémantique est pourtant un élément essentiel pour réaliser des outils de TALN utilisant les pictogrammes. Un travail équivalent a déjà été réalisé pour d'autres jeux de pictogrammes qui ne sont malheureusement pas utilisés en France (Vandeghinste and Schuurman, 2014). Nous présentons donc une première base de données réalisant ce lien à partir de pictogrammes qui sont à la fois libres et utilisés dans les institutions. Notre objectif est de promouvoir le développement de divers outils autour des pictogrammes, nous souhaitons cette base soit enrichie au fur et à mesure des années.

2.1 Le jeu de pictogrammes ouvert et libre : Arassac

Les pictogrammes *Arasaac* sont fournis par le Portail Aragonais de la Communication Améliorée et Alternative (<http://www.arasaac.org>). Le portail aragonais met à disposition plus de treize mille pictogrammes en noir et blanc et plus de quinze mille pictogrammes en couleur. Il s'agit ainsi de la plus grande base librement disponible. Ces pictogrammes disposent d'une licence Creative Commons de type BY-NC-SA qui autorise l'exploitation à des fins non commerciales, ainsi que la création d'œuvres dérivées, à condition qu'elles soient distribuées sous la même licence.



FIGURE 1 – Manger.



FIGURE 2 – Boire.



FIGURE 3 – Dormir.

2.2 Exemples d'applications

Une fois le lien entre une base de pictogrammes et *WordNet* établie, il est possible d'envisager de nombreuses applications. Nous en présentons deux que nous souhaiterions développer : 1) la génération vocale à partir des pictogrammes qui permettrait à une personne en situation de handicap de composer des messages sous la forme d'une voix synthétisée. Le problème revient ainsi à la recherche des pictogrammes nécessaires à la composition du message ; *Arasaac-WN* permettrait ainsi une recherche en fonction des idées associées aux images en passant par le texte des définitions et/ou le réseau lexical par exemple à la manière de (Zock and Schwab, 2011) ; 2) la génération de pictogrammes à partir du langage naturel (Vaschalde et al., 2018b,a; Sevens et al., 2017). Il s'agit ainsi d'associer les pictogrammes au discours correspondant. L'idée est de plonger dans un bain langagier une personne nécessitant d'apprendre ou de réapprendre à partir de zéro. En effet, c'est en multipliant les occasions où elle est confrontée à l'association d'un pictogramme avec un certain mot, un certain concept que la personne arrivera à les associer de manière naturelle exactement comme les enfants typiques apprennent les mots.

3 La ressource *Arasaac-WN*

Afin de présenter au mieux la ressource, nous avons opté pour l'utilisation d'outils spécialisés dans la diffusion de collections numériques. Nous nous sommes orientés sur Omeka (Scheinfeldt, 2008) qui est une plateforme libre développée par le *Center for History and New Media (CHNM)* de l'Université

George Mason. Cet outil est particulièrement conçu pour l'organisation, l'exposition et la mise en ligne de données iconographiques, avec leurs métadonnées. Par exemple, Omeka permet d'associer des métadonnées standardisées au format du Dublin Core (vocabulaire du web sémantique utilisé pour exprimer les données dans un modèle *Resource Description Framework*, RDF) afin d'effectuer des recherches poussées au sein de la collection numérique.

3.1 Structure de la ressource

La ressource est disponible dans le format RDF, il est ainsi possible d'utiliser des outils classiques du Web sémantique et de l'interroger en SPARQL (*SPARQL Protocol and RDF Query Language*). Nous avons pris le parti d'exploiter les champs initiaux du Dublin Core afin de représenter les différents pictogrammes. Les principaux attributs de *Arasaac-WN* sont les suivants : 1) *Titre* : nom du pictogramme tel qu'il était indiqué sur *Arasaac* ; 2) *Description* : identifiants *WordNet* permettent l'identification unique d'un terme dans la base de données lexicale et ainsi de supprimer toute ambiguïté (emplacement des bases de données (Database locations 1), le numéro de sens (Sense numbers 2) ainsi que la clé de sens (Sense key 3)) ; 3) *Créateur* : l'organisme qui a créé le lien ; 4) *Contributeur* : nom de la personne qui a ajouté l'entrée dans la base ; 5) *Relation* : comme indiqué dans les spécifications du Dublin Core, ce champ permet de faire appel à une ressource apparentée et peut servir à donner des liens vers celles-ci. Cet élément sert donc à mettre en évidence les liens à partir desquels les données sont extraites ; 6) *Langue* : cet élément permet de préciser que les informations renseignées sont en anglais. Le *WordNet* étant en anglais, l'ensemble des mots des deux listes en français ont été intégrés à la collection sous leur nom anglais sur *Arasaac* ; 7) *Alternative title* : cet élément du Dublin Core qualifié permet, comme son nom l'indique, de donner un titre alternatif à la ressource. Ce champ a donc été utilisé pour renseigner le nom français du pictogramme et ainsi faciliter la recherche dans la base.

Au 25 mai 2019, la ressource contient 586 liens, c'est-à-dire 586 pictogrammes d'*Arasaac* qui ont été reliés à *WordNet*.

3.2 Difficultés et protocoles d'annotation

Pour certains pictogrammes, il est difficile d'extraire une signification unique à partir du contenu représenté. Pour le pictogramme "oublier" par exemple, l'image ne permet pas d'établir avec certitude la signification visée par le créateur de celle-ci et de faire un lien univoque avec *WordNet* (forget). Dans ce genre de cas, les entrées pour un même pictogramme peuvent être multipliées pour correspondre aux différentes significations possibles lorsque celles-ci sont couramment usitées. Des différences relativement fines sont présentes pour certains termes comme la pluie par exemple, où *WordNet* propose les deux définitions suivantes : "water falling in drops from vapor condensed in the atmosphere" et "drops of fresh water that fall as precipitation from clouds". Lorsque ce genre de cas se présente, il est nécessaire de sélectionner le bon synset. D'autres problèmes de correspondance ont pu être mis en évidence lors de la création de la ressource, comme des noms de pictogrammes en plusieurs mots ne trouvant pas d'équivalent sur *WordNet* (ex : to grow larger).

4 Conclusion et perspectives

Dans cet article nous avons présenté une première version de *Arasaac-WN* qui lie le *WordNet* à la base ARASSAAC : la plus grande base de pictogrammes destinés aux personnes en situation de handicap disponible librement. À ce jour, 586 pictogrammes ont été liés permettant d'accéder à l'écosystème du *WordNet* et ainsi de permettre d'accéder à tout un ensemble d'outils du traitement automatique des langues pour l'assistance aux personnes en situation de handicap. La réalisation de ce type de base est assez fastidieuse en raison des difficultés rencontrées et du protocole d'annotation. Comme nous l'avons montré, il y a des problèmes liés à des équivalences avec *WordNet* qui n'existent pas. Dans les versions à venir, nous proposerons des solutions pour contourner ces problèmes.

Références

- D. Beukelman and P. Mirenda. 2017. *Communication alternative et augmentée : Aider les enfants et les adultes avec des difficultés de communication*.
- E. Cataix Nègre. 2017. *Communiquer autrement : Accompagner les personnes avec des troubles de la parole ou du langage*.
- Tom Scheinfeldt. 2008. Omeka: Open source web publishing for research, collections and exhibitions. *Open Source Business Resource*.
- Didier Schwab, Amela Fejza, Loïc Vial, and Yann Robert. 2018. The GazePlay Project: Open and Free Eye-trackers Games and a Community for People with Multiple Disabilities. In *ICCHP 2018 - 16th International Conference on Computers Helping People with Special Needs*, volume 10896 of *LNCS*, pages 254–261, Linz, Austria. Springer.
- L. Sevens, V. Vandeghinste, I. Schuurman, and F. Van Eynde. 2017. Simplified Text-to-Pictograph Translation for People with Intellectual Disabilities. *NLDB*.
- V. Vandeghinste and I. Schuurman. 2014. Linking Pictographs to Synsets: Sclera2Cornetto. *LREC*.
- C. Vaschalde, B. Lecouteux, and D. Schwab. 2018a. Génération de pictogrammes à partir de la parole spontanée pour la mise en place d’une communication médiée. *50 ans de linguistique sur corpus oraux : Apports à l’étude de la variation*.
- C. Vaschalde, P. Trial, E. Esperança-Rodier, D. Schwab, and B. Lecouteux. 2018b. Automatic pictogram generation from speech to help the implementation of a mediated communication. *Conference on Barrier-free Communication*.
- Michael Zock and Didier Schwab. 2011. Storage does not Guarantee Access: The Problem of Organizing and Accessing Words in a Speaker’s Lexicon. *Journal of Cognitive Science*, 12 :233–258. (Impact-F 3.52 estim. in 2012).