

# Constitution de corpus parallèle pour la simplification de textes médicaux

Rémi Cardon

CNRS, UdLille, UMR 8163 - STL - Savoirs Textes Langage  
`remi.cardon@univ-lille.fr`

M2 SDL

# Plan

- La simplification automatique de textes
- Le corpus CLEAR
- La tâche d'alignement de phrases
  - Annotation
  - Calcul d'accord inter-annotateur
  - Évaluation
  - Alignement automatique
  - Analyse d'erreurs

# Simplification automatique de textes – Objectifs


- Rendre l'information accessible aux humains
  - Enfants ou adultes ayant des difficultés de lecture (Bosch *et al.*, 2008; De Belder *et al.*, 2010; Vu *et al.*, 2014; Paetzold & Specia, 2016a)
  - Étrangers (Paetzold & Specia, 2016b)
  - Adultes ayant des troubles neurocognitifs (Chen *et al.*, 2016)
  - Grand public (textes spécialisés) (Arya *et al.*, 2011)
  - ...
- Pré-traitement de données pour le TAL
  - Analyse syntaxique (Chandrasekar & Srinivas, 1997)
  - Résumé automatique (Blake *et al.*, 2007)
  - Traduction automatique (Stymne *et al.*, 2013; Štajner & Popović, 2016)
  - Extraction / Recherche d'information (Beigman Klebanov *et al.*, 2004)
  - ...

# Simplification automatique de textes – Méthodes


- Modifier un texte pour le rendre accessible, tout en préservant son sens
- Principalement deux versants :
  - Simplification lexicale : remplacer les termes ou expressions complexes par des équivalents accessibles
  - Simplification syntaxique : retravailler les structures de phrases

# Simplification lexicale

## The Pipeline




# Simplification syntaxique



## Simplification syntaxique

- Phrase d'origine :
  - Caïn, l'aîné, cultive la terre et Abel (étymologie : de l'hébreu "souffle", "vapeur", "existence précaire") garde le troupeau.
- Possibilités de substitution :
  - ① Caïn, l'aîné, cultive la terre et Abel garde le troupeau.
  - ② Caïn, l'aîné, cultive la terre. Abel garde le troupeau.
  - ③ Caïn, l'aîné, cultive la terre.
  - ④ Abel garde le troupeau.
  - ⑤ Caïn, l'aîné, cultive la terre. Abel (étymologie : de l'hébreu "souffle", "vapeur", "existence précaire") garde le troupeau.
  - ⑥ Abel (étymologie : de l'hébreu "souffle", "vapeur", "existence précaire") garde le troupeau.
- Simplification sélectionnée :
  - Caïn, l'aîné, cultive la terre. Abel garde le troupeau.

# Réseaux de neurones



## Simplification automatique de textes – Méthodes

- Modifier un texte pour le rendre accessible, tout en préservant son sens
- Principalement deux versants :
  - Simplification lexicale : remplacer les termes ou expressions complexes par des équivalents accessibles
  - Simplification syntaxique : retravailler les structures de phrases
- Schéma d'annotation pour le processus de simplification (Brunato *et al.*, 2014)
  - Découpage, fusion, réorganisation de phrases
  - Insertion / Effacement (verbes, sujets, autres)
  - Transformation (substitution lexicale, remplacement des anaphores, modification des traits verbaux...)
- Pas de consensus pour l'évaluation d'un système de simplification
- Nécessite des corpus parallèles avec différents degrés de complexité

# Simplification automatique de textes – Corpus

- Corpus parallèles :
  - Anglais, Espagnol, Italien, Portugais du Brésil, Danois  
(Chandrasekar & Srinivas, 1997; Bott *et al.*, 2014; Brunato *et al.*, 2014; Caseli *et al.*, 2009; Klerke & Sjøgaard, 2012)
  - Pas toujours accessibles librement
- Corpus comparables :
  - Anglais : Simple English Wikipedia - English Wikipedia (SEW-EW), Newsela
  - Autres : Révisions dans Simple English Wikipedia, articles scientifiques ou romans simplifiés
- Pas de ressource en français

# Le corpus CLEAR

- Corpus comparable médical en français, pour la simplification de textes biomédicaux
- Trois sous-corpus :
  - Articles encyclopédiques
  - Notices de médicaments
  - Articles scientifiques
- Paires de documents
  - Même sujet
  - Deux niveaux de complexité

## Articles Encyclopédiques

- Publiés par la Fondation Wikimedia
- Wikipedia: s'adresse au grand public  
(2 186 891 tokens, 19 287 lemmes)
- Wikidia: s'adresse aux enfants de 8 à 13 ans  
(183 051 tokens, 3 117 lemmes)
- Rédigés indépendamment
- Articles du portail de la médecine
- 2\*575 articles
- Exemples :
  - La luette ou uvule est un appendice conique situé au fond de la **cavité buccale**. La luette est un organe de 10 à 15 millimètres de long. Elle est constituée d'un tissu membraneux et musculaire.
  - La luette ou uvule est un appendice conique situé au fond de la **bouche**. C'est un organe fait de tissus membraneux et musculaires, d'environ 10 à 15mm de long, qui pend à la partie moyenne du voile du palais.

# Notices de médicament

- Publiés par le Ministère de la Santé
- Résumés des caractéristiques produit (RCP), pour les praticiens

(51 705 111 tokens, 43 515 lemmes)

- Notices, pour les patients

(33 116 119 tokens, 25 725 lemmes)

- 2\*11 800 notices

- Exemples :

- **hypersensibilité** à l'huile de paraffine. / - ne pas utiliser chez les personnes présentant des **difficultés de déglutition** en raison du risque d'inhalation bronchique et de pneumopathie lipoïde.
- si vous avez une **allergie** à l'huile de paraffine. / - ne pas utiliser chez les personnes présentant des **difficultés pour avaler** en raison du risque d'inhalation de la paraffine liquide qui entraîne une pneumopathie lipoïde.

## Articles scientifiques

- Publiés par la Fondation Cochrane
- Revues de littérature médicale pour les praticiens  
(2 804 335 tokens, 11 558 lemmes)
- Versions simplifiées manuellement par la fondation pour le grand public  
(1 491 243 tokens, 7 567 lemmes)
- 2\*3 815 résumés
- Exemples :
  - L'hématome aigu de l'oreille est une affection qui se caractérise par la formation d'une collection sanguine sous le périchondre du pavillon. Il est souvent provoqué par un traumatisme contondant.
  - L'hématome aigu de l'oreille est une affection qui se caractérise par la formation d'une collection sanguine dans le pavillon (oreille externe), souvent à la suite d'un traumatisme contondant.

## Résumé

	<i>docs</i>	<i>tokens<sub>tech</sub></i>	<i>tokens<sub>acc</sub></i>	<i>total tokens</i>	<i>lemmes<sub>tech</sub></i>	<i>lemmes<sub>acc</sub></i>
<i>Wiki</i>	575*2	2,293,078	197,672	2,490,750	19 287	3 117
<i>Médicaments</i>	11,800*2	52,313,126	33,682,889	85,996,015	43 515	25 725
<i>Cochrane</i>	3,815*2	2,840,003	1,515,051	4,355,054	11 558	7 567
<i>Total</i>	16,190	57,446,207	35,395,612	92,841,819		

- 16 190 paires de documents
- Technique : 57M tokens
- Simple : 35M tokens
- Total : 92M tokens
- Plus grande diversité lexicale côté technique

# Alignement automatique

- Objectif : constituer un corpus de phrases parallèles
- Alignement manuel : données d'entraînement
- Unité de traitement : paire de phrases
- Trop peu de données pour les réseaux de neurones
- Approche : tâche de classification binaire (paire alignée / non-alignée)
- Données :
  - paires alignées : résultat de l'alignement manuel
  - paires non alignées : appariement aléatoire hors paires alignées

# Critères d'alignement

- Alignement :
  - Équivalence – sens identique ou presque identique :
    - Une gêne visuelle passagère peut être ressentie après **instillation** du collyre.
    - Une gêne visuelle passagère peut être ressentie après l'**administration** du collyre.
  - Inclusion – le sens d'une phrase se retrouve intégralement dans une autre :
    - **La maladie de Charcot est l'autre nom de la sclérose latérale amyotrophique.**
    - Il est le découvreur de **la sclérose latérale amyotrophique, ou maladie de Charcot**, une maladie neurodégénérative.

## Critères d'alignement

- Non-alignement :
  - Phrases identiques, ou qui varient seulement par la ponctuation ou les mots grammaticaux :
    - Effets sur l'aptitude à conduire des véhicules **ou** à utiliser des machines
    - Effets sur l'aptitude à conduire des véhicules **et** à utiliser des machines
  - Intersection – deux phrases qui partagent du sens mais qui apportent chacune une information qui leur est propre :
    - Une faiblesse musculaire (hypotonie axiale), des difficultés d'alimentation (troubles de la succion entraînant une faible prise de poids), une hyperexcitabilité, une agitation ou des tremblements **peuvent survenir chez le nouveau-né**, ces troubles étant réversibles.
    - Un traitement en fin de grossesse par benzodiazépines même à faibles doses, peut être responsable **chez le nouveau-né de signes d'imprégnation tels qu'hypotonie axiale, troubles de la succion entraînant une faible prise de poids.**

## Critères d'alignement – Récapitulatif

- **Alignement :**
  - Équivalence – sens identique ou presque identique
  - Inclusion – Le sens d'une phrase se retrouve intégralement dans l'autre
- **Non-alignement :**
  - Phrases identiques
  - Phrases qui diffèrent seulement par la ponctuation ou les mots grammaticaux
  - Intersection – Les phrases partagent une partie de leur signification mais chacune apporte une information qui ne se retrouve pas dans l'autre
- **Format :**
  - Créer un fichier .ex et un fichier .gp (exemple : Hématome.ex et Hématome.gp). Pour chaque alignement, la phrase ex est à mettre dans le fichier .ex, et la phrase gp dans le fichier .gp, **au même numéro de ligne**

# Alignement automatique

- Descripteurs des paires de phrases :
  - Nombre de mots communs hors stopwords
  - Nombre de stopwords communs
  - Pourcentage de mots d'une phrase présents dans l'autre
  - Différence de longueur entre les deux phrases (en mots)
  - Différence de longueur moyenne des mots entre les deux phrases
  - Nombre total de bigrammes et trigrammes communs (en caractères)
  - Mesures de similarité : cosine, Dice, Jaccard
  - Distance d'édition (Levenshtein) entre les deux phrases (caractères, et mots)

- ARYA D. J., HIEBERT E. H. & PEARSON P. D. (2011). The effects of syntactic and lexical complexity on the comprehension of elementary science texts. *Int Electronic Journal of Elementary Education*, **4**(1), 107–125.
- BEIGMAN KLEBANOV B., KNIGHT K. & MARCU D. (2004). Text simplification for information-seeking applications. In R. MEERSMAN & Z. TARI, Eds., *On the Move to Meaningful Internet Systems 2004: CoopIS, DOA, and ODBASE*. Berlin, Heidelberg: Springer, LNCS vol 3290.
- BIRAN O., BRODY S. & ELHADAD N. (2011). Putting it simply: a context-aware approach to lexical simplification. In *Annual Meeting of the Association for Computational Linguistics*.
- BLAKE C., KAMPOV J., ORPHANIDES A., WEST D. & LOWN C. (2007). Query expansion, lexical simplification, and sentence selection strategies for multi-document summarization. In *DUC*.
- BOSCH S., PRETORIUS L. & FLEISCH A. (2008). Experimental bootstrapping of morphological analysers for Nguni languages. *Nordic Journal of African Studies*, **17**(2), 66–88.

- BOTT S., SAGGION H. & MILLE S. (2014). Text simplification tools for spanish. In *LREC 2014*, p. 1–7.
- BRUNATO D., DELL'ORLETTA F., VENTURI G. & MONTEMAGNI S. (2014). Defining an annotation scheme with a view to automatic text simplification. In *CLICIT*, p. 87–92.
- CASELI H. M., PEREIRA T. F., SPECIA L., PARDO T. A. S., GASPERIN C. & ALUISIO S. M. (2009). Building a Brazilian Portuguese parallel corpus of original and simplified texts. In *CICLING*, p. 1–12.
- CHANDRASEKAR R. & SRINIVAS B. (1997). Automatic induction of rules for text simplification. *Knowledge Based Systems*, **10**(3), 183–190.
- CHEN P., ROCHFORD J., KENNEDY D. N., DJAMASBI S., FAY P. & SCOTT W. (2016). Automatic text simplification for people with intellectual disabilities. In *AIST*, p. 1–9.
- CÔTÉ R. (1996). *Répertoire d'anatomopathologie de la SNOMED internationale, v3.4*. Université de Sherbrooke, Sherbrooke, Québec.

- DE BELDER J., DESCHACHT K. & MOENS M.-F. (2010). Lexical simplification. In *ITEC*. 1-4.
- KLERKE S. & SØGAARD A. (2012). DSim, a Danish parallel corpus for text simplification. In *LREC*, p. 4015–4018.
- PAETZOLD G. H. & SPECIA L. (2016a). Benchmarking lexical simplification systems. In *LREC*, p. 3074–3080.
- PAETZOLD G. H. & SPECIA L. (2016b). Unsupervised lexical simplification for non-native speakers. In *AAAI Conference on Artificial Intelligence*, p. 3761–3767.
- PEDREGOSA F., VAROQUAUX G., GRAMFORT A., MICHEL V., THIRION B., GRISEL O., BLONDEL M., PRETTENHOFER P., WEISS R., DUBOURG V., VANDERPLAS J., PASSOS A., COURNAPEAU D., BRUCHER M., PERROT M. & DUCHESNAY E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, **12**, 2825–2830.
- SAJOUS F. & HATHOUT N. (2015). GLAWI, a free XML-encoded Machine-Readable Dictionary built from the French Wiktionary. In *Proceedings of the eLex 2015 conference*, p. 405–426, Herstmonceux, England.

- SHARDLOW M. (2014). A survey of automated text simplification. *Int J Advanced Computer Science and Applications*, **1**, 1–13.
- STYMNE S., TIEDEMANN J., HARDMEIER C. & NIVRE J. (2013). Statistical machine translation with readability constraints. In *NODALIDA*, p. 1–12.
- ŠTAJNER S. & POPOVIĆ M. (2016). Can text simplification help machine translation? *Baltic J. Modern Computing*, **4**(2), 230–242.
- VU T. T., TRAN G. B. & PHAM S. B. (2014). Learning to simplify children stories with limited data. In L. . SPRINGER, Ed., *Intelligent Information and Database Systems*, p. 31–41.
- WUBBEN S., VAN DEN BOSCH A. & KRAHMER E. (2012). Sentence simplification by monolingual machine translation. In *Annual Meeting of the Association for Computational Linguistics*, p. 1015–1024.