

Construction d'un vocabulaire patient/médecin

Mike Donald TAPI NZALI^{1,2} **S. Bringay**² C. Lavergne¹
T. Opitz¹ J. Azé² C. Mollevi³

¹IMAG, Université de Montpellier, France

²LIRMM, Université de Montpellier, France

³ICM, Institut du Cancer de Montpellier, France

1^{er} juillet 2015



Plan

- 1 Introduction
 - Contexte
 - Objectifs
- 2 Méthodes
- 3 Résultats
 - Protocole de validation
 - Résultats
- 4 Conclusions
 - Conclusions
 - Perspectives

Financements

3 projets

- **Patients Mind** : Réseau National des MSH (Maisons des Sciences de l'Homme) 2013-2014 et 2014-2015
- **SFIR** : Projet ANR 2012-2015
- **Qualité de vie** : Contrat Iresp 2012-2015



SFIR

Toulouse



Lille

Montpellier



Qualité de vie



Média sociaux



QLQ BR-23

Formulaire sur la
qualité de vie



Qualité de vie

Travaux réalisés : extraction supervisée et non supervisée

- des **thèmes** d'intérêt des patients
- de la **temporalité** (avant, après la chirurgie...)
- des **sentiments**
- des **locuteurs**

Ma sœur a très **peur** de ne pas supporter sa **chimiothérapie** du 8 janvier 2015.

Difficulté : traiter les textes mal rédigés des patients

[163904] posté le 05/01/2012 09:45:00 par

Je m'interroge aussi. J'ai 31 ans et on m'a annoncé clairement que jamais je ne pourrais avoir d'enfants. Maintenant pkoi ne pas bloquer les ovaires...si reeellement je ne donnerai jms la vie, ces trucs ne servent plus qu'a nourrir mon cancer.

Je vois mon gygy ce mois ci je vais bien lui en parler

Acquisition du vocabulaire Patient/Médecin

Motivations : Faciliter les traitements des textes issus des réseaux sociaux

- **Rechercher** plus efficacement des contenus dans ces messages (mots-clés patients)
- **Classifier**

Objectif

- Étendre une **ontologie médicale** existante avec le vocabulaire fréquemment utilisé par les patients (INCA)

Intuition

- Utiliser les **Patient Author Text** pour extraire le vocabulaire **semi-automatiquement**

CHV : Consumer Health Vocabulary

2 CHV en anglais

- *MedlinePlus* produit par la National Library of Medicine
- *Open and Collaborative Consumer Health Vocabulary* inclus dans l'UMLS

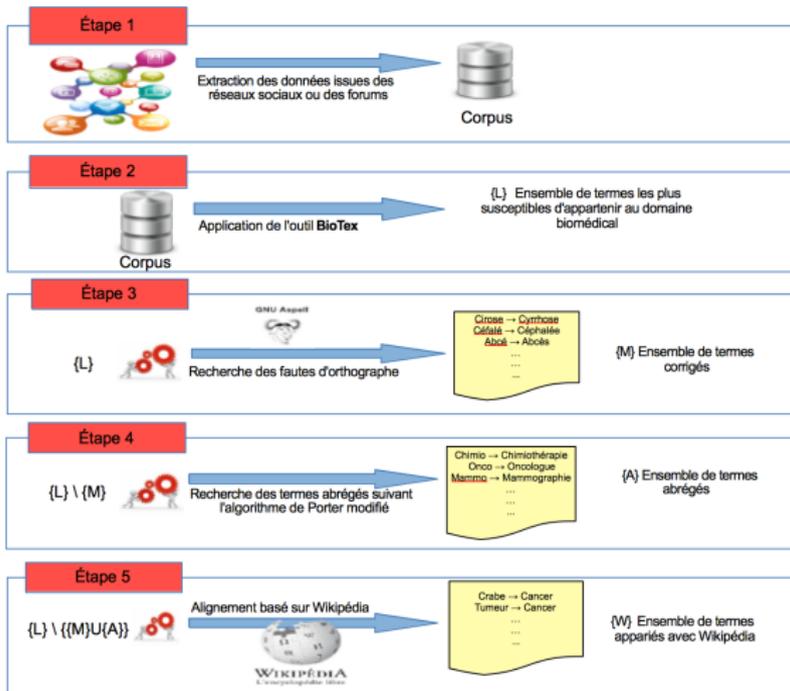
Utilisation

- Réduire les **écarts de connaissances** patient/médecin
- Améliorer la **lisibilité** des documents médicaux
- Augmenter la **confiance** que l'on a dans le discours du médecin (mieux compris)

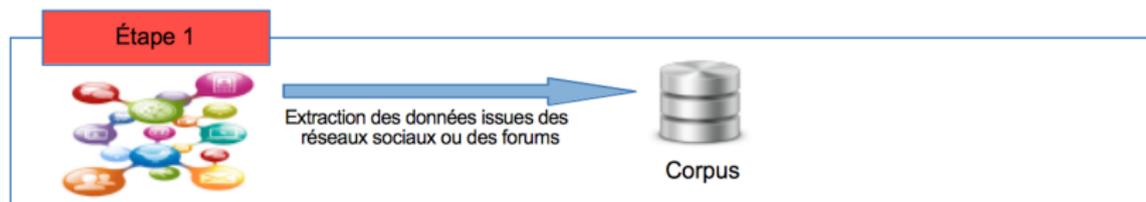
Plan

- 1 Introduction
 - Contexte
 - Objectifs
- 2 Méthodes
- 3 Résultats
 - Protocole de validation
 - Résultats
- 4 Conclusions
 - Conclusions
 - Perspectives

Méthode proposée



Étape 1 : Acquisition des données



Forums de santé : de la création des sites jusqu'en octobre 2014

<http://www.cancerdusein.org/le-forum>

- 665 membres
- 1050 topics
- 17 000 messages

<http://www.lesimpatientes.com>

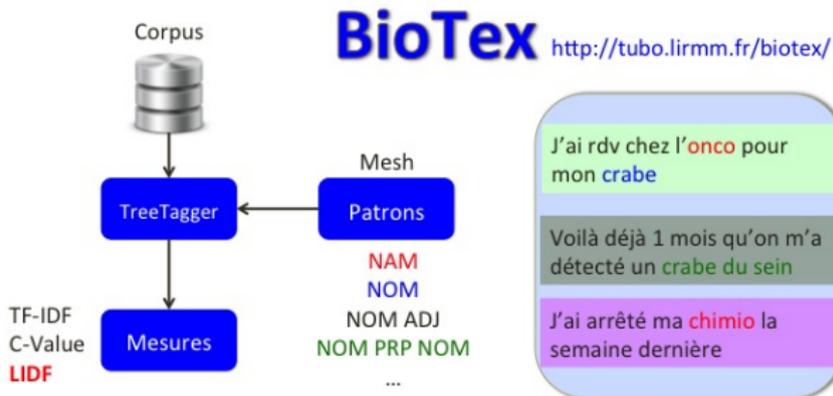
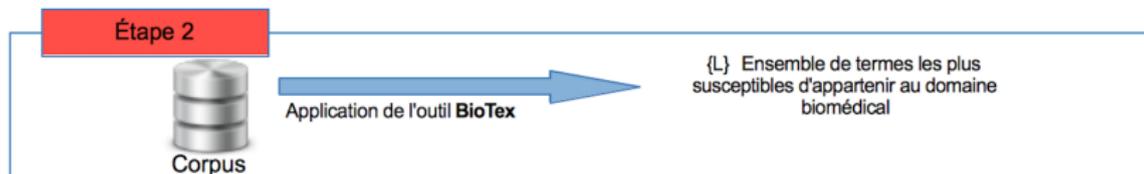
- 4 486 membres
- 93 topics
- 132 789 messages

Acquisition des données : Groupes du réseau social facebook

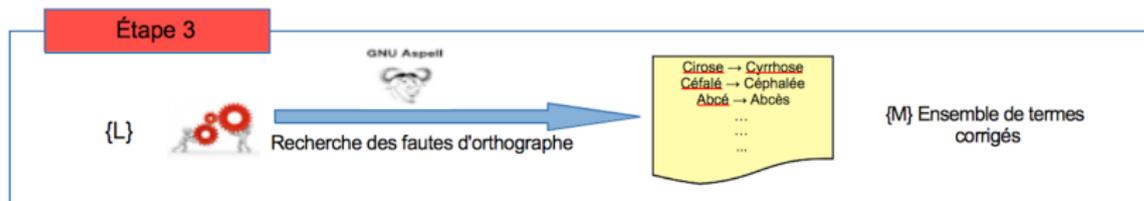
Groupes facebook

- Post d'un utilisateur (ou membre)
 - Date et heure du post
 - Commentaires/"like" liés aux posts
-
- 5 groupes
 - 1 389 utilisateurs
 - 96 792 messages

Étape 2 : Extraction des termes candidats

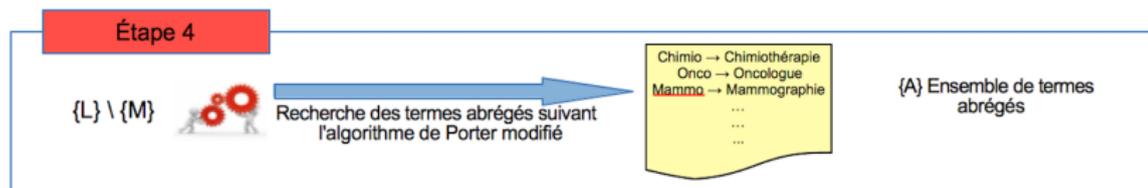


Étape 3 : Erreurs d'orthographe fréquentes



- Modification de l'algorithme **ASPELL** : INCA
- Mot patient \rightsquigarrow Mot médecin
 - **Cirose** \rightsquigarrow **Cirrhone**
 - **Céfalé** \rightsquigarrow **Céphalée**
 - **Abcé** \rightsquigarrow **Abcès**

Étape 4 : Détection des termes abrégés



- Liste de **suffixes** : *logue, logie, thérapie, thérapeute...*
- Mot patient \rightsquigarrow Mot médecin
 - onco \rightsquigarrow oncologue
 - chimio \rightsquigarrow chimiothérapie

(Paternostre et al. 2002) Carry, un algorithme de désuffixation pour le français.

Étape 5 : Alignement basé sur Wikipédia



WIKIPÉDIA
L'encyclopédie libre

Accueil
Portails thématiques
Article au hasard
Contact

Contribuer
Débiter sur Wikipédia
Aide
Communauté
Modifications récentes
Faire un don

Outils
Importer un fichier
Pages spéciales
Version imprimable

Langues

Article Discussion

Pages liées à Crabe

-- Crabe

Pages liées

Page : Crabe Espace de noms : To

Filtres

Afficher les inclusions | Masquer les liens | Masquer les redirections

Les pages ci-dessous contiennent un ou plusieurs liens vers **Crabe** (ne voir que Voir (250 précédentes | 250 suivantes) (20 | 50 | 100 | 250 | 500).

- Bahamas (– liens)
- Cuisine française (– liens)
- Costa Rica (– liens)
- Zodiaque (– liens)
- Amazone (fleuve) (– liens)
- Mississippi (fleuve) (– liens)
- Cancer (homonymie) (– liens)
- René-Antoine Ferchault de Réaumur (– liens)

$$M(w_k, t_n) = \frac{N(w_k, W(t_n)) + N(t_n, W(w_k))}{2}$$

$$Poids(w_j, t_i) = \frac{M(w_j, t_i)}{\sum_{k=1}^{|W|} M(w_k, t_i)}$$

où $N(a, W(b))$: fréquence de a dans la page wikipedia de b .

Plan

- 1 Introduction
 - Contexte
 - Objectifs
- 2 Méthodes
- 3 Résultats**
 - Protocole de validation
 - Résultats
- 4 Conclusions
 - Conclusions
 - Perspectives

Protocole de validation

Connaissances extraites

- Relation r
- Mot patient pat
- Mot médecin med
- Etiquette $meth \in \{ortho, abb, asso\}$

Validation automatique

- **JeuxDeMot** : réseau lexical issu d'un jeu contributif (<http://www.jeuxdemots.org/diko.php>)

Validation manuelle

- Relations non validées automatiquement
- Annotations manuelles : **4 annotateurs**

Résultats

Validation automatique

- Sur 432 relations obtenues, 211 ont été validées automatiquement (48,8%)
- 32 relations - erreurs orthographiques (7,4%)
- 10 relations - abbréviations (2,3%)
- 169 relations - associations wikipedia retrouvées dans JDM (39,1%)

Validation manuelle

- Sur 218 relations restantes, 93 ont été retenues après consensus (42,6%)
- Kappa : 0,21 (faible)

Plan

- 1 Introduction
 - Contexte
 - Objectifs
- 2 Méthodes
- 3 Résultats
 - Protocole de validation
 - Résultats
- 4 Conclusions
 - Conclusions
 - Perspectives

Conclusions

Des travaux préliminaires

- + Précision globale : **71% vs. 31%** (Doing-Harris 2011) pour un CHV en anglais généraliste
- + Alignements d'**expressions composées**
- + **Solicitation de l'expert** limitée > Impact du poids
- **Peu de relations** > Spécificité de la ressource pour le cancer du sein (dictionnaire INCA - 1 227 termes)

(Doing-Harris 2011) Computer-assisted update of consumer health vocabulary through mining of social network data.

Perspectives

À court terme

- Applications à d'**autres domaines** que la cancérologie
- **Rappel** : combien de mots patients intéressants a t'on oublié ?
- Impact des **données** en entrée (forums » réseaux sociaux...)

À plus long terme

- Choix Wikipedia (ni grand public, ni scientifique) > Autres **mesures d'appariement** « google, yahoo... »
- Étendre une ontologie au format « SKOS » > **export dans BioPortal**
- Évaluer l'effet sur la classification

Ressources

En français

- Vocabulaire **Patient** :
<http://www.lirmm.fr/tapinzali/Ressources/VocPatMed>
- Vocabulaire **Sentiment** : <https://www.lirmm.fr/patient-mind/>
> onglet Ressource

Principal auteur de ces travaux

Mike-Donald.Tapi-Nzali@lirmm.fr

