

Quality of life and breast cancer: medical information retrieval in internet health forums

Thomas Opitz

Laboratoire d'Informatique, de Robotique et de Microélectronique de Montpellier (LIRMM)
Institut de Mathématiques et de Modélisation de Montpellier (I3M)
Université Montpellier 2

Workshop « Evaluation et Analyse de la Qualité de Vie en Oncologie »

ICM, Montpellier
03/04/2014

The project



Institut de Mathématiques
et de Modélisation
de Montpellier

Christian Lavergne
Cyrille Joutard

Thomas Opitz

Sandra Bringay
Jérôme Azé



Laboratoire
d'Informatique
de Robotique
et de Microélectronique
de Montpellier



Institut régional du Cancer
Montpellier | Val d'Aurelle

Caroline Mollevi

① Introduction : quality of life and social media

② A method for the extraction of medical information

③ Results

④ Perspectives and conclusions

Quality of life (QoL) as a clinical concept

- **multidimensional**

physical – psychological – social

- definition and **quantification** of QoL-dimensions is **difficult**

- **auto-questionnaires** : EORTC-QLQ-C30¹
breast cancer specific module QLQ-BR23

1. [Aaronson et al., 1993]

Quality of life in social media

- **social media** $\rightsquigarrow$ user empowerment, knowledge democratization
- **large textual databases**

Cancerdusein.org forum : 675 members, 17,000 posts.

- **anonymous communication**

$\rightsquigarrow$ easier expression of affective states (emotions, opinions, doubts, ...)²

Our project's objectives

extract **clinically relevant information**

- items of the QLQ-BR23 questionnaire
- online health forums (Cancerdusein.org)
- compare to traditional clinical studies

① Introduction : quality of life and social media

② A method for the extraction of medical information

③ Results

④ Perspectives and conclusions

Main challenges

- texts are **heterogeneous and noisy**
 - ~> standard preprocessing methods
- many lexical variations of a given topic keyword
 - ~> **query expansion** techniques to **enrich topic descriptions**
- need **user metadata** → socio-economic data, clinical history, ...
 - ~> retrieve information from data

Overview of our approach

Step 1



**Message collection
and preprocessing**



Messages
database

Step 2



**Topic identification
Morphological topic expansion**

$\{TTI\} \cup \{TMM\}$

Initial list of topics

Step 3

Synonymic
topic
expansion

$\{TTI\} \cup \{TMM\}$



Proposed
 $\{TTS\}$



Web validation

Topic context $\{E_i\}$

Score S

Expansion context $\{O_i\}$



$S < S_0$
 $S \geq S_0$

Validated
 $\{TTS\}$

Step 4

Final list of topics

$TIMS = \{TTI\} \cup \{TMM\} \cup \{\text{Validated } TTS\}$

Query
+



Messages
database

Statistical
interpretation



Step 1 : Data preprocessing

① spell correction

② dimension reduction

① removal of stopwords like *et, de, ne, ...*

② lemmatization³ : *traite, traitant, traité, traitées, ...* $\rightsquigarrow$ *traiter*

Example :

moi j ai faite un reconstruction avec expendeur et je suis satisfaite du resultat

1) *moi j'ai fait_ un reconstruction avec expendeur et je suis satisfaite du résultat*

2.1) *j'ai fait reconstruction expendeur satisfaite résultat*

2.2) *je faire reconstruction expendeur satisfaire résultat*

Step 2 : Manual definition of topics



QLQ-BR23

I1 : Avez-vous eu la bouche sèche?

I2 : La nourriture ou la boisson ... ?

...

secondary effects of the treatment
(e.g. hair loss)

symptoms in the breast region

body image

sexuality

...

identify topics → keyword representation

Topic 1 = {bouche sec}

Topic 2 = {boisson goût, nourriture goût}

...

morphological expansion

bouche
buccal

dessèchement
sec
sécheresse desséché

Topic 1 = {bouche sec, **buccal sec**, **bouche dessèchement**, **bouche desséché** ...}

Topic 2 = {boisson goût, nourriture goût, **aliment goût** ...}

...

Step 3 : Automatic synonymic topic expansion

lexical variations beyond morphology $\rightsquigarrow$ many false negatives

*"Mauvais goût dans la bouche et **langue pâteuse** ah ma bouche réel point faible !!!"*

*"[...] car ma **langue** faisait **bizarre** et avait un bouton [...]"*



use **synonym expressions** for topic keywords

synonym tools : www.synonymo.fr and www.cnrtl.fr/synonymie

polysemy

- synonymy is context-sensitive
- synonym terms too numerous for manual selection

$\rightsquigarrow$ define a **score** for **automatic ranking** of synonym expansion

$\rightsquigarrow$ keep only useful expansions

Context = frequent co-occurrences

- **synonym context** must be **close to the original context**
- context defined from a large text corpus (yahoo.fr)
 - unigrams/bigrams from 40 search engine snippets for each keyword
 - feature weight = frequency of co-occurrence

[Bouche sèche - Xérostomie - Doctissimo](http://www.doctissimo.fr/html/sante/encyclopedie/bouche-seche.htm)

www.doctissimo.fr/html/sante/encyclopedie/bouche-seche.htm En cache

Avoir une **bouche sèche**, cela peut arriver à n'importe qui ponctuellement. Mais quand cela persiste, il ne faut pas se contenter de boire pour hydrater sa **bouche**.

[Bouche sèche - Traitement et symptômes de la sécheresse ...](http://www.santepublique.fr/bouche-seche.php)

www.santepublique.fr/bouche-seche.php En cache

La **bouche sèche** pourrait être prévenue en partie par une hygiène rigoureuse mais non agressive de la cavité buccale et une hydratation suffisante.

...

topic : { *bouche* | *buccal* | ... *sec* | *dessécher* | ... }

topic context : *bouche sec* (0.68), *buccal* (0.58), *sécheresse* (0.45), *sec* (0.42), *bouche* (0.25), *mauvais haleine* (0.2), *xérostomie* (0.17), *symptôme* (0.13), *salive* (0.13), ...

[langue seche et tres blanche - Troubles ORL - FORUM Santé](http://forum.doctissimo.fr/sante/troubles-ori/langue-seche...)

forum.doctissimo.fr/sante/troubles-ori/langue-seche... En cache

bonjour voila depuis plus de six mois j'ai ma **langue** de plus en plus blanche, tres blanche et **seche** , j'ai consulté mon generaliste il m'a donne des anti bio, et c ...

[Bouche sèche la nuit / le matin? - Yahoo Questions/Réponses](http://fr.answers.yahoo.com/question/index?qid=20090714173539...)

fr.answers.yahoo.com/question/index?qid=20090714173539... En cache

"Bouche **sèche** la nuit / le matin?" ... ça fait plusieurs années que j'ai la bouche **sèche** (parfois même la **langue** collé au palais) ...

...

expansion : *langue sec*

expansion context : *langue* (0.95), *langue sec* (0.8), *sec* (0.72), *bouche sec* (0.4), *mauvais haleine* (0.2), *bouche* (0.19), *sensation* (0.18), ...

...

we define the **chi-square score**

$$S = 1 - \left(\sum_{i=1}^k E_i \right)^{-1} \times \sum_{i=1}^k \max(E_i - O_i, 0)^2 / E_i \quad \in [0, 1].$$


- E_i – **weights** of the most important **topic** co-occurrences
- O_i – corresponding **weights** for the **expansion**

$\rightsquigarrow$ disjoint contexts for $S = 0$ and identical contexts for $S = 1$

- 1 Introduction : quality of life and social media
- 2 A method for the extraction of medical information
- 3 Results**
- 4 Perspectives and conclusions

Results

- keep automatic synonymic expansions if $S \geq 0.2$, manual validation for $0.1 \leq S \leq 0.2$
- 5 topic categories




- ① Introduction : quality of life and social media
- ② A method for the extraction of medical information
- ③ Results
- ④ Perspectives and conclusions

Clinical evaluation of results

further information is necessary

- **clinical history of forum users** $\rightsquigarrow$ **supervised classification methods**
- information about quality of life related to occurrences
 $\rightsquigarrow$ **semi-automatic sentiment analysis** in free texts



Conclusions

- patients discuss **clinically relevant issues in health forums**
- **semi-automatic approach** works
- close **cooperation** between **data experts** and **clinical experts** :
 - **information** in social media is **abundant**
 - which information is **useful** ?
 - how can we **extract** it ?

