

## French ConText: Détecter la négation, la temporalité et le sujet dans les textes cliniques Français

Amine Abdaoui, Andon Tchechmedjiev, William Digan, Sandra Bringay,  
Clement Jonquet

### ► To cite this version:

Amine Abdaoui, Andon Tchechmedjiev, William Digan, Sandra Bringay, Clement Jonquet. French ConText: Détecter la négation, la temporalité et le sujet dans les textes cliniques Français. 4ème Symposium sur l'Ingénierie de l'Information Médicale, SIIM'17, Nov 2017, Toulouse, France. 2017, <<http://www.cimi.univ-toulouse.fr/mib/fr/symposium-sur-l'ingenierie-de-l'information-medicale-siim>>. <lirmm-01656834>

**HAL Id: lirmm-01656834**

**<https://hal-lirmm.ccsd.cnrs.fr/lirmm-01656834>**

Submitted on 6 Dec 2017

**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.

# French ConText: Détecter la négation, la temporalité et le sujet dans les textes cliniques Français

Amine Abdaoui\*, Andon Tchechmedjiev\*, William Digan\*\*,  
Sandra Bringay\*,\*\*\*, Clément Jonquet\*,\*\*\*\*

\*LIRMM, Université de Montpellier, France

\*\*Hôpital Européen Georges Pompidou, Paris, France

\*\*\*Groupe AMIS, Université de Paul Valéry, Montpellier, France

\*\*\*\*Stanford Center for Biomedical Informatics Research, Stanford, USA

*a\_abdaoui@esi.dz, jonquet@lirmm.fr*

**Résumé.** La détection du contexte des conditions cliniques présentes dans un dossier patient est un élément important dans le traitement automatique des textes médicaux. Ce papier décrit l'adaptation au français du système anglais ConText qui permet de détecter si une condition clinique identifiée dans un texte est affirmée ou niée, récente ou historique, et concerne le patient ou pas. Nous avons évalué notre système sur deux types de textes médicaux : des dossiers patients et des certificats de décès. Les résultats obtenus sont comparables aux versions anglaises et suédoises de ConText et dépassent ceux obtenus en langue française (négation seulement) lorsqu'on utilise le même jeu de données de référence. En outre, le système French ConText a été intégré dans le SIFR Annotator (<http://bioportal.lirmm.fr/annotator>), un service web d'annotation sémantique de données biomédicales pour le français.

## 1 Introduction

L'annotation automatique des conditions cliniques dans les textes médicaux permet d'extraire des connaissances très utiles à partir de données textuelles brutes. Elle permet, par exemple, de détecter automatiquement les maladies ou les symptômes décrits dans les dossiers médicaux des patients. Cela est utilisé, entre autres, pour l'aide au diagnostic, l'identification de cohortes ou la surveillance. Cependant, il ne suffit pas de détecter une condition particulière dans un dossier patient, mais il faut aussi distinguer une condition affirmée d'une condition niée. De même, un patient sera exclu d'une cohorte si une maladie identifiée dans son dossier ne le concerne pas directement (par exemple antécédents familiaux). Ainsi, la détection du «contexte» des conditions cliniques est un élément clé dans le processus d'annotation. Plusieurs méthodes ont été proposées pour détecter le contexte des conditions cliniques, en particulier pour les textes médicaux en anglais. Dans ce travail, notre objectif est double : (i) proposer un système équivalent et efficace pour les textes cliniques français et (ii) rendre ce système facilement accessible et utilisable par la communauté médicale française qui ne possède pas nécessairement d'expertise en traitement automatique de la langue.

NegEx est l'un des premiers systèmes permettant de détecter le contexte des conditions cliniques pour la langue anglaise (Chapman et al., 2001). Il utilise des expressions régulières et des indicateurs lexicaux (modificateurs, pseudo-modificateurs et termes de terminaison). L'idée de base est de considérer une condition comme affirmée par défaut et de la marquer comme niée si elle apparaît sous la portée d'un modificateur ("aucun signe", "absence de", "est écarté", etc.). Outre sa simplicité, cet algorithme est rapide et efficace. Dans la littérature scientifique, deux principales catégories de méthodes de détection de la négation ont été proposées : les méthodes de la première catégorie suivent le même principe que NegEx en utilisant uniquement des indicateurs lexicaux (Elkin et al., 2005) ou en les combinant avec des règles de grammaire construites manuellement (Huang et Lowe, 2007). Les méthodes de la deuxième catégorie utilisent des techniques d'apprentissage supervisé comme les arbres de décision (Rokach et al., 2008), les champs aléatoires conditionnels ou les machines à vecteurs de support (Morante et Daelemans, 2009). Cette deuxième catégorie de méthodes nécessite des données d'entraînement préalablement annotées, ce qui est généralement difficile à obtenir dans les milieux cliniques. En outre, une étude comparative a évalué NegEx et deux systèmes d'apprentissage supervisé sur le même jeu de données et a conclu que NegEx était plus efficace (Goryachev et al., 2006).

Pour sa simplicité et son efficacité, NegEx a été adapté à trois autres langues européennes : suédois (Skeppstedt, 2011), français (Deléger et Grouin, 2012) et allemand (Chapman et al., 2013). Adapter NegEx à ces langues consistait principalement à traduire ses indicateurs lexicaux. L'approche de NegEx a été par la suite étendue pour détecter non seulement la négation, mais aussi la temporalité et le sujet des conditions cliniques, toujours dans des textes en anglais (Harkema et al., 2009). Le système résultant, ConText, a depuis été porté au suédois (Velupillai et al., 2014) mais pas au français. En ce qui concerne la langue française, l'adaptation de NegEx (Deléger et Grouin, 2012) s'est basée sur une liste restreinte d'indicateurs lexicaux (270 termes français) qui concernaient tous un seul contexte (la négation). Plus récemment, Garcelon et al. ont proposé un autre système pour détecter le contexte des conditions cliniques lors de la recherche dans l'entrepôt de données cliniques de l'hôpital Necker (Garcelon et al., 2016). En plus de la négation, les auteurs ont compilé des indicateurs lexicaux français pour détecter l'historique familial. Leur système est assez spécifique car il filtre les conditions négatives et liées à la famille uniquement dans le contexte du moteur de recherche de l'hôpital. Néanmoins, nous avons utilisé leur liste d'indicateurs afin d'enrichir la nôtre.

En ce qui concerne le processus d'annotation, notre équipe développe le SIFR Annotator (<http://bioportal.lirmm.fr/annotator>) : un service d'annotation sémantique ouvert et facilement accessible pour le français (Jonquet et al., 2016; Tchechmedjiev et al., 2009). Ce service a été significativement amélioré et adapté pour le français, mais repose à l'origine sur le NCBO Annotator (Jonquet et al., 2009), un service Web permettant d'utiliser les ontologies et terminologies biomédicales pour annoter automatiquement des textes en anglais. L'Annotator traite les données textuelles brutes, identifie les concepts d'ontologies biomédicales et renvoie les annotations aux utilisateurs dans le format désiré (JSON-LD, RDF ou BRAT). Le SIFR Annotator utilise 25 terminologies et ontologies standards qui ont été agrégées dans le SIFR BioPortal (<http://bioportal.lirmm.fr>), une installation locale de la technologie du NCBO (Noy et al., 2005) dédiée au français. Dans le but de proposer une plateforme complète d'annotation sémantique, nous avons intégré French ConText dans le workflow du SIFR Annotator. La suite de ce papier présente l'adaptation de ConText

au français, son intégration dans le SIFR Annotator et son évaluation sur deux types de textes médicaux.

## 2 Matériels et Méthodes

Dans cette section, nous présentons l'algorithme original de ConText, son adaptation au français par la compilation d'une liste d'indicateurs lexicaux, son intégration dans le SIFR Annotator et notre méthode d'évaluation.

### 2.1 L'algorithme ConText

L'algorithme ConText utilise une liste d'indicateurs lexicaux afin d'identifier le contexte des conditions cliniques annotées dans une phrase. Il considère trois contextes : la négation, la temporalité et le sujet. Chaque contexte peut accepter les valeurs suivantes <sup>1</sup> :

- **Négation** : *affirmé*, possible ou nié ;
- **Temporalité** : *récente*, historique ou hypothétique ;
- **Sujet** : *patient* ou autre.

Par défaut, une condition médicale annotée est considérée comme affirmée, récente et concerne le patient. Cependant, les valeurs contextuelles peuvent changer si la condition se trouve sous la portée d'un modificateur. Par exemple, dans la phrase "le patient n'a aucun signe de mélanome", la condition soulignée est niée puisqu'elle est précédée par le modificateur "aucun signe de". Pour chaque valeur contextuelle (en dehors des valeurs par défaut), le système ConText conserve une liste distincte de termes (modificateurs). Par exemple, le terme "est écarté" déclenche la valeur niée, le terme "antécédent de" déclenche la valeur historique, tandis que le terme "mère" déclenche la valeur autre.

La portée de chaque modificateur est prédéfinie soit vers l'avant (par exemple, "pas de") ou vers l'arrière (par exemple, "est exclue"). Cette portée se termine par défaut à la fin de la phrase. Cependant, certains termes peuvent mettre fin à la portée des modificateurs. Par exemple, le terme "mais" met fin à la portée des modificateurs de négation. Enfin, certaines expressions contiennent des termes de déclenchement mais ne modifient pas le contexte. Par exemple, l'expression "sans augmentation" est considérée comme un pseudo-modificateur. Elle contient un terme de déclenchement de négation ("sans") mais n'agit pas en tant que modificateur.

En conclusion, le système ConText repose sur trois catégories d'indicateurs lexicaux :

- **Les modificateurs** qui déclenchent une autre valeur contextuelle que celle par défaut ;
- **Les pseudo-modificateurs** qui contiennent des modificateurs mais ne modifient pas le contexte ;
- **Les termes de terminaisons** qui mettent fin à la portée des modificateurs.

### 2.2 Compilation des indicateurs lexicaux

Notre liste a été obtenue à travers une traduction automatique, une validation manuelle et enfin un enrichissement avec les listes françaises précédemment citées.

---

1. Les valeurs par défaut sont présentées en italique

### 2.2.1 Traduction automatique

Nous avons utilisé plusieurs services web de traduction automatique pour traduire tous les indicateurs (356 termes) de la version anglaise de ConText. D'abord, six traducteurs basés sur des dictionnaires ont été interrogés : Bab.la (<http://fr.bab.la/dictionnaire>), Sensagent (<http://dictionnaire.sensagent.leparisien.fr>), CNRS ISC (<http://dico.isc.cnrs.fr>), Colins (<https://www.collinsdictionary.com>), Linguee (<http://www.linguee.fr>) et Wordreference (<http://www.wordreference.com>). Nous avons conservé seulement les termes français retournés par au moins trois traducteurs. Des travaux antérieurs ont évalué ces six services pour la création d'un dictionnaire de sentiments, et ont prouvé qu'un vote majoritaire donne une traduction de bonne qualité (Abdaoui et al., 2016). Cependant, ces traducteurs basés sur des dictionnaires ne parviennent pas à gérer les termes composés (termes contenant plusieurs mots). Par conséquent, une deuxième liste d'indicateurs lexicaux a été compilée à l'aide de Google Translate (<https://translate.google.fr>). À la fin de cette étape, nous avons obtenu automatiquement une première liste de 809 indicateurs lexicaux français.

### 2.2.2 Validation manuelle

Toutes les traductions automatiques ont été vérifiées, corrigées et enrichies manuellement par un spécialiste bilingue de fouille de texte (parmi les auteurs). Une application Web dédiée a été implémentée pour vérifier (valider ou supprimer) chaque traduction automatique et ajouter de nouvelles traductions ou de nouvelles formes corrigées. La validation manuelle consistait également à ajouter différentes formes fléchies à partir des traductions automatiquement obtenues (féminin / masculin, singulier / pluriel). À la fin de cette étape, nous avons supprimé automatiquement les doublons et avons obtenu 574 indicateurs lexicaux français validés manuellement.

### 2.2.3 Enrichissement

Notre liste d'indicateurs lexicaux a été enrichie à l'aide des deux listes disponibles dans la littérature décrite précédemment (Deléger et Grouin, 2012; Garcelon et al., 2016). Tout d'abord, nous avons comparé automatiquement notre liste avec les deux précédentes pour éliminer les doublons. Ensuite, nous avons vérifié les termes qui n'étaient pas déjà présents dans notre liste. Ce processus nous a permis d'enrichir notre liste de nouveaux termes (par exemple : "élimine") et de nouvelles formes (comme l'apostrophe : "aucun signe d'"). Ainsi, notre liste finale contient 710 entrées (négation : 603, temporalité : 64, sujet : 43). Cette liste sera bientôt également mise à disposition de la communauté, ainsi que le code de French Context (<https://github.com/sifrproject>).

## 2.3 Intégration dans le SIFR Annotator

French ConText a été intégré dans le workflow du SIFR Annotator. Une fois que le texte de l'utilisateur a été annoté, le nouveau composant ConText divise le texte en plusieurs phrases en utilisant le point ".", puis applique French ConText à chaque annotation. Enfin, les caractéristiques contextuelles obtenues sont ajoutées à chaque annotation et renvoyées à l'utilisateur

dans le format demandé. La figure 1 montre l'interface utilisateur du SIFR Annotator et les résultats obtenus sur un exemple.

The screenshot displays the SIFR Annotator interface. At the top, there is a navigation bar with links: Browse, Search, Mappings, Recommender, Annotator, NCBO Annotator+, Projects, Landscape, Sign In, Help, About, Feedback. The main heading is 'Annotator'. Below it, a text box contains the sample text: 'Le patient n'a aucun signe de mélanome, bien que son père ait des antécédents de cancer de la peau.' To the right of the text box is the 'SIFR project' logo. Below the text box are three configuration panels: 'Ontology filters' (with 'MSHFRE' selected), 'Matching parameters' (with 'Match Longest Only' checked), and 'NegEx / ConText' (with 'Detect negation', 'Detect experienter', and 'Detect temporality' checked). There are also dropdowns for 'Include Ancestors Up To Level' and 'Include Score', both set to 'None'. A 'Get Annotations' button is present. Below the configuration is an 'Annotations' table with 10 columns: CLASS, filter, ONTOLOGY, filter, RSTYPE, filter, UMLS SEM TYPE, CONTEXT, MATCHED CLASS, filter, MATCHED ONTOLOGY, filter, NEGATION, EXPERIENCER, and TEMPORALITY. Two rows of results are shown, corresponding to 'Mélanome' and 'Tumeurs cutanées'.

CLASS	filter	ONTOLOGY	filter	RSTYPE	filter	UMLS SEM TYPE	CONTEXT	MATCHED CLASS	filter	MATCHED ONTOLOGY	filter	NEGATION	EXPERIENCER	TEMPORALITY
Mélanome		Medical Subject Headings, version française		direct			... signe de <b>mélanome</b> , bien que son ...	Mélanome		Medical Subject Headings, version française		NEGATED	PATIENT	RECENT
Tumeurs cutanées		Medical Subject Headings, version française		direct			... antécédents de <b>cancer de la peau</b> .	Tumeurs cutanées		Medical Subject Headings, version française		AFFIRMED	OTHER	HISTORICAL

FIG. 1 – Interface du SIFR Annotator intégrant les fonctionnalités de French ConText. Dans cet exemple, la terminologie utilisée est la version française de MeSH (MSHFRE) et les annotations sont filtrées selon le groupe sémantique «Maladies» (DISO) (McCray et al., 2001). Le paramètre "match longest only" est activé. Le lien suivant peut être utilisé pour reproduire cet exemple avec le service Web : <https://goo.gl/Tgx7gk>.

En plus de l'interface graphique, le SIFR Annotator peut être aussi appelé automatiquement à l'aide d'une API REST ([http://data.bioportal.lirmm.fr/documentation#nav\\_annotator](http://data.bioportal.lirmm.fr/documentation#nav_annotator)) et peut être intégré dans des workflow d'annotation. En outre, comme l'accès aux données cliniques est le plus souvent restreint, nous avons conçu une implémentation de l'ensemble du système basée sur Docker (<https://github.com/sifrproject/docker-compose-bioportal>) qui peut être facilement déployée localement. Enfin, le SIFR BioPortal offre également la possibilité d'interroger, pour du texte anglais, le NCBO Annotator à l'aide d'un proxy appelé NCBO Annotator+ (<http://bioportal.lirmm.fr/>

nco\_annotatorplus). En effet, nous avons intégré la version anglaise de ConText afin de traiter les textes en anglais.

## 2.4 Évaluation

Afin d'évaluer French ConText, nous avons annoté manuellement des phrases issues de deux types de documents médicaux :

- **Des dossiers patient électroniques** issus de l'Hopital Européen Georges Pompidou (HEGP) et décrivant l'état médical des patients ;
- **Des certificats de décès** extrait du corpus CépiDC mis à la disposition des participants à la tâche 1 de la campagne d'évaluation CLEF eHealth 2017 (Névéol et al., 2017).

Pour chaque type de texte, nous avons créé semi-automatiquement trois jeux de données tests correspondant aux trois contextes (négation, temporalité et sujet). Chaque ensemble a été compilé selon la méthode suivante : D'abord, nous avons sélectionné des phrases candidates contenant des modificateurs, ainsi que le même nombre de phrases ne contenant aucun modificateur. Ce processus nous permet d'améliorer les chances de trouver des conditions négatives, historiques et non liées aux patients dans les phrases candidates, tout en nous laissant la possibilité d'identifier de nouvelles formes qui ne sont pas incluses dans notre liste. Une méthode similaire a été utilisée pour évaluer l'adaptation suédoise de NegEX (Skeppstedt, 2011). Ensuite, nous avons utilisé le SIFR Annotator pour annoter les conditions médicales dans les phrases candidates. Nous avons limité l'annotation aux conditions appartenant au groupe sémantique UMLS "DISORDER" (McCray et al., 2001). Pour des raisons de simplicité, nous n'avons conservé qu'une seule condition par phrase et supprimé les phrases sans condition annotée. Enfin, nous avons décrit manuellement le contexte de chaque condition en utilisant l'outil BRAT (<http://brat.nlplab.org>). La plupart des phrases étaient faciles à contextualiser. Seules quelques-unes (une douzaine) ont nécessité une discussion ou l'aide d'un expert médical.

Nous avons effectué une évaluation bi-classes pour chaque contexte (affirmé / nié, récent / historique, patient / autre) tel que cela a été fait lors des évaluations précédentes des systèmes basés sur NegEx/ConText (Skeppstedt, 2011; Deléger et Grouin, 2012). Le tableau 1 présente le nombre de phrases annotées manuellement pour chaque type de texte et pour chaque contexte.

## 3 Résultats

Dans cette section, nous présentons les résultats obtenus par French ConText sur les phrases annotées présentées ci-dessus en termes de précision, rappel et F1 (ou F-mesure).

### 3.1 Négation

L'évaluation bi-classes de la négation considère seulement deux valeurs : nié et affirmé. Le tableau 2 présente les résultats obtenus par French ConText et en comparaison aux résultats de l'adaptation précédente de NegEx au français (Deléger et Grouin, 2012) sur les mêmes phrases. En effet, en utilisant la liste des termes de de Deléger et al., nous avons pu comparer exactement nos performances. Notre système obtient de meilleurs F1 sur les deux types de textes cliniques.

TAB. 1 – Répartition des phrases annotées manuellement.

		Nié	Affirmé	Total
<b>Négation</b>	Dossiers patient	145	855	1000
	Certificats de décès	41	989	1030
		Historique	Récent	Total
<b>Temporalité</b>	Dossiers patient	85	215	300
	Certificats de décès	63	87	150
		Other	Patient	Total
<b>Sujet</b>	Dossiers patient	135	165	300
	Certificats de décès	10	50	60

Principalement, notre système obtient un meilleur rappel pour la prédiction de la classe niée, ce qui signifie qu'il permet de trouver plus de conditions niées. Cette observation s'explique bien évidemment par la liste élargie d'indicateurs lexicaux que nous avons compilée. En outre, nos résultats montrent des performances légèrement meilleures que les versions anglaise et suédoise de ConText. En effet, ces deux versions ont obtenu entre 0,80 et 0,82 de F1 pour la classe niée (Skeppstedt, 2011).

TAB. 2 – Résultats de l'évaluation comparative entre l'adaptation de NegEx en français (De-léger et Grouin, 2012) et notre système French ConText sur deux types de textes cliniques.

			Précision	Rappel	F1
<b>Dossiers patient</b>	Ancienne adaptation de NegEx	Nié	0,989	0,648	0,783
		Affirmé	0,901	0,999	0,947
	French ConText	Nié	0,904	0,799	<b>0,837</b>
		Affirmé	0,963	0,986	0,975
<b>Certificats de décès</b>	Ancienne adaptation de NegEx	Nié	1	0,659	0,794
		Affirmé	0,986	1	0,993
	French ConText	Nié	0,970	0,780	<b>0,865</b>
		Affirmé	0,991	0,998	0,994

### 3.2 Temporalité

Le tableau 3 présente les résultats obtenus par French ConText sur les phrases annotées pour la temporalité. Approximativement 0,90 de F1 est un très bon résultat pour une première mise en œuvre pour le français. En effet, l'algorithme original anglais de ConText a obtenu environ 0,76 de F1 pour la prédiction de la temporalité (Harkema et al., 2009).



TAB. 3 – Résultats de la détection de la temporalité sur les deux types de textes cliniques.

		<b>Précision</b>	<b>Rappel</b>	<b>F1</b>
<b>Dossiers patient</b>	Historique	0,928	0,906	<b>0,917</b>
	Récent	0,963	0,972	0,968
<b>Certificats de décès</b>	Historique	0,833	0,952	<b>0,889</b>
	Récent	0,962	0,862	0,909

### 3.3 Sujet

Le tableau 4 présente les résultats obtenus par French ConText sur les phrases annotées pour le sujet. Les F1 rapportées (0,909 et 0,792) sont de bons résultats pour une première implémentation pour le français. L'algorithme original anglais ConText a obtenu un score F1 de 1 pour la prédiction de classe "autre", mais en utilisant un ensemble de tests qui contient seulement cinq conditions qui ne concerne pas le patient (Harkema et al., 2009). Dans notre cas, nous en avons identifié 360.

TAB. 4 – Résultats d'évaluation de la détection du sujet sur les deux types de textes cliniques.

		<b>Précision</b>	<b>Rappel</b>	<b>F1</b>
<b>Dossiers patient</b>	Autre	0,861	0,733	<b>0,792</b>
	Patient	0,805	0,903	0,851
<b>Certificats de décès</b>	Autre	0,833	1	<b>0,909</b>
	Patient	1	0,960	0,980

## 4 Conclusion

Dans cet article, nous avons présenté une adaptation et un enrichissement de ConText à la langue française. Le système proposé permet de détecter la négation, la temporalité et le sujet de conditions cliniques pré-annotées. Le système a été évalué sur deux types de textes cliniques et a obtenu des résultats comparables aux versions anglaise et suédoise de ConText. Lorsqu'il est comparé sur les mêmes ensembles de données, French ConText obtient de meilleurs résultats que l'ancienne adaptation de NegEx à la langue française (Deléger et Grouin, 2012). En outre, French ConText a été intégré dans le SIFR Annotator afin de le rendre facilement accessible à la communauté scientifique biomédicale. Ce service peut être consulté manuellement à l'aide d'une interface Web et automatiquement en utilisant une API REST. En outre, il peut être déployé localement afin de traiter les données sensibles. Notre implémentation a également été généralisée à l'anglais pour les annotations produites par le NCBO Annotator. Les nouvelles fonctionnalités apportées par ConText améliorent fortement les services d'annotation d'origine, en particulier pour annoter des données cliniques.

## Remerciements

Ce travail est réalisé au sein des projets SIFR (<http://www.lirmm.fr/sifr/>) et PractiKPharma (<http://praktikpharma.loria.fr>) financés en partie par l'Agence Nationale de la Recherche (ANR-12-JS02-01001 et ANR-15-CE23-0028), ainsi que par le programme Européen H2020 Marie Skłodowska-Curie action (No 701771), l'Université de Montpellier et le CNRS. Nous remercions également le US National Center for Biomedical Ontology (NCBO) pour leur assistance avec le NCBO Annotator, le CépiDC et les organisateurs de CLEF eHealth 2017 pour leur autorisation d'utiliser le corpus, et l'HEGP pour leur aide avec l'accès aux dossiers patient. Finalement, nous remercions le BLULab (University of Utah) pour leur information et le code de NegEx/Context et Louise Délégé pour la liste de termes français.

## Références

- Abdaoui, A., J. Azé, S. Bringay, et P. Poncelet (2016). FEEL : a french expanded emotion lexicon. *Language Resources and Evaluation*, 1–23.
- Chapman, W. W., W. Bridewell, P. Hanbury, G. F. Cooper, et B. G. Buchanan (2001). A simple algorithm for identifying negated findings and diseases in discharge summaries. *Journal of biomedical informatics* 34(5), 301–310.
- Chapman, W. W., D. Hilert, S. Velupillai, M. Kvist, M. Skeppstedt, B. E. Chapman, M. Conway, M. Tharp, D. L. Mowery, et L. Deleger (2013). Extending the NegEx lexicon for multiple languages. *Studies in health technology and informatics* 192, 677–681.
- Délégé, L. et C. Grouin (2012). Detecting negation of medical problems in french clinical notes. In *Proceedings of the 2nd ACM SIGHIT International Health Informatics Symposium*, pp. 697–702. ACM.
- Elkin, P. L., S. H. Brown, B. A. Bauer, C. S. Husser, W. Carruth, L. R. Bergstrom, et D. L. Wahner-Roedler (2005). A controlled trial of automated classification of negation from clinical notes. *BMC medical informatics and decision making* 5(1), 13.
- Garcelon, N., A. Neuraz, V. Benoit, R. Salomon, et A. Burgun (2016). Improving a full-text search engine : the importance of negation detection and family history context to identify cases in a biomedical data warehouse. *Journal of the American Medical Informatics Association* 24(3), 607–613.
- Goryachev, S., M. Sordo, Q. T. Zeng, et L. Ngo (2006). Implementation and evaluation of four different methods of negation detection. In *Decision Systems Group*.
- Harkema, H., J. N. Dowling, T. Thornblade, et W. W. Chapman (2009). ConText : an algorithm for determining negation, experiencer, and temporal status from clinical reports. *Journal of biomedical informatics* 42(5), 839–851.
- Huang, Y. et H. J. Lowe (2007). A novel hybrid approach to automated negation detection in clinical radiology reports. *Journal of the American Medical Informatics Association* 14(3), 304–311.
- Jonquet, C., A. Annane, K. Bouarech, V. Emonet, et S. Melzi (2016). SIFR BioPortal : Un portail ouvert et générique d'ontologies et de terminologies biomédicales françaises au ser-

- vice de l'annotation sémantique. In *16th Journées Francophones d'Informatique Médicale, JFIM'16*, pp. 16.
- Jonquet, C., N. H. Shah, et M. A. Musen (2009). The open biomedical annotator. *Summit on translational bioinformatics 2009*, 56–60.
- McCray, A. T., A. Burgun, et O. Bodenreider (2001). Aggregating UMLS semantic types for reducing conceptual complexity. *Studies in health technology and informatics* 84(0), 216–220.
- Morante, R. et W. Daelemans (2009). A metalearning approach to processing the scope of negation. In *Proceedings of the Thirteenth Conference on Computational Natural Language Learning*, pp. 21–29. Association for Computational Linguistics.
- Noy, N. F., N. H. Shah, P. L. Whetzel, B. Dai, M. Dorf, N. B. Griffith, C. Jonquet, D. L. Rubin, M.-A. Storey, C. G. Chute, et M. A. Musen (2009-05). BioPortal : ontologies and integrated data resources at the click of a mouse. *Nucleic Acids Research* 37, 170–173.
- Névéol, A., R. N. Anderson, K. B. Cohen, C. Grouin, T. Lavergne, G. Rey, A. Robert, C. Rondet, et P. Zweigenbaum (2017). CLEF eHealth 2017 multilingual information extraction task overview : ICD10 coding of death certificates in english and french. In *CLEF 2017 Evaluation Labs and Workshop : Online Working Notes, CEUR-WS*, pp. 17.
- Rokach, L., R. Romano, et O. Maimon (2008). Negation recognition in medical narrative reports. *Information Retrieval* 11(6), 499–538.
- Skeppstedt, M. (2011). Negation detection in swedish clinical text : An adaption of NegEx to swedish. *Journal of Biomedical Semantics* 2(3), S3.
- Tchechmedjiev, A., A. Abdaoui, V. Emonet, et C. Jonquet (2017-09). ICD10 coding of death certificates with the NCBO and SIFR annotator(s) at CLEF eHealth 2017 task 1. In *Working Notes of CLEF eHealth Evaluation Lab*, Volume 1866 of *CEUR Workshop Proceedings*, pp. 16.
- Velupillai, S., M. Skeppstedt, M. Kvist, D. Mowery, B. E. Chapman, H. Dalianis, et W. W. Chapman (2014). Cue-based assertion classification for swedish clinical text—developing a lexicon for pyConTextSwe. *Artificial intelligence in medicine* 61(3), 137–144.

## Summary

Detecting the context of clinical conditions present in a patient record is an important feature to consider when automatically processing medical texts. This paper describes the French adaptation of the English ConText system which allows to detect whether a clinical condition identified in a text is affirmed or negated, recent or historical, and concerns the patient or not. We evaluated our system on two types of medical texts: patient records and death certificates. The results obtained are comparable to the English and Swedish versions of ConText and exceed those obtained in French (negation only) when using the same reference data set. In addition, the French ConText system was integrated into the SIFR Annotator (<http://biportal.lirmm.fr/annotator>), a web service for semantic annotation of biomedical data for French.