Extraction automatique d'affixes pour la reconnaissance d'entités nommées chimiques

Yoann Dupont, Isabelle Tellier, Christian Lautier, Marco Dinarelli

Extraction automatique d'affixes pour la reconnaissance d'entités nommées chimiques

Yoann Dupont[1,2], Isabelle Tellier[1], Christian Lautier[2], and Marco Dinarelli[1]

[1]Laboratoire Lattice, UMR 8094, 1 rue Maurice Arnoux, 92120 Montrouge

[2]Temis SA, 207 rue de Bercy, 75012 Paris

I. Résumé

Nous détaillons ici une approche permettant de détecter des affixes à partir de dictionnaires en se basant sur l'algorithme de la plus longue sous-chaîne commune, dans le cadre de la reconnaissance d'entités nommées chimiques sur CHEMDNER (Krallinger et al., 2015). Nous verrons ensuite des méthodes de sélection et de tri pour choisir les plus pertinents.

II. Corpus CHEMDNER

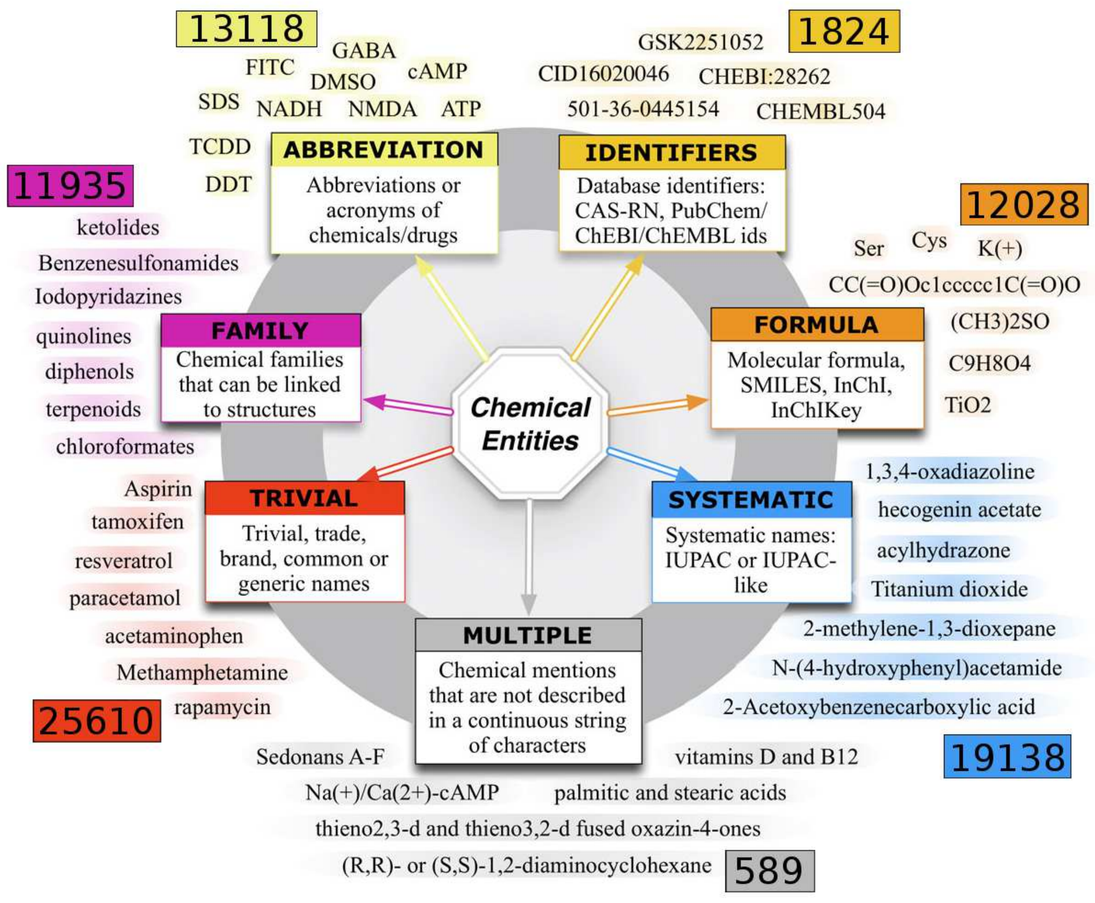

Figure 1: Les entités du corpus CHEMDNER ainsi que leurs comptes

III. Annotation de séquences avec des CRF

étiquette	B-TRIVIAL	I-TRIVIAL	O	O	O	B-FORMULA	B-FAMILY	O	[...]
tokens	Glaucogenin	E	,	a	new	C21	steroid	from	[...]
préfixe |3|	Gla	#	#	#	new	C21	ste	fro	[...]
suffixe |3|	nin	#	#	#	new	C21	oid	rom	[...]

Figure 2: CRF → système à base de traits pondérés pour retrouver la séquence "étiquette"

f(B-TRIVIAL | mot=Glaucogenin) = $poids_1$	f(I-TRIVIAL | mot=Glaucogenin) = $poids_2$
f(B-FAMILY | préfixe |3|=ste) = $poids_x$	f(I-FAMILY | préfixe |3|=ste) = $poids_{x+1}$

$$etiquette(traits) = \underset{E \in Etiquettes}{\operatorname{argmax}} \sum_{t \in traits} f(E|t)$$

Figure 3: vision simplifiée du fonctionnement d'un CRF

IV. Extraction d'affixes

		m	e	n	t	h	o	n	e
		0	0	0	0	0	0	0	0
r		0	0	0	0	0	0	0	0
o		0	0	0	0	0	0	1	0
t		0	0	0	0	1	0	0	0
e		0	0	1	0	0	0	0	0
n		0	0	0	2	0	0	0	1
o		0	0	0	0	0	0	1	0
n		0	0	0	1	0	0	0	2
e		0	0	1	0	0	0	0	0

Table 1: matrice de calcul de sous-séquences

préfixes	infixes	suffixes
∅	{e,o,n,t,en}	{one}

Table 2: affixes extraits

- liste d'affixes candidats
- liste bruitée : besoin d'élaguer !

V. Sélection et tri des affixes

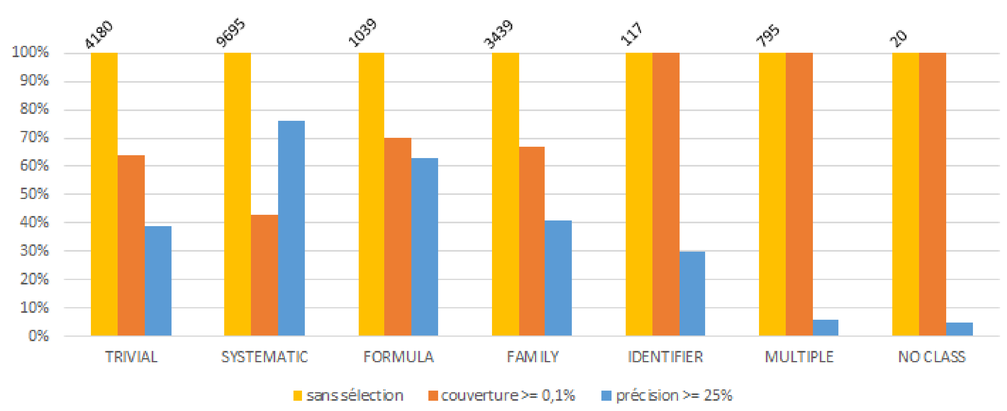

Figure 4: Réduction du volume des affixes selon le score calculé sur le corpus d'entraînement

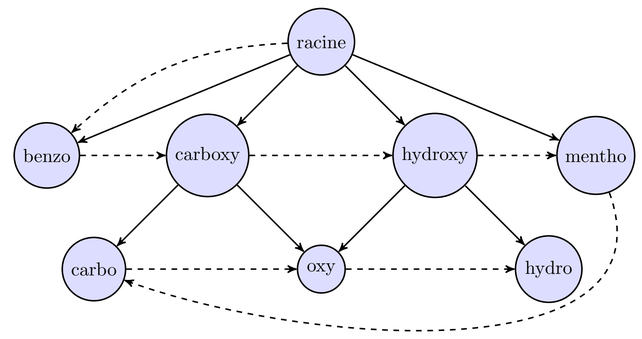

Figure 5: Le treillis des affixes. Représente la relation "X est une sous-chaîne stricte de Y". Les affixes sont sélectionnés selon une recherche en largeur (pointillets)

VI. Résultats

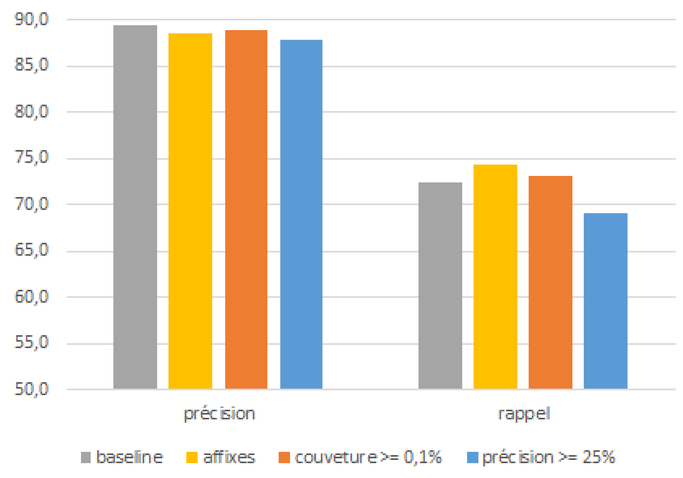

- baseline :
  - préfixes taille < 6
  - suffixes taille < 6
- autres :
  - le plus long préfixe
  - le plus long suffixe
  - 5 infixes

VII. Conclusions et perpectives

- approche pour trouver automatiquement des affixes
- entités extraites du corpus d'entraînement → utiliser PubChem (Wang et al., 2009)
- sélection : probabilité conditionelle entre deux affixes apparentés (Zhang and Lee, 2006)
- intégrer affixes dans des méthodes vectorielles (SVM, RN)
- appliquer la méthode pour trouver automatiquement des termes déclencheurs

IUT	de	Reims	Châlon	Charleville
IUT	de		de	Troyes
Université	de	technologies	de	Troyes
Université	d'	Angers		

Références

Krallinger, M., O. Rabal, F. Leitner, M. Vazquez, D. Salgado, Z. Lu, R. Leaman, Y. Lu, D. Ji, D. M. Lowe, et al. (2015). **The CHEMDNER corpus of chemicals and drugs and its annotation principles**. *Journal of cheminformatics 7*(Suppl 1), S2.

Wang, Y., J. Xiao, T. O. Suzek, J. Zhang, J. Wang, and S. H. Bryant (2009). **PubChem: a public information system for analyzing bioactivities of small molecules**. *Nucleic acids research 37*(suppl 2), W623–W633.

Zhang, D. and W. S. Lee (2006). **Extracting Key-substring-group Features for Text Classification**. In *Proceedings of the 12th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '06, New York, NY, USA, pp. 474–483. ACM.