QuickNorm, une méthode rapide et peu coûteuse pour la normalisation d'entité

Arnaud Ferré, Louise Deleger

QUICKNORM, UNE MÉTHODE RAPIDE ET PEU COÛTEUSE POUR LA NORMALISATION D'ENTITÉ

Arnaud Ferré
Louise Deléger
Université Paris-Saclay, INRAE, MaIAGE, Jouy-en-Josas, France

Introduction : De nombreuses informations d'intérêt sont disséminées dans la littérature des domaines de spécialité, en particulier dans les publications scientifiques. L'extraction d'information vise à extraire ces informations et à les structurer de façon à les rendre exploitables. Nous aborderons ici une des étapes de l'extraction d'information : la tâche de normalisation d'entité.

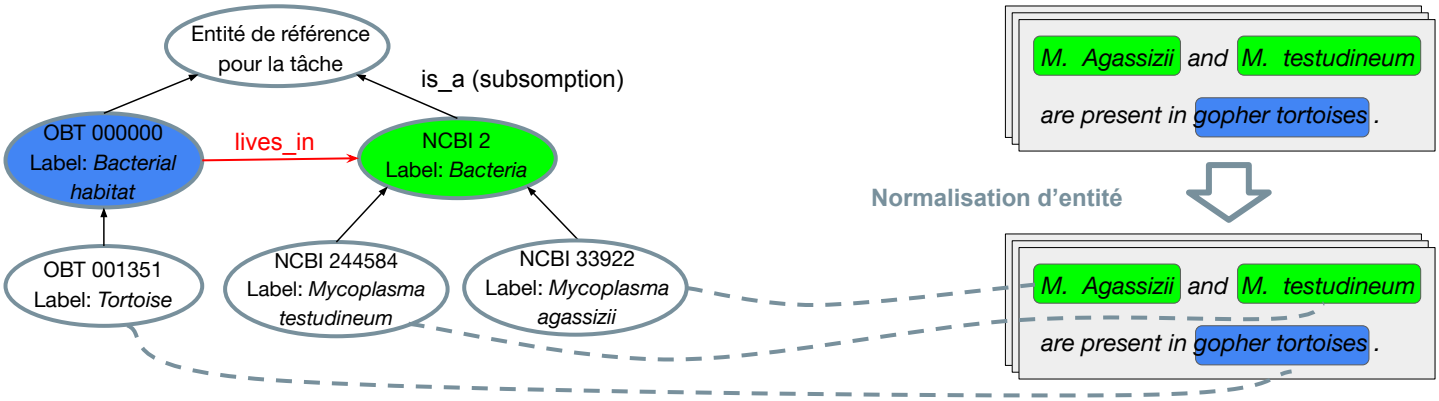

Etat de l'art :

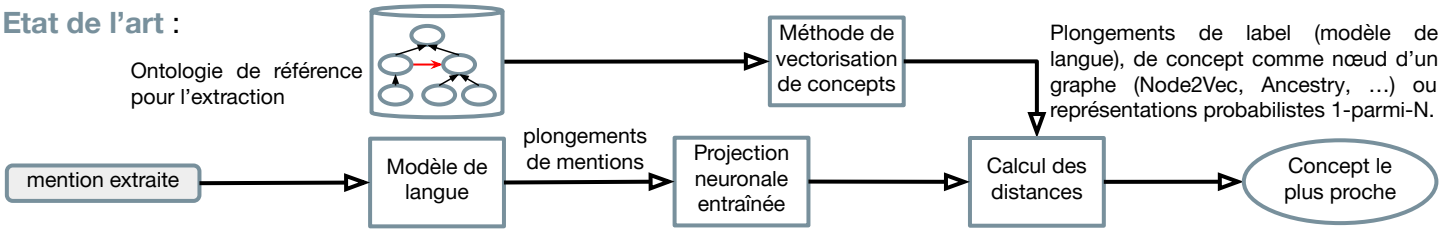

Problématique : Les performances n'ont pas arrêté de croître, proportionnellement au nombre de paramètres à entraîner et donc aux besoins en puissance et en temps de calcul. Cela pose de plus en plus de problèmes en termes d'accessibilité, de reproductibilité, ainsi qu'en termes écologiques.

Une méthode rapide et peu coûteuse :

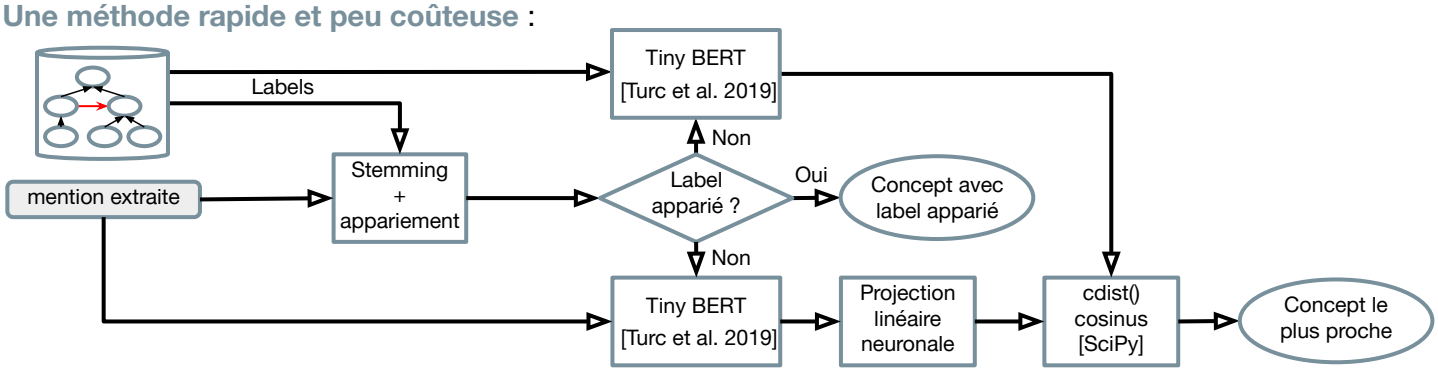

Résultats : La méthode a été évaluée sur un jeu de données standard d'évaluation, celui de Bacteria Biotope 4 [Bossy et al. 2019]. Comparée à des méthodes de l'état de l'art, la méthode réussit à ne pas être trop consommatrice de RAM et à s'exécuter (chargement des données, entraînement et prédiction) au moins 10 fois plus rapidement sur CPU que les méthodes état de l'art performantes sur GPU.

	Tiny BERT	BERT	PubMed BERT
Taille vecteur	128	768	768
Volume (Mb)	15,97	389,71	386,20
Jeu de données	Wikipedia and BooksCorpus	Wikipedia and BooksCorpus	MEDLINE/ PubMed

	Tiny BERT	BERT	PubMed BERT
Accuracy	48,93	50,96	51,44
Ecart-type	0,59	0,54	0,29
Temps (sec.)	82	1352	1339

(calcul de la variabilité sur 5 exécutions, CPU d'ordinateur portable de 32 Go de RAM)

Références :
- Bossy et al. 2019. Bacteria biotope at BioNLP open shared tasks 2019. BioNLP open shared tasks workshop.
- Turc et al., 2019. Well-read students learn better: On the importance of pre-training compact models. arXiv:1908.08962.
- SciPy: https://docs.scipy.org/doc/scipy/reference/generated/scipy.spatial.distance.cdist.html