

Intégration du contexte spatio-temporel et social pour l'analyse de sentiments sur Twitter

Ophélie Fraïsier

► **To cite this version:**

Ophélie Fraïsier. Intégration du contexte spatio-temporel et social pour l'analyse de sentiments sur Twitter. 8eme Forum Jeunes Chercheurs du congrès INformatique des Organisations et Systemes d'Information et de Decision (INFORSID 2016), May 2016, Grenoble, France. pp. 1-4. hal-01475015

HAL Id: hal-01475015

<https://hal.archives-ouvertes.fr/hal-01475015>

Submitted on 23 Feb 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.



Open Archive TOULOUSE Archive Ouverte (OATAO)

OATAO is an open access repository that collects the work of Toulouse researchers and makes it freely available over the web where possible.

This is an author-deposited version published in : <http://oatao.univ-toulouse.fr/>
Eprints ID : 17152

The contribution was presented at INFORSID 2016 :
http://inforsid.fr/Grenoble2016/wp-content/uploads/2016/06/INFORSID_2016/forumJC.html

To cite this version : Fraasier, Ophélie *Intégration du contexte spatio-temporel et social pour l'analyse de sentiments sur Twitter*. (2016) In: 8eme Forum Jeunes Chercheurs du congrès INFormatique des Organisations et Systèmes d'Information et de Decision (INFORSID 2016), 31 May 2016 (Grenoble, France).

Any correspondence concerning this service should be sent to the repository administrator: staff-oatao@listes-diff.inp-toulouse.fr

Intégration du contexte spatio-temporel et social pour l'analyse de sentiments sur Twitter

Ophélie Fraiser

*IRIT, 118 route de Narbonne, 31062 Toulouse, France
CEA Tech Midi-Pyrénées, 135 avenue de Rangueil, F-31400 France*

Ophelie.Fraiser@irit.fr

MOTS-CLÉS : Analyse de sentiments, Analyse de médias sociaux, Synthèse d'information

KEYWORDS: Sentiment analysis, Social media analysis, Information synthesis

ENCADREMENT: IRIT : Mohand Boughanem, Guillaume Cabanac et Yoann Pitarch ; CEA : Romaric Besançon

1. Contexte

L'analyse de sentiments est un domaine attirant beaucoup d'attention depuis quelques années. Ceci est notamment dû au fait que l'explosion des médias sociaux a permis à n'importe quelle personne disposant d'un accès au net de s'exprimer publiquement. Le domaine bénéficiant d'un transfert très rapide vers le monde industriel, de nombreuses entreprises sont apparues sur le marché (Viralheat, Brand24, Linkfluence, ...).

Les sentiments sont des « états privés », car ils ne sont pas observables et vérifiables de manière objective. De nombreuses méthodes ont néanmoins été développées pour détecter et catégoriser ces états privés à partir de textes, en utilisant des techniques de traitement automatique des langues, des lexiques spécialisés et des méthodes d'apprentissage automatique (Liu, 2012). Les données analysées sont souvent issues de microblogs, dont la plateforme la plus connue et la plus utilisée est Twitter. Les messages qui y sont publiés s'appellent des tweets et sont limités à 140 caractères.

Les sentiments d'une personne peuvent évoluer dans le temps et être influencés par de nombreux facteurs. Ma thèse porte donc sur la problématique de détection de

sentiments à partir de tweets, tout en considérant des éléments contextuels tels que la localisation de l'auteur-e, l'horodatage des messages ou les relations sociales qu'il entretient avec les autres membres du réseau.

2. État de l'art

La recherche d'information est un domaine ayant toujours accordé une grande importance à l'évaluation des modèles développés. De nombreuses campagnes d'évaluation permettent de comparer son système de classification de sentiments à celui d'autres équipes de recherche sur des jeux de données communs. Parmi les campagnes d'évaluation internationales, les plus importantes sont SemEval et TREC (Ounis et al., 2006). Il existe également des campagnes francophones, telles que DEFT (Hamon et al., 2015).

Les approches de classification rencontrées dans ces campagnes peuvent se diviser en trois grandes familles : les approches lexicales basées sur des lexiques tels que SentiWordNet (Feldman, 2013), celles à base d'apprentissage utilisant des corpus annotés (Xia et al., 2011) et les approches distributionnelles définissant le sens d'un mot par rapport à son contexte (Írsoy & Cardie, 2014).

Certains travaux ont tentés d'enrichir leur analyse en mettant en relation les sentiments et le contexte dans lequel ceux-ci ont été émis. Allisio et al. (2013) ont notamment visualisé la répartition géographique des sentiments de leur corpus en les représentant sur une carte de l'Italie. Celli et Rossi (2012) ; Celli et Zaga (2013) ont pour leur part étudié l'influence de la personnalité de l'auteur-e sur ses sentiments et ses interactions avec les autres utilisateur-trice-s de Twitter. Pardo et Rosso (2013) ont eux mis en relation le sexe, les émotions et le style d'écriture de l'auteur-e.

Afin d'améliorer la prise en compte du contexte social d'un-e auteur-e, les liens d'abonnements entre utilisateur-trice-s – explicitement disponibles sur Twitter – peuvent être utilisés pour détecter des similarités. Shao et al. (2015) proposent notamment un algorithme se basant sur les distances entre nœuds du réseau pour étudier l'appartenance de l'auteur-e à une communauté.

3. Problématique

Les méthodes de classification présentées dans la section précédente se sont montrées efficaces mais ne prennent en compte que le contenu du tweet pour détecter le sentiment. Or, le sentiment éprouvé vis-à-vis de certains termes peut être intimement lié au point de vue de l'auteur-e (par exemple pour des termes tels que « capitalisme » ou « IVG »). L'hypothèse d'homophilie nous permet de considérer que les points de vue de personnes appartenant aux mêmes communautés sont similaires (Abbasi et al., 2014). Une analyse sociale – prenant en compte les relations de l'auteur-e, son âge, son sexe, le contexte spatio-temporel du message, etc. – pourrait donc apporter un éclairage nouveau sur certains messages. La problématique de ma thèse consiste

donc à assembler « analyse de sentiments » et « analyse sociale » afin de proposer un résumé multi-factoriel s'appuyant sur ces différentes composantes.

4. Actions réalisées

Afin de me familiariser avec les méthodes d'évaluation du domaine, j'ai réalisé un état de l'art des campagnes d'évaluation. Ceci a également permis de repérer quelles tâches pourraient être intéressantes, qu'il s'agisse de tâches actuelles auxquelles il serait possible de participer dans le futur ou de tâches passées pour lesquelles les jeux de données et les résultats sont disponibles (Fraisier, 2016). L'étape suivante a été de définir le front de recherche actuel afin de savoir où situer mon travail dans le domaine (voir section 2).

J'ai effectué une première expérimentation pour découvrir les algorithmes classiques, avec une approche à base d'apprentissage supervisé sur une tâche de classification automatique de tweets en opinions positives/négatives/neutres. Les données d'évaluation proviennent de la tâche 2 de la campagne SemEval 2013 et sont composées de 9655 tweets d'entraînement et de 3813 tweets de test. Les résultats sont présentés dans le tableau 1. On constate que le classifieur le plus efficace est le SVM à noyau sigmoïde avec un score F1 de 0,60 (le score du meilleur participant étant de 0,69).

Classifieur	Score F1	Classifieur	Score F1
SVM à noyau sigmoïde	0,60	Forêt aléatoire	0,55
SVM à noyau linéaire	0,59	Arbre de décision	0,55
Bayésien naïf multinomial	0,57		

Tableau 1. Résultats de mes expérimentations sur la classification des tweets de la tâche 2 de la campagne SemEval 2013

5. Actions futures

Par la suite, je vais utiliser mes premières expérimentations pour mettre en œuvre un modèle plus performant, en intégrant plus de caractéristiques. Les premiers éléments rajoutés seront des éléments propres au tweet (présence de ponctuation, d'émoticône, négation, etc.), avant d'introduire le contexte – et notamment la notion d'homophilie – dans le modèle. Après cela, je me servirai des résultats obtenus pour déterminer quelles caractéristiques conserver et comment les assembler formellement afin d'avoir un modèle pertinent. Je déterminerai également comment évaluer les différentes composantes de ce nouveau modèle. Afin de comparer notre modèle à d'autres, une participation à une campagne d'évaluation est fortement envisagée. Il pourrait s'agir de la tâche « Sentiment Analysis in Twitter » de SemEval ou la nouvelle tâche TREC combinant « Microblog » et « Temporal Summarization ».

Remerciements : Ce travail a été réalisé grâce à l'obtention d'un financement Contrat Laboratoire – Entreprise numéro 14050975 soutenu par la Région Languedoc – Roussillon Midi-Pyrénées.

Références

- Abbasi, M. A., Zafarani, R., Tang, J., & Liu, H. (2014). Am I more similar to my followers or followees ? : analyzing homophily effect in directed social networks. In *ACM-HT* (pp. 200–205). ACM. doi: 10.1145/2631775.2631828
- Allisio, L., Mussa, V., Bosco, C., Patti, V., & Ruffo, G. (2013). Felicità : Visualizing and Estimating Happiness in Italian Cities from Geotagged Tweets. In *ESSEM@AI*IA* (Vol. 1096, pp. 95–106). CEUR-WS.org.
- Celli, F., & Rossi, L. (2012). The Role of Emotional Stability in Twitter Conversations. In *Proc. Workshop on Semantic Analysis in Social Media* (pp. 10–17). ACL.
- Celli, F., & Zaga, C. (2013). Be Conscientious, Express your Sentiment ! In *ESSEM@AI*IA* (Vol. 1096, pp. 140–147). CEUR-WS.org.
- Feldman, R. (2013). Techniques and applications for sentiment analysis. *Communications of the ACM*, 56(4), 82. doi: 10.1145/2436256.2436274
- Fraisier, O. (2016, février). Information Retrieval – Evaluation Campaigns. (IRIT/RR-2016-04-FR). Consulté sur https://www.irit.fr/publis/IRIS/2016_R_F.pdf
- Hamon, T., Fraisse, A., Paroubek, P., Zweigenbaum, P., & Grouin, C. (2015). Analyse des émotions, sentiments et opinions exprimés dans les tweets : présentation et résultats de l'édition 2015 du défi fouille de texte (DEFT). In *Actes de deft*. Caen, France.
- Liu, B. (2012). Sentiment Analysis and Opinion Mining. *Synthesis Lectures on HLT*, 5(1), 1–167. doi: 10.2200/S00416ED1V01Y201204HLT016
- Ounis, I., de Rijke, M., Macdonald, C., Mishne, G., & Soboroff, I. (2006). Overview of the TREC-2006 Blog track. In *Text Retrieval Conference*. Consulté sur <http://trec.nist.gov/pubs/trec15/papers/BLOG06.OVERVIEW.pdf>
- Pardo, F. M. R., & Rosso, P. (2013). On the Identification of Emotions and Authors' Gender in Facebook Comments on the Basis of their Writing Style. In *ESSEM@AI*IA* (pp. 34–46).
- Shao, J., Han, Z., Yang, Q., & Zhou, T. (2015). Community Detection Based on Distance Dynamics. In *ACM-SIGKDD* (pp. 1075–1084). doi: 10.1145/2783258.2783301
- Xia, R., Zong, C., & Li, S. (2011). Ensemble of feature sets and classification algorithms for sentiment classification. *Information Sciences*, 181(6), 1138–1152. doi: 10.1016/j.ins.2010.11.023
- Írsoy, O., & Cardie, C. (2014). Opinion Mining with Deep Recurrent Neural Networks. In *EMNLP* (pp. 720–728).