

Une approche hybride pour la détection d'influenceurs dans les médias sociaux

Namrata Patel¹, Cédric Lopez¹, Ioannis Partalas¹, Frédérique Segond¹

VISEO TECHNOLOGIES, CENTRE R & D
4 av. Doyen Louis Weil, 38000, Grenoble, France
[nom] . [prenom]@viseo.com

Résumé : Un influenceur est une personne ayant les capacités d'imposer des attitudes, des comportements, des opinions à un public. La détection de tels individus est d'un grand intérêt, par exemple pour les campagnes commerciales qui cherchent à identifier les acteurs les plus influents pour promouvoir une marque ou un produit. Dans cet article, nous nous focalisons sur la détection d'influenceurs dans les réseaux sociaux qui s'appuie généralement sur une structure de graphe dont les nœuds sont les utilisateurs et les arcs orientés sont leurs interactions. Au-delà de la structure du graphe, nous expérimentons l'impact du contenu textuel des messages sur l'influence. En considérant des critères linguistiques hypothétiques (tels que l'argumentation d'un utilisateur, l'accord/désaccord entre utilisateurs) en plus des critères numériques classiques (nombre de réponses, taille du message, nombre de relations, etc.), nous montrons par le biais d'un système d'apprentissage que certains critères linguistiques sont pertinents pour la tâche de détection d'influenceurs.

Mots-clés : Détection d'influenceurs, traitement automatique du langage naturel, système d'apprentissage

1 Introduction

"Dans un contexte marketing et dans son sens le plus large, un influenceur est un individu qui par son statut, sa position ou son exposition médiatique peut influencer les comportements de consommation dans un univers donné." ¹ Un influenceur a les capacités d'imposer des attitudes, des comportements, des opinions à un public, ce qui en fait une source de communication pertinente pour les organismes désireux de promouvoir une marque, un produit, un service, ou une idée.

Depuis quelques années, poussé par les intérêts du marketing, des travaux cherchent à évaluer de façon automatique la force d'influence des individus impliqués dans les médias sociaux. La détection d'influenceurs s'appuie généralement sur une structure de graphe représentant les utilisateurs et leurs interactions pour calculer une mesure de centralité (Bonacich, 1987). Récemment, cette tâche s'est intéressée au contenu textuel généré par les utilisateurs en considérant des critères linguistiques (Kien-Weng Tan *et al.*, 2011) (Rosenthal, 2015).

Dans cet article, nous faisons l'hypothèse que les critères linguistiques (tels que l'argumentation d'un utilisateur, l'accord/désaccord entre utilisateurs) sont pertinents pour la tâche de détection d'influenceurs dans les médias sociaux. Pour ce faire, les informations sont extraites du contenu textuel par des règles linguistiques puis sont intégrées dans un système d'apprentissage automatique. Le système résultant est un système "doublement hybride" puisqu'il s'appuie sur des méthodes symboliques et statistiques d'une part, et sur la structure et le contenu textuel du réseau d'autre part.

L'article est organisé de la façon suivante : la section 2 fait un tour d'horizon sur la détection d'influenceurs dans les médias sociaux. La section suivante détaille l'architecture de notre

1. <http://www.definitions-marketing.com/definition/influenceur/>

système évalué à la section 4.

2 État de l'art

Dans la littérature, la tâche de détection d'influenceurs exploite :

- les interactions entre utilisateurs en se fondant sur la théorie des graphes. Étant donné un réseau social, l'influence est calculée en analysant les informations structurelles des interactions entre utilisateurs.
- le contenu textuel des messages publiés par les individus. Le texte est analysé en se fondant sur des indicateurs linguistiques.

Les études basées sur la théorie des graphes exploitent la pléthore de mesures disponibles dans la littérature pour analyser l'information structurelle du réseau d'interactions des utilisateurs. Pour la détection d'influence en particulier, les *mesures de centralité* sont utilisées afin d'identifier les nœuds les plus importants d'un réseau (Bonacich, 1987). Parmi ces mesures de centralité, une mesure indicative est la *centralité d'interférence*, qui exprime le nombre de fois qu'un nœud donné est dans le chemin le plus court entre deux nœuds quelconques dans le réseau. Dans la même famille, *PageRank* est l'une des mesures les plus connues pour le classement des nœuds (Page *et al.*, 1999). Par ailleurs, Kempe *et al.* (2003) utilisent des *modèles de propagation* dans le but de spécifier comment les actions (par exemple les *retweets* d'un message dans Twitter) se propagent à travers le réseau social et Reid & Ng (2000) montrent qu'il y a une forte corrélation entre les tours de conversation et l'influence.

Les études récentes fondées sur la prise en compte du contenu textuel cherchent à identifier les traits de comportement influents par le biais de marqueurs linguistiques présents dans les messages. Biran *et al.* (2012) et (Rosenthal, 2015) proposent plusieurs marqueurs tels que la persuasion, l'accord et le désaccord, la structure de dialogue et les sentiments, et proposent une approche d'apprentissage automatique pour détecter les influenceurs. D'autres travaux se focalisent sur les opinions véhiculées par les messages (Bigonha *et al.*, 2012). Cette lignée de travaux fournit des résultats prometteurs de par une analyse fine des comportements influents.

Enfin, il existe quelques rares travaux cherchant à combiner l'analyse structurelle et l'analyse du contenu. Par exemple, Weng *et al.* (2010) ajoutent un biais à la mesure de PageRank dans le calcul d'influence entre utilisateurs, en tenant compte du sujet abordé dans les messages; Katsimpras *et al.* (2015) proposent une approche supervisée afin de détecter des nœuds influents pour un sujet donné; le contenu du message n'est exploité ici que sous l'angle du sujet abordé.

Dans les travaux antérieurs, la détection d'influenceurs se fait par apprentissage automatique. Notre approche intègre un système à base de règles permettant l'analyse du contenu des messages selon plusieurs descripteurs que nous expérimentons.

3 Description de l'approche hybride

Notre approche se compose de quatre phases successives :

1. Constitution du jeu de données
2. Analyse linguistique
3. Génération d'un modèle d'apprentissage

4. Calcul de scores d'influence (par message et par auteur) et classement

Chacune de ces phases est décrite dans la suite.

3.1 Constitution des jeux de données

Notre jeu de données initial est constitué d'un ensemble de fils de discussions en anglais extraits d'un forum de cosmétique². Nous avons recueilli plus de 5000 fils de discussions et les avons divisé aléatoirement en trois parties : 1000 fils sont dédiés à l'analyse et au développement de règles linguistiques, 1000 fils sont dédiés à l'entraînement du modèle d'apprentissage, et 3000 fils sont réservés à l'évaluation de notre approche. Chacun des 18085 messages constituant les 1000 fils dédiés à l'entraînement du modèle d'apprentissage ont été annotés manuellement. Il s'agissait de décider de façon booléenne si un message a un pouvoir d'influence ou non, selon ses propres critères personnels.

3.2 Analyse linguistique

La phase d'identification des critères s'est appuyée sur les travaux cités dans la section précédente et sont présentés dans le tableau 1. Les critères sont catégorisés en tant que "linguistique" ou "non linguistique". Les critères non linguistiques sont calculés par des fonctions de comptage ou booléennes. Les critères linguistiques sont calculés à base de règles linguistiques.

Critère	Catégorie	Nature	Sortie (type)
isFirstPost?	non-linguistique	Position d'un message dans un fil	booléen
isSecondPost?	non-linguistique	Position d'un message dans un fil	booléen
isPenultimateost?	non-linguistique	Position d'un message dans un fil	booléen
isLatestPost?	non-linguistique	Position d'un message dans un fil	booléen
sizeOfMessage	non-linguistique	Information quantitative	$0 < x < n$
RegistrationDate	non-linguistique	Date	date
Location of the user	non-linguistique	Emplacement	string
Elongation	linguistique	Style d'écriture	booléen
Uppercase	linguistique	Style d'écriture	booléen
Exclamation	linguistique	Style d'écriture	booléen
Interrogation	linguistique	Style d'écriture	booléen
Nb of premises	linguistique	Argumentation	$0 < x < n$
conclusion?	linguistique	Argumentation	booléen
ArgumentInFirstSentence	linguistique	Argumentation	booléen
Advising	linguistique	Argumentation	$0 < x < n$
Advising	linguistique	Accord	booléen
Advising	linguistique	Désaccord	booléen

TABLE 1 – Description des caractéristiques extraites qui servent d'entrée pour le modèle d'apprentissage

A chaque critère linguistique est associé un module de règles que nous avons développé manuellement à partir du jeu de données dédié (3.1). Chaque règle s'appuie sur une analyse morphosyntaxique fournie par Holmes Semantic Solutions³.

Les textes sont ainsi automatiquement annotés selon ces critères qui serviront par la suite d'entrée pour le modèle d'apprentissage supervisé.

2. Nous en dissimulons le nom pour des raisons de confidentialité

3. <http://www.ho2s.com/fr/>

3.3 Génération d'un modèle d'apprentissage

Suite à l'extraction des valeurs de chaque critère, l'ensemble de messages annotés est représenté sous forme matricielle : chaque ligne représente un message et chaque colonne représente une caractéristique. La matrice est remplie en fonction des valeurs des critères extraits par message et sert comme telle d'entrée pour le modèle d'apprentissage supervisé. Nous avons choisi les *Forêts d'arbres décisionnels* qui sont robustes et très utilisés dans une variété d'applications

3.4 Calcul du score d'influence

Notre modèle génère un score d'influence par message, et représente la probabilité de répondre positivement à chaque critère. Ces scores d'influence sont ensuite agrégés afin de produire un score d'influence final par auteur de message. Cette agrégation se fait en exploitant l'information structurelle présente dans le réseau d'interactions des utilisateurs (auteurs).

Soit $U = \{u_1, u_2, \dots, u_n\}$ l'ensemble d'utilisateurs dans un réseau social et $S_u = \{s_1, s_2, \dots, s_{K_u}\}$ l'ensemble de scores par message d'un utilisateur donné u , où $K_u =$ nombre de messages postés par l'utilisateur. Le score final par utilisateur est alors défini par :

$$Inf(u) = \frac{\frac{1}{K_u} \sum_{i=1}^{K_u} s_i}{\max_{u'} \frac{1}{K_{u'}} \sum_{j=1}^{K_{u'}} s_j}$$

4 Evaluation

4.1 Expérimentation

Nous avons entraîné notre modèle de forêts d'arbres décisionnels en effectuant une recherche aléatoire couplée avec une validation croisée à 5-plis afin de régler ses paramètres : (1) nombre d'arbres $\in [50, 500]$, (2) profondeur $\in [2, 10]$ et (3) critère d'information $\in \{\text{entropie}, \text{gini}\}$. Nous avons entraîné deux versions du modèle, avec et sans critères linguistiques afin d'évaluer leur pertinence. Les deux modèles ont été optimisés pour ROC-AUC qui est une mesure de la probabilité qu'une instance positive soit plus haute dans le classement qu'une instance négative.

4.2 Résultats

La figure 1 représente les courbes ROC-AUC pour les deux modèles. On remarque qu'avec une tolérance de 30% de faux positifs, le système peut obtenir jusqu'à 82% de vrais positifs en considérant les caractéristiques linguistiques. Pour mieux évaluer la pertinence de ces caractéristiques, nous avons également calculé le classement de l'ensemble des caractéristiques par ordre d'importance pour le modèle (cf. Figure 2).

On remarque que la caractéristique la plus pertinente est la taille du message, qui reflète naturellement le fait que les messages longs contiennent plus d'instances de caractéristiques linguistiques que des messages courts. Ce qui est particulièrement remarquable est le classement des critères d'argumentation (plus précisément des prémisses) et d'élongation lexicale (par exemple "ce produit est suuuuuuper"). Ainsi, entre deux critères non linguistiques (numériques) traditionnellement utilisés dans la tâche de détection d'influenceurs, se positionnent les critères liés à l'argumentation et au conseil, ce qui dessine nos perspectives à court terme.




FIGURE 1 – Courbes ROC-AUC pour les deux modèles.

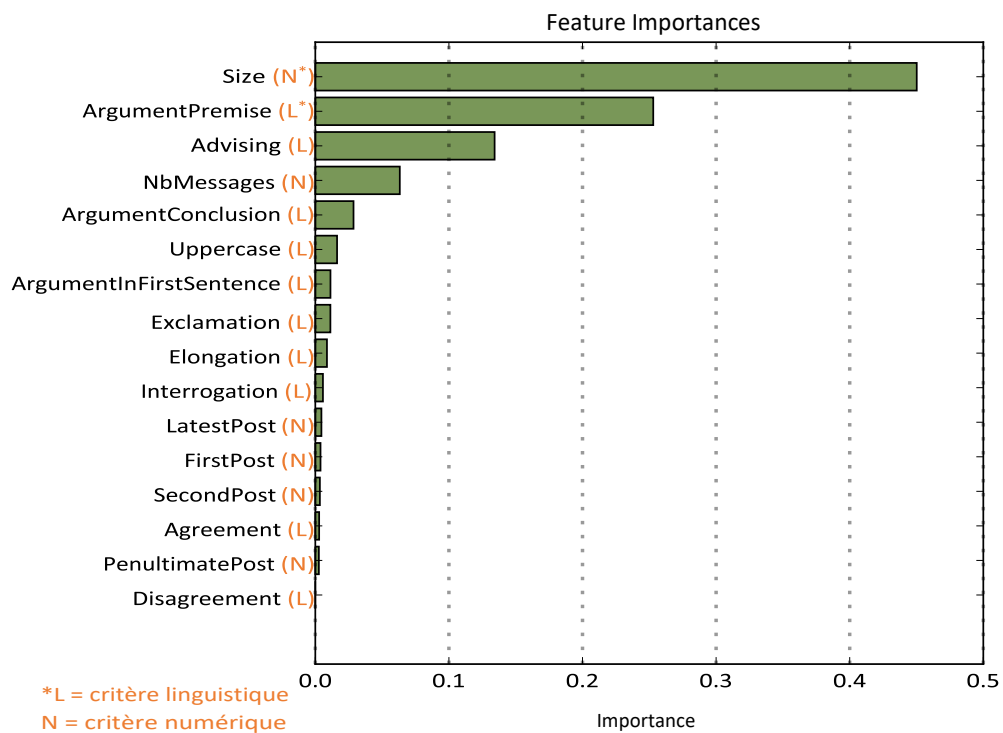


FIGURE 2 – Caractéristiques par ordre décroissant de pertinence pour le modèle.

5 Conclusion

Dans cet article, nous avons présenté une approche hybride pour la détection d'influenceurs qui s'appuie sur des méthodes symboliques et statistiques d'une part, et sur la structure et le contenu textuel des réseaux d'autre part. Ayant confronté des critères linguistiques (tels que l'argumentation d'un utilisateur, l'accord/désaccord entre utilisateurs) à des critères numériques classiques (nombre de réponses, taille du message, nombre de relations, etc.) vis à vis de la tâche de détection d'influenceurs, nos résultats confirment la pertinence des premiers dans la détection d'influence. Plus précisément, l'argumentation et la présence d'élongation apparaissent parmi les critères les plus pertinents.

Motivés par ces résultats, nous chercherons à améliorer nos modules linguistiques par une analyse structurelle du discours. Nous explorerons également une analyse basée sur la théorie des graphes afin de mieux exploiter l'information structurelle présente dans le réseau d'interactions des utilisateurs.

6 Remerciement

Ce travail de recherche est soutenu par la commission européenne Eurostars dans le cadre du projet SOMA (E9202).

Références

- BIGONHA C., CARDOSO T. N., MORO M. M., GONÇALVES M. A. & ALMEIDA V. A. (2012). Sentiment-based influence detection on twitter. *Journal of the Brazilian Computer Society*, **18**(3), 169–183.
- BIRAN O., ROSENTHAL S., ANDREAS J., MCKEOWN K. & RAMBOW O. (2012). Detecting influencers in written online conversations. In *Proceedings of the Second Workshop on Language in Social Media*, p. 37–45 : Association for Computational Linguistics.
- BONACICH P. (1987). Power and Centrality : A Family of Measures. *American Journal of Sociology*, **92**(5), 1170–1182.
- KATSIMPRAS G., VOGIATZIS D. & PALIOURAS G. (2015). Determining influential users with supervised random walks. In *Proceedings of the 24th International Conference on World Wide Web, WWW '15 Companion*, p. 787–792, New York, NY, USA : ACM.
- KEMPE D., KLEINBERG J. & TARDOS E. (2003). Maximizing the spread of influence through a social network. In *Proceedings of the Ninth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD '03*, p. 137–146 : ACM.
- KIEN-WENG TAN L., NA J.-C. & THENG Y.-L. (2011). Influence detection between blog posts through blog features, content analysis, and community identity. *Online Information Review*, **35**(3), 425–442.
- PAGE L., BRIN S., MOTWANI R. & WINOGRAD T. (1999). *The PageRank Citation Ranking : Bringing Order to the Web*. Technical Report 1999-66, Stanford InfoLab.
- REID S. A. & NG S. H. (2000). Conversation as a resource for influence : Evidence for prototypical arguments and social identification processes. *European Journal of Social Psychology*, **30**(1), 83–100.
- ROSENTHAL S. (2015). *Detecting Influencers in Social Media Discussions*. PhD thesis, Columbia University.
- WENG J., LIM E.-P., JIANG J. & HE Q. (2010). Twiterrank : Finding topic-sensitive influential twitterers. In *Proceedings of the Third ACM International Conference on Web Search and Data Mining, WSDM '10*, p. 261–270 : ACM.