
Détection de points de vue à l'aide des proximités inter-profils

Ophélie Fraisier^{1,2}, Guillaume Cabanac², Yoann Pitarch²,
Romaric Besançon³, Mohand Boughanem²

1. CEA-Tech en Occitanie
31 400 Toulouse
ophelie.fraisier@cea.fr
2. IRIT, Université de Toulouse, CNRS
31 062 Toulouse
{prenom}.{nom}@irit.fr
3. CEA, LIST
91 191 Gif-sur-Yvette
romaric.besancon@cea.fr

RÉSUMÉ. De nombreux domaines ont intérêt à étudier les points de vue exprimés en ligne, que ce soit le marketing, la cybersécurité, ou les humanités numériques. Nous proposons un modèle générique permettant de détecter ces points de vue en s'appuyant sur la proximité entre les profils utilisateurs, déterminée en fonction des éléments disponibles sur la plateforme étudiée. Nous utilisons un échantillon de profils annotés au départ, et des graphes modélisant la proximité des profils, afin de catégoriser le reste de la population. Ce modèle exploite les communautés, représentant des profils assez proches pour supposer qu'ils partagent une posture similaire. En utilisant plusieurs jeux de données, nous montrons qu'en combinant plusieurs types de proximités, nous obtenons des résultats très pertinents malgré la simplicité de la méthode.

ABSTRACT. Numerous domains have interests in studying the viewpoints expressed online, be it for marketing, cybersecurity, or computational social sciences. We propose a generic model to detect said viewpoints, relying on the proximity between user profiles, determined according to the information available online. We use a sample of seed profiles for whom we know the stance, and graphs modeling the proximity of the user profiles, to classify the rest of the population. This model exploits communities, which represent profiles close enough to assume they share a similar stance. Using several datasets, we show that by combining several types of proximity we can achieve excellent effectiveness despite the simplicity of the method.

MOTS-CLÉS : Détection de points de vue, Media sociaux, Expression politique, Humanités numériques

KEYWORDS: Stance detection, Social media, Political Expression, Computational Social Science

DOI:10.3166/HSP.1-12 © 2017 Lavoisier

1 Introduction

La détection de points de vue attire de plus en plus d'intérêt en raison de son large éventail d'applications. Il s'agit notamment d'un outil précieux pour les chercheurs en humanités numériques. Elle permet d'avoir une meilleure compréhension de certaines problématiques de recherche en étendant les observations à de grands corpus de données, qui étaient auparavant inexploitable.

La tâche que nous explorons ici est, en utilisant un petit échantillon de profils¹ avec un point de vue connu, de détecter les points de vue des autres profils, par exemple « Démocrate » ou « Républicain ». La plupart des travaux consacrés à cette tâche se concentrent sur une plateforme spécifique, ou reposent uniquement sur le texte. Le modèle que nous proposons ici est générique, et requiert peu de données annotées pour produire des résultats hautement pertinents.

Notre modèle s'appuie sur la notion de *proximités* entre profils, permettant de les regrouper en communautés. Ces proximités peuvent être basées sur diverses informations : éléments de langage, interactions sociales, emplacement géographique... Nous supposons que les profils appartenant à une même communauté partagent un point de vue similaire, plusieurs études ayant montré que les media sociaux étaient fortement polarisés concernant les sujets politiques. En s'appuyant sur cette hypothèse, notre modèle réussit à déduire le point de vue des profils à partir de quelques points de vue connus dans leurs communautés d'appartenance.

Les contributions de cet article sont :

- une confirmation de l'importance de l'influence communautaire sur le point de vue des profils utilisateurs sur les media sociaux.
- un modèle générique semi-supervisé de détection de points de vue, adaptable à n'importe quel medium à condition qu'il existe des éléments permettant de relier les profils, évalué sur quatre jeux de données différents.
- une comparaison de plusieurs proximités permettant de déterminer celles qui sont les plus utiles pour détecter le point de vue.

2 État de l'art

2.1 Polarisation des media sociaux

Plusieurs études ont montré que les media sociaux virtuels étaient fortement polarisés, en particulier sur les sujets politiques (McPherson *et al.*, 2001 ; Iyengar, Westwood, 2015). Elles ont révélé l'existence de « *chambres d'écho* » : la majorité des profils se contentent d'interagir avec les personnes partageant leur point de vue plutôt que de débattre avec leurs adversaires.

Plusieurs plateformes présentent ce phénomène. Adamic et Glance (2005) ont étudié les liens et les sujets de discussion de blogueurs politiques. Ils ont constaté que

1. Les contenus publiés sur les media sociaux peuvent être considérés comme un discours authentique, mais il est important de rappeler qu'il y a pas toujours de lien bijectif entre personnes et profils numériques. Dans cet article, nous faisons la distinction entre *utilisateur* et *profil*, l'un étant la personne gérant un compte sur une plateforme numérique, et l'autre une représentation virtuelle de cette personne sur la plateforme.

les blogs conservateurs et libéraux tendaient à faire plus fréquemment référence aux blogs de leur propre camp idéologique. Conover *et al.* (2011) ont montré que le réseau des retweets sur Twitter concernant les élections américaines était fortement polarisé entre les profils de gauche et de droite, alors que les gens interagissaient plus librement dans le réseau des mentions. Barberá *et al.* (2015) ont confirmé cette observation, tout en notant que cette observation était plus nuancée lorsque les sujets n'étaient pas politiques.

2.2 Détection de points de vue

Dans la littérature, le texte est souvent l'élément principal utilisé pour déterminer le point de vue, notamment sur les sites de débats et dans les essais argumentatifs (Hasan, Ng, 2013). Thonet *et al.* (2016) ont utilisé un *topic model* pour catégoriser des textes concernant le conflit israélo-palestinien selon leur tendance idéologique. D'autres études ont porté sur des plateformes n'étant pas conçues spécifiquement pour débattre. Plusieurs travaux ont exploité des modèles statistiques pour déterminer le point de vue de profils Twitter en fonction de leurs tweets (Boireau, 2014 ; Mohammad *et al.*, 2017). D'autres ont utilisé des réseaux de neurones pour déterminer la posture de profils interagissant sur des forums (Zhang *et al.*, 2017).

Enfin, de nombreux travaux s'appuient sur les interactions sociales entre profils, avec des objectifs variés. Certains ont pour but de détecter « l'inclinaison politique » des profils, et s'appuient pour cela sur les profils suivis ou les retweets (Barberá, 2015 ; Wong *et al.*, 2013). D'autres cherchent à exploiter les partages de publications pour diminuer l'effet des chambres d'écho, en présentant des profils promouvant des opinions divergentes afin d'offrir, pour le sujet donné, une vision objective – ou au moins une combinaison de différentes visions (Rajadesingan, Liu, 2014). Une autre utilisation est la prédiction de l'attitude des profils après un événement majeur, par exemple dans le cadre d'une attaque terroriste et des débats qui s'ensuivent (Magdy *et al.*, 2016).

3 Présentation du modèle de détection de points de vue

Nos hypothèses principales sont que certaines communautés tendent à rassembler des profils qui partagent le même point de vue, et que ces communautés peuvent être modélisées à l'aide d'éléments présents sur les média sociaux. Nous proposons donc le modèle suivant : tout d'abord, différents ensembles de communautés sont détectés à l'aide de différentes proximités liant les profils, et les proximités sont ordonnées. Un ensemble de profils-graine est ensuite sélectionné, puis une détection de point de vue itérative est effectuée à partir de ces profils-graine pour déterminer le point de vue de chaque profil. Les sections suivantes présentent ces quatre étapes en détail.

3.1 Initialisation

Soit $X = (x_1, \dots, x_n)$ la séquence des n proximités à utiliser, avec chaque *proximité* indiquant un type de similarité des profils (exemple : $X = (\text{retweet}, \text{mention}, \text{hashtag})$).

Les profils peuvent faire partie des profils cibles à catégoriser, T , ou faire partie du sous-ensemble des profils qui ont simplement interagi avec T .

Pour chaque proximité x_i dans X , un graphe G_{x_i} est construit pour modéliser les relations entre les profils. Chaque sommet est un profil et les arêtes représentent la proximité entre les profils. Elles sont pondérées et peuvent être dirigées, en fonction des informations disponibles et du besoin de l'utilisateur final. Un algorithme de détection de communautés² détecte ensuite sur chaque graphe un ensemble de m communautés, $C_{x_i} = (c_{x_i,1}, \dots, c_{x_i,m})$.

Plusieurs types de proximités peuvent être définis : proximité textuelle, proximité sociale, proximité géographique, ... Cette définition flexible permet un modèle générique, qui peut être utilisé sur toute plateforme sociale dotée d'éléments disponibles pour inférer des liens entre profils. Les proximités utilisées dans nos expériences sont présentées dans la section 5.

3.2 Ordonnement des proximités

La fonction d'ordonnement $(x_1, \dots, x_n) \mapsto (x_1^{ord}, \dots, x_n^{ord})$ permet d'obtenir la séquence ordonnée de proximités à utiliser lors de la suite de notre modèle, X^{ord} .

Fonction d'ordonnement manuel. Ce mode est utile si l'utilisateur possède déjà une expertise concernant le jeu de données, et lorsqu'il désire choisir lui-même l'ordre dans lequel les proximités doivent être employées.

Fonction d'ordonnement automatique. Le modèle peut également ordonner automatiquement les proximités selon une fonction définie par l'utilisateur. Pour des raisons de concision nous ne détaillons pas dans cet article cet aspect d'ordonnement automatique.

3.3 Sélection de la graine

Une limite importante et bien connue des modèles supervisés et semi-supervisés est l'annotation manuelle des données d'entraînement. Ici, la sélection de la graine dépend du coût global d'annotation s que l'utilisateur final souhaite investir : s est le nombre de profils à annoter manuellement. Notre modèle est efficace avec une très petite graine (c'est-à-dire de taille inférieure à 5 % du nombre de profils à catégoriser). Les *profils-graine* sont des profils contenus dans la graine, et les *communautés-graine* les communautés contenant des profils-graine.

Pour une graine S , avec $S \subset T$ et $|S| = s$, la sélection doit se conformer aux règles suivantes, conçues pour exploiter au mieux l'aspect communautaire :

1. Il y a au moins s_{com} communautés-graine, sélectionnées dans $C_{x_1^{ord}}$ par taille décroissante.
2. Le nombre de profils-graine dans chaque communauté-graine est proportionnel à la taille de cette dernière.
3. Chaque communauté-graine doit contenir au moins s_{min} profils-graine.
4. Les profils-graine sont ensuite sélectionnés dans chaque communauté-graine de manière aléatoire.

2. Construire un graphe dirigé ou non dirigé aura bien évidemment un impact sur le choix de l'algorithme. Peu d'algorithmes tiennent compte de l'orientation quoiqu'il en existe, tel Infomap (Rosvall *et al.*, 2009).

3.4 Assignment des points de vue

Le point de vue s_p d'un profil p est son point de vue public sur un sujet particulier, déterminé grâce aux éléments partagés ou à des ressources externes. Chaque jeu de données contient σ points de vue, avec $\sigma \geq 2$. Plusieurs communautés différentes peuvent partager le même point de vue.

La dernière étape de notre modèle est l'assignation d'un point de vue par communauté de façon itérative:

Pour chaque x_i^{ord} dans X^{ord} :

Pour chaque $c_{x_i^{ord},j}$ dans $C_{x_i^{ord}}$:

Pour chaque p dans $c_{x_i^{ord},j} \cap T$:

Si s_p est indéfini:

$$s_p = \text{maj}_s(c_{x_i^{ord},j})$$

avec $\text{maj}_s(c_{x_i^{ord},j})$ le point de vue majoritaire de la communauté $c_{x_i^{ord},j}$. Si une communauté ne recense aucun profil avec une posture connue, $\text{maj}_s(c_{x_i^{ord},j})$ est indéfini.

Notez que :

- Le point de vue d'un profil ne peut pas changer une fois qu'il a été assigné.
- Par conséquent, l'ordre dans lequel les proximités sont considérées est important. Il vaut mieux placer tôt les proximités étant les plus discriminantes. La précision des premières proximités est ainsi combinée avec le rappel des suivantes.

4 Jeux de données utilisés

Pour pouvoir inclure dans nos expérimentations des proximités sociales, les jeux de données construits uniquement autour de mots-clés ne sont pas adaptés car les profils présents interagissent rarement. Au lieu de cela, nous avons utilisé des jeux de données construits en récoltant les publications d'un ensemble fixé de profils (voir tableau 1³). Trois proviennent de *Twitter* et un de *CreateDebate*.

Tableau 1. Tailles des jeux de données

Jeu de données	Nombre de publications		Données annotées	
	Originales (<i>Date</i>)	Collectées	Point de vue	Profils
<i>RI</i>	1 369 120 (<i>2014</i>)	890 795	Oui	564
			Non	537
<i>EM</i>	170 136 (<i>2014</i>)	154 114	Démocrate	761
			Républicain	810
<i>EP</i>	3 958 096 (<i>2016</i>)	3 307 983	Démocrate	481
			Républicain	427
<i>CA</i>	3 051 (<i>2016</i>)	3 051	Pour un contrôle strict des armes à feu	312
			Contre un contrôle strict des armes à feu	489

3. Les différences entre les tailles des jeux de données d'origine et de ceux collectés sont dues aux publications et comptes supprimés depuis l'exploration initiale.

4.1 Référendum sur l'indépendance écossaise du 18 septembre 2014 (RI)

Brigadir *et al.* (2015) ont recueilli des tweets reflétant le débat autour de ce référendum. Les profils ont été considérés comme partisans du « Oui » ou du « Non » si les utilisateurs correspondant faisaient partie de la Commission électorale de ce référendum, ou indiquaient sans ambiguïté leur camp sur leurs profils.

4.2 Élections américaines de mi-mandat du 4 novembre 2014 (EM)

Ce jeu de données a également été collecté par Brigadir *et al.* (2015), qui ont utilisé pour l'annotation plusieurs sources recensant les profils Twitter de candidats et militants. Les profils sont « Démocrate » ou « Républicain » (les partis minoritaires ont été ignorés).

4.3 Élections présidentielles américaines du 8 novembre 2016 (EP)

Littman *et al.* (2016) ont initialement collecté ce jeu de données, contenant l'activité des profils Twitter des candidats et des comptes officiels des partis démocrate et républicain. Il contient également des tweets collectés à l'aide de mots-clés couvrant plusieurs événements clés de la campagne : les conventions des partis, les débats, et le jour des élections. Les profils annotés sont ceux des candidats et des comptes officiels, ainsi que les profils annotés du jeu de données EM qui étaient également présents dans ce jeu de données.⁴

4.4 Contrôle des armes à feu aux États-Unis (CA)

Ce jeu de données est constitué de discussions issues de CreateDebate – un site de débat – sur le contrôle des armes à feu aux États-Unis. Il s'agit d'un sous-ensemble de l'*Internet Argument Corpus 2.0* (Abbott *et al.*, 2016). Chaque discussion a deux points de vue exprimables, déterminés par le profil créant la discussion. Lorsqu'un profil ajoute une publication à une discussion, il doit indiquer le point de vue défendu, et si elle soutient, clarifie, ou conteste une autre publication. Chaque point de vue a ensuite été lié par les créateurs du jeu de données à un point de vue global : « Pour un contrôle strict des armes à feu » ou « Contre un contrôle strict des armes à feu ». Par exemple, dans une discussion intitulée « Le droit de porter une arme est-t-il nécessaire ? », la position « Oui, pour nous défendre » est liée à « Contre un contrôle strict des armes à feu » alors que « Non, il ne crée que des criminels » est lié à « Pour un contrôle strict des armes à feu ».⁵

Les profils contiennent des informations biographiques, les nombres de débats et de publications, et les profils marqués comme alliés, ennemis, ou hostiles. Sont également présents l'efficacité, mesurant le pourcentage de votes positifs sur les publications du profil, et les points de récompense, mesurant l'activité sur le site. En outre, les entités nommées et les types de lemmes sont identifiés dans les publications.

4. Le nombre de politiciens ayant changé de parti entre temps est considéré comme négligeable.

5. Les 88 profils dont le point de vue global n'est pas constant n'ont pas été inclus ici.

5 Proximités définies

5.1 Contenu textuel

Ce type de proximité relie les profils à l'aide d'éléments textuels similaires apparaissant dans leurs publications. Plutôt que de s'appuyer sur une analyse coûteuse des textes qui nécessiterait de calculer des mesures de similarité sémantique complexes, nous avons choisi, pour définir ces proximités, de nous appuyer seulement sur quelques éléments textuels saillants :

- L'utilisation d'un *mot-clé* : hashtags pour les tweets et noms pour les publications CreateDebate.
- Une *référence* à une information externe : urls dans les tweets et noms de domaine pour CreateDebate.⁶

5.2 Contexte social

Ces proximités reposent sur les interactions sociales, et les critères influençant l'environnement social.

- *Citation* de la publication d'un autre profil : retweets pour Twitter et inclusion d'une partie d'une autre publication pour CreateDebate.
- *Appel* à un autre profil : mentions pour les tweets, et publications soutenant ou clarifiant une autre publication pour CreateDebate.
- *Associé* : amis pour Twitter – i.e. profils suivis – et alliés pour CreateDebate. Seuls les associés des profils dans T ont été collectés.
- Critères *socio-démographiques* : les profils CreateDebate contiennent des informations sur le sexe, l'âge et le niveau de formation. Les profils semblables sont liés pour chaque critère, donnant une arête de poids 3 entre 2 profils ayant le même sexe, la même décennie et le même niveau de formation.
- *Croyance*: de même, nous avons utilisé les informations sur la religion et le parti politique des profils CreateDebate.

Les interactions sociales réciproques (indiquées par rec par la suite) se concentrent sur les profils qui ont mutuellement interagi : un lien existe entre A et B si A a interagi avec B et B a interagi avec A . Réciproquement, \overline{rec} indique les interactions non réciproques.

5.3 Contexte géographique

Ce type de proximité repose sur les localisations signalées dans les profils. Sur CreateDebate, seuls les *pays* étaient signalés, alors que les profils Twitter avaient parfois une granularité plus fine, avec *région* et *ville*.

Seuls les emplacements des profils Twitter dans T ont été utilisés pour réduire le coût du nettoyage manuel, nécessaire en raison des variations de format des données renseignées. Ces proximités ont encore de fortes limites : (1) un grand nombre de profils n'indiquent pas leur emplacement et (2) certains emplacements ne sont pas utilisables : « Mars », « Le meilleur pays du monde », « Terre du Milieu »...

6. Les urls offrent une information plus précise, mais seulement 3 urls ont été partagés par plusieurs profils dans le jeu de données CreateDebate.

6 Résultats

Nous avons choisi dans nos expérimentations d'utiliser un algorithme de propagation de labels pour détecter les communautés, implémenté dans la bibliothèque *igraph* (Csardi, Nepusz, 2006). Malgré le non-déterminisme de cette méthode, les expérimentations préliminaires ont démontré son efficacité pour notre tâche.

6.1 Validation de l'hypothèse d'homogénéité des communautés

Notre hypothèse principale étant que les profils appartenant à une même communauté partageaient le même point de vue, nous avons voulu avant toute chose mesurer l'homogénéité d'un échantillon de communautés afin de valider notre intuition.

Pour ce faire, nous nous sommes concentrés sur les deux proximités les plus utilisées dans la littérature, à savoir *citation* et *appel*, et les jeux de données *RI* et *EM* car ils se rapprochaient de la situation idéale pour nous : ils étaient construits purement sur la base des profils à catégoriser, et étaient suffisamment grands pour naturellement contenir de nombreuses interactions. En plus des graphes $G_{citation}$ et G_{appel} , nous avons construit un graphe G_{c+a} prenant en compte ces deux proximités sans distinction.

Tableau 2. Homogénéité moyenne des communautés – Afin de mesurer des scores cohérents, nous avons considéré exclusivement celles contenant au moins 3 profils annotés.

	RI			EM		
	<i>citation</i>	<i>appel</i>	<i>c + a</i>	<i>citation</i>	<i>appel</i>	<i>c + a</i>
Pureté (Girvan, Newman, 2002) ⁷	0.98	0.53	0.54	0.93	0.78	0.90
IMN (Danon <i>et al.</i> , 2005)	0.85	0.01	0.01	0.25	0.11	0.20

Après avoir détecté les communautés, nous avons mesuré la pureté et l'information mutuelle normalisée de celles-ci en terme de point de vue, en utilisant tous les profils annotés à notre disposition (voir tableau 2). Cette analyse préliminaire nous confirme que toutes les proximités n'ont pas la même pertinence pour détecter les points de vue. *Citation* nous permet d'obtenir des communautés bien plus homogènes qu'*appel*, et le fait d'exploiter les deux à la fois sans distinction n'apporte pas d'avantage.

6.2 Scores du modèle de détection des points de vue

Nous avons comparé les performances de notre modèle à plusieurs modèles de référence (tableau 3) :

SVM-Publi Un modèle SVM classant chaque publication suivi d'un vote majoritaire pour déterminer le point de vue du profil, avec un vocabulaire composé des 10 000 mots les plus distinctifs et une validation croisée à 5 échantillons.

SVM-Profil Un modèle SVM classant chaque profil en fonction de la concaténation de ses publications, avec un vocabulaire composé des 10 000 mots les plus distinctifs et une validation croisée à 5 échantillons.

7. La pureté est connue comme étant biaisée en faveur des petites communautés, mais elle reste un indicateur valide dans notre cas, puisque nous voulons mesurer l'homogénéité de celles-ci.

Com-Simplifié Une version de base de notre modèle, avec $X = (x)$ pour chaque proximité x , et $(s, s_{com}, s_{min}) = (3\% \times |T|, 6, 3)$.⁸

Tableau 3. Macro-moyennes de la précision, du rappel, et du score F1. Les scores présentés sont les scores moyens sur 10 itérations.

	RI			EM			EP			CA			
	p	r	fl	p	r	fl	p	r	fl	p	r	fl	
<i>Modèles de référence</i>													
SVM-Profil	0.92	0.92	0.92	0.88	0.87	0.87	0.89	0.89	0.89	0.43	0.37	0.37	
SVM-Publi	0.62	0.48	0.43	0.49	0.43	0.42	0.56	0.56	0.55	0.34	0.28	0.17	
Com-Simplifié	$S = 33$			$S = 47$			$S = 27$			$S = 24$			
	référence	0.51	0.37	0.33	0.87	0.15	0.25	0.74	0.03	0.06	0.38	0.02	0.03
	mot-clé	0.25	0.46	0.32	0.57	0.34	0.38	0.26	0.48	0.33	0.31	0.50	0.39
	citation	0.91	0.71	0.78	0.97	0.29	0.37	0.99	0.54	0.69	0.58	0.04	0.08
	citation _{rec}	1.00	0.34	0.50	1.00	0.03	0.06	1.00	0.29	0.45	0.83	0.02	0.04
	appel	0.25	0.42	0.31	0.72	0.02	0.04	0.74	0.21	0.32	0.60	0.05	0.09
	appel _{rec}	0.78	0.23	0.35	0.94	0.03	0.06	0.94	0.13	0.23	0.72	0.03	0.05
	associé	0.97	0.84	0.90	0.97	0.81	0.88	0.98	0.86	0.92			
	associé _{rec}	0.99	0.85	0.91	0.25	0.43	0.31	0.97	0.81	0.88	0.59	0.17	0.24
	associé _{rec}	0.55	0.39	0.31	0.25	0.38	0.30	0.26	0.39	0.31			
	socio										0.39	0.21	0.25
	croyance										0.56	0.21	0.27
	ville	0.60	0.08	0.14	0.64	0.05	0.09	0.65	0.09	0.15			
région	0.56	0.10	0.16	0.56	0.14	0.22	0.58	0.18	0.26				
pays										0.64	0.23	0.25	
<i>Modèle complet</i>													
(S, s_{com}, s_{min})													
$(3\% \times T , 6, 3)$	$S = 33$			$S = 47$			$S = 27$			$S = 24$			
	0.94	0.93	0.93	0.94	0.94	0.94	0.97	0.97	0.97	0.58	0.52	0.45	
$(2\% \times T , 4, 3)$	$S = 22$			$S = 31$			$S = 18$			$S = 16$			
	0.94	0.93	0.93	0.95	0.94	0.94	0.96	0.95	0.96	0.61	0.52	0.45	

L'ordre des proximités est un élément clé de notre modèle : les interactions fournissant les communautés les plus homogènes doivent être utilisées en premier pour obtenir les meilleurs résultats. Nous avons décidé de tester l'intérêt de notre approche en utilisant un ordonnancement manuel optimal par plateforme, en fonction des scores obtenus avec Com-Simplifié, par précision moyenne décroissante. Nous obtenons ainsi :

$$X_{Twitter} = (\text{citation}_{rec}, \text{associé}, \text{citation}, \text{appel}_{rec}, \text{associé}_{rec}, \text{référence}, \text{ville}, \text{appel}, \text{région}, \text{mot-clé}, \text{associé}_{rec})$$

$$X_{CreateDebate} = (\text{citation}_{rec}, \text{appel}_{rec}, \text{pays}, \text{appel}, \text{associé}_{rec}, \text{citation}, \text{croyance}, \text{socio}, \text{référence}, \text{mot-clé})$$

8. L'un des objectifs de notre modèle étant de limiter la charge que représente l'annotation des données d'entraînement, nous avons volontairement choisi $s \ll |T|$. Les valeurs de s_{com} et s_{min} ont été fixées de manière expérimentales : plusieurs tuples (s_{com}, s_{min}) ont été étudiés mais les résultats obtenus n'étant pas significativement différents, nous n'en présentons ici qu'un seul par souci de concision.

SVM-*Profil* obtient de meilleurs résultats que SVM-*Publication*, ce qui n'est pas surprenant compte tenu de la faible taille des publications. Pour Com-*Simplifié*, on peut noter qu'en dépit de la petite taille de la graine, certaines proximités ont obtenu des scores de précision extrêmement élevés, confirmant les observations précédentes. Malheureusement, dans la plupart des cas le fait que peu de profils soient concernés a conduit à un mauvais rappel.

Les mauvais scores obtenus par Com-*Simplifié* avec $X = (associés_{rec})$ sur *EM* sont surprenants par rapport aux performances sur *RI* et *EP*. Après une analyse plus approfondie, il s'avère que les profils dans *T* étaient tellement proches avec cette proximité qu'ils ont tous été affectés à la même communauté.

En comparaison, le modèle complet utilisant l'ensemble des proximités disponibles a obtenu de très bons scores, en précision comme en rappel. En utilisant seulement 3 % de données annotées, nous avons gagné jusqu'à 8 points sur le score F1 (avec une moyenne de 6 points) par rapport à SVM-*Profil*, qui avait déjà d'excellents résultats. Les profils sur *CA* étaient beaucoup plus difficiles à catégoriser. Cela peut être dû à la petite taille du jeu de données, ou au fait que la taille des publications n'est pas limitée, permettant aux profils d'exprimer des idées plus nuancées, et rendant ainsi le point de vue plus difficile à détecter automatiquement.

Afin d'étudier l'impact de la taille de la graine, nous avons réduit celle-ci en terme de nombre de profils-graine et de communautés-graine. Avec $(s, s_{com}, s_{min}) = (2\% \times |T|, 4, 3)$, la perte de performance est rare, et négligeable lorsqu'elle a lieu. De manière intéressante, le fait de se concentrer sur moins de communautés peut dans certains cas conduire à de meilleurs scores.

7 Discussion et conclusion

Pour rappel, notre objectif principal était de détecter le point de vue des profils en utilisant leur proximité avec d'autres profils, cela avec une très petite graine afin de réduire les coûts d'annotation. Nous proposons un modèle générique qui peut être facilement personnalisé pour répondre à toutes les exigences, et qui a montré une amélioration de score F1 allant jusqu'à 8 points par rapport aux modèles de référence.

Nos résultats confirment que les communautés peuvent être une source d'information puissante pour détecter les points de vue, même en utilisant moins de 5% de données annotées. De plus, ils ont démontré que l'utilisation de plusieurs types de proximité permettait de renforcer les résultats. Ceci est dû au fait que toutes les proximités ne sont pas porteuses de la même information en termes de point de vue, et que les plus précises concernent souvent un petit sous-ensemble de profils. Cette combinaison de proximités nous permet d'obtenir de meilleurs résultats que les systèmes basés exclusivement sur le texte en utilisant jusqu'à 40 fois moins de données annotées.

L'analyse des différentes proximités est en accord avec les observations présentes dans la littérature. Les scores de précision obtenus par *citation* et *référence* suggèrent que les gens ont tendance à construire leur discours en ligne en partageant les arguments avec lesquels ils sont d'accord plutôt que de réfuter les arguments opposés. Notez que si les profils peuvent interpeller leurs adversaires, ils ont tendance à bien plus répondre à leurs alliés. Ceci est démontré par la meilleure précision obtenue par

appel_{rec} par rapport à *appel*. La précision de la proximité *associé* tend à démontrer qu'ils choisissent également avec soin les profils suivis (Conover *et al.*, 2011 ; An *et al.*, 2013). Fait intéressant, un comportement contraire à l'observation précédente est également visible : certains profils décident de suivre leurs adversaires autant que leurs alliés, ce qui se traduit par l'assignation de tous les profils à la même communauté. Il s'agit probablement d'une façon de surveiller leurs actions et discours.

Une utilisation plus complète et plus fine du contenu textuel permettrait certainement d'améliorer les performances. En effet, les résultats indiquent que les mots-clés seuls sont difficilement exploitables. La majorité des mots-clés semblent plus liés au sujet qu'à un point de vue spécifique. La formation et la diffusion des points de vue est un processus complexe, encore difficile à appréhender par des méthodes purement informatiques. Nous pouvons supposer que chaque interaction sur les réseaux sociaux a son propre rôle dans ce processus.

Nous prévoyons par la suite de comparer différentes méthodes de sélection des profils-graines afin d'étudier l'impact de cette sélection sur les résultats. Il pourrait également être bénéfique d'étudier l'impact de chaque proximité sur les résultats en fonction de son rang dans X^{ord} . Cela permettrait de déterminer si une version « abrégée » du modèle serait préférable au fait d'utiliser toutes les proximités disponibles. Enfin il serait intéressant de comparer notre modèle, traitant chaque proximité à part, avec une approche utilisant un unique graphe multi-couche (Mucha *et al.*, 2010) afin d'observer les différences de comportements des différents modèles.

Nous pensons que ce modèle pourrait être d'une grande aide pour les chercheurs en humanités numériques qui souhaitent exploiter de grands jeux de données sans avoir les ressources nécessaires pour les annoter manuellement. Les éléments de base ne nécessitent pas de compétences techniques avancées à appréhender. Nous prévoyons d'expérimenter cet aspect dans le cadre du projet interdisciplinaire LisTIC.⁹

Remerciements

Ce projet est cofinancé par l'Union européenne – l'Europe s'engage en Midi-Pyrénées avec le Fonds européen de développement régional.

Références

- Abbott R., Ecker B., Anand P., Walker M. (2016). Internet Argument Corpus 2.0: An SQL schema for Dialogic Social Media and the Corpora to go with it. In *LREC*, p. 23–28.
- Adamic L. A., Glance N. (2005). The political blogosphere and the 2004 U.S. election: Divided they blog. In *LinkKDD*, p. 36–43.
- An J., Quercia D., Crowcroft J. (2013). Fragmented social media: A look into selective exposure to political news. In *WWW*, p. 51–52.
- Barberá P. (2015). Birds of the Same Feather Tweet Together: Bayesian Ideal Point Estimation Using Twitter Data. *Political Analysis*, vol. 23, n° 1, p. 76–91.

9. <https://listic.irit.fr>

- Barberá P., Jost J. T., Nagler J., Tucker J. A., Bonneau R. (2015). Tweeting From Left to Right: Is Online Political Communication More Than an Echo Chamber? *Psychological Science*, vol. 26, n° 10, p. 1531–1542.
- Boireau M. (2014). Determining Political Stances from Twitter Timelines: The Belgian Parliament Case. In *EGOSE*, p. 145–151.
- Brigadir I., Greene D., Cunningham P. (2015). Analyzing Discourse Communities with Distributional Semantic Models. In *WebSci*, p. 1–10.
- Conover M. D., Ratkiewicz J., Francisco M., Gonçalves B., Flammini A., Menczer F. (2011). Political Polarization on Twitter. In *ICWSM*, p. 89–96.
- Csardi G., Nepusz T. (2006). The igraph software package for complex network research. *InterJournal*, vol. Complex Systems, p. 1695.
- Danon L., Díaz-Guilera A., Duch J., Arenas A. (2005). Comparing community structure identification. *JSTAT*, n° 9, p. P09008.
- Girvan M., Newman M. E. J. (2002). Community structure in social and biological networks. *NAS*, vol. 99, n° 12, p. 7821–7826.
- Hasan K. S., Ng V. (2013). Stance Classification of Ideological Debates: Data, Models, Features, and Constraints. In *EMNLP*, p. 1348–1356.
- Iyengar S., Westwood S. J. (2015). Fear and Loathing across Party Lines: New Evidence on Group Polarization. *American Journal of Political Science*, vol. 59, n° 3, p. 690–707.
- Littman J., Wrubel L., Kerchner D. (2016). *2016 United States Presidential Election Tweet Ids*. Harvard Dataverse.
- Magdy W., Darwish K., Abokhodair N., Rahimi A., Baldwin T. (2016). #ISISisNotIslam or #DeportAllMuslims?: Predicting unspoken views. In *WebSci*, p. 95–106.
- McPherson M., Smith-Lovin L., Cook J. M. (2001). Birds of a Feather: Homophily in Social Networks. *Annual Review of Sociology*, vol. 27, n° 1, p. 415–444.
- Mohammad S. M., Sobhani P., Kiritchenko S. (2017). Stance and Sentiment in Tweets. *ACM Transactions on Internet Technology*, vol. 17, n° 3, p. 1–23.
- Mucha P. J., Richardson T., Macon K., Porter M. A., Onnela J.-P. (2010). Community Structure in Time-Dependent, Multiscale, and Multiplex Networks. *Science*, vol. 328, n° 5980, p. 876–878.
- Rajadesingan A., Liu H. (2014). Identifying Users with Opposing Opinions in Twitter Debates. In *SBP*, vol. 8393, p. 153–160.
- Rosvall M., Axelsson D., Bergstrom C. T. (2009). The map equation. *EPJ ST*, vol. 178, n° 1, p. 13–23.
- Thonet T., Cabanac G., Boughanem M., Pinel-Sauvagnat K. (2016). VODUM: a Topic Model Unifying Viewpoint, Topic and Opinion Discovery. In *ECIR*, vol. 9626, p. 533–545.
- Wong F. M. F., Tan C.-W., Sen S., Chiang M. (2013). Quantifying Political Leaning from Tweets and Retweets. In *ICWSM*, p. 640–649.
- Zhang S., Qiu L., Chen F., Zhang W., Yu Y., Elhadad N. (2017). We Make Choices We Think Are Going to Save Us: Debate and Stance Identification for Online Breast Cancer CAM Discussions. In *WWW*, p. 1073–1081.