



HAL
open science

Retweeter ou ne pas retweeter

Thomas Palmer, Gilles Hubert, Karen Pinel-Sauvagnat

► **To cite this version:**

Thomas Palmer, Gilles Hubert, Karen Pinel-Sauvagnat. Retweeter ou ne pas retweeter : Le dilemme des portails de diffusion d'information temps-réel. Document numérique - Revue des sciences et technologies de l'information. Série Document numérique, 2018, 21 (3), pp.81-103. 10.3166/DN.21.3.81-103 . hal-02064611

HAL Id: hal-02064611

<https://hal.science/hal-02064611>

Submitted on 12 Mar 2019

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 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's version published in:
<http://oatao.univ-toulouse.fr/22738>

Official URL <https://dn.revuesonline.com/accueil.jsp>

To cite this version: Palmer, Thomas and Hubert, Gilles and Pinel-Sauvagnat, Karen *Retweeter ou ne pas retweeter*. (2018) Document numérique, 21 (3). 81-103. ISSN 1279-5127

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

Retweeter ou ne pas retweeter

Le dilemme des portails de diffusion d'information temps-réel

Thomas Palmer , Gilles Hubert , Karen Pinel-Sauvagnat

*IRIT UMR 5505 CNRS,
Université Paul Sabatier – Toulouse 3, France
{Gilles.Hubert@irit.fr,Karen.Sauvagnat@irit.fr}*

RÉSUMÉ. L'étude des caractéristiques contextuelles a été largement traitée en Recherche d'Information (RI), mais les applications concrètes sur de vrais flux de données ne sont pas très répandues. Dans cet article, notre problématique concerne la décision automatique de retweeter un message. En considérant le centre d'intérêt d'un utilisateur, nous proposons un modèle pour effectuer un filtrage automatique en temps-réel du flux Twitter en utilisant de multiples caractéristiques contextuelles. Le modèle sépare l'aspect contextuel du contenu du message en lui-même, tout en conservant une très grande vitesse d'exécution. Notre modèle a été évalué dans le cadre des tâches TREC Microblog 2015 et TREC Real-Time Summarization 2016. Les résultats montrent la grande efficacité (temps de retweet) de notre modèle, et son efficacité sur les mesures de 2015. Ces résultats en termes d'efficacité n'ont cependant pas été confirmés sur 2016. Ceci nous a conduit à une analyse plus en détail des résultats (approche et cadre d'évaluation). Cette analyse a notamment montré un biais dans l'évaluation, biais que nous discutons à la fin de l'article.

ABSTRACT. The study of contextual features has been widely discussed in Information Retrieval (IR), but concrete applications on real data streams are not common. In this paper, we aim at doing retweet recommendation. Considering a user interest, we introduce a model to perform real-time online filtering of the Twitter stream using several contextual features. The model separates content and contextual aspects, achieving a very high velocity. Experiments were performed on the TREC Microblog 2015 and TREC 2016 Real-Time Summarization frameworks. Results show that our model is very efficient as well as effective on the 2015 collection. However, the results regarding effectiveness have not been confirmed on the 2016 framework. This led us to conduct a detailed analysis of the results with regard to our approach and the evaluation framework. This analysis showed an evaluation bias discussed at the end of the article.

MOTS-CLÉS : RI contextuelle, filtrage temps-réel, microblogs, évaluation.

KEYWORDS: contextual IR, real-time filtering, microblogs, evaluation

1. Introduction

Les plateformes de microblogging, initialement conçues comme des outils de communication, ont vu leur utilisation évoluer dans de nouvelles directions, telle que la collecte d'information en temps-réel. Twitter est l'exemple type de ce genre de plateformes avec 313 millions d'utilisateurs uniques et actifs par mois et plus de 500 millions de messages (tweets) par jour¹. Une grande partie des utilisateurs de Twitter, que nous appellerons « auditeurs » dans cet article, se contentent de lire les tweets d'autres utilisateurs sans jamais poster eux-mêmes de message. Twitter est alors considéré comme une source d'information temps-réel et les auditeurs scannent continuellement le flux de tweets postés par les personnes auxquelles ils sont abonnés. Leur but est de trouver des informations à la fois nouvelles (qu'ils n'ont jamais lues auparavant), récentes (qui viennent de sortir) et précises (qui les concernent).

Dans la plupart des cas, les utilisateurs actifs (les personnes suivies) postent des messages qui peuvent être regroupés en différents thèmes précis et distincts. Les auditeurs ont leurs propres centres d'intérêt et ils doivent identifier quelles sont les bonnes personnes à suivre, pour ensuite filtrer les messages pertinents issus des différents flux d'information auxquels ils sont abonnés. Certains comptes spécifiques essaient d'aider ces auditeurs en se concentrant sur un sujet en particulier. Leur but est de retweeter (c'est-à-dire relayer un message posté par un autre utilisateur sans aucune modification) le plus de contenu possible sur ce sujet spécifique. (Zhao, Tajima, 2014) les appellent des « comptes portails ». Ces comptes sont à l'heure actuelle administrés manuellement par une ou plusieurs personnes. Un administrateur de compte portail est confronté à plusieurs challenges: (i) il doit sélectionner un nombre approprié de tweets par unité de temps (comme une journée) afin d'éviter de surcharger ses followers² avec trop de messages, (ii) il doit également le faire le plus rapidement possible, car être le premier à apporter l'information est essentiel (Takemura, Tajima, 2012), et enfin par dessus tout (iii) il ne doit pas laisser passer d'information cruciale.

L'aspect le plus important ici, au-delà de l'habituel critère de pertinence des résultats, est la vitesse de retransmission (c'est-à-dire le temps écoulé entre la première émission d'une information nouvelle et son relais par le compte portail). En effet, la valeur d'une information va décroître au fur et à mesure que le temps passe avant que l'auditeur ne la lise. Une situation encore plus problématique survient si l'auditeur en question lit cette même information à partir d'une autre source. Il peut dans ce cas interrompre son abonnement au portail. Donner la sensation d'être « le premier à savoir » aux auditeurs est l'atout majeur de ce type de systèmes. Toutefois, il existe un risque de surcharge de l'auditeur en étant trop rapide à retransmettre de trop nombreux messages. Supprimer un message une fois qu'il est relayé étant impossible, les comptes portails doivent impérativement trouver un équilibre entre élire les meilleurs messages candidats dans un intervalle de temps donné et la vitesse de retransmission.

1. <http://about.twitter.com/fr/company>, <http://www.internetlivestats.com/>, 2016

2. Dans le jargon Twitter, les followers sont les personnes qui sont abonnées au compte.

Notre question de recherche est d’automatiser le fonctionnement de ces comptes portails, c’est-à-dire de concevoir un outil de recommandation de retweet automatique en temps-réel. Nous proposons un modèle qui suggère automatiquement un ensemble restreint de tweets pertinents provenant d’un flux de données selon un centre d’intérêt donné. Ce modèle repose sur un ensemble de caractéristiques de contexte associées à chacun des tweets, combiné à un traitement du contenu du message en lui-même. Le modèle est conçu pour respecter des contraintes de temps de traitement et ainsi retransmettre les messages sélectionnés dans les plus brefs délais.

Notre approche a été instanciée pour répondre aux objectifs définis dans le cadre de tâches d’évaluation orientées vers la problématique de synthèse de tweets en temps-réel : la tâche TREC Microblog 2015 et TREC Real-Time Summarization (RTS) 2016 qui est une évolution de la précédente. Les expérimentations dans le cadre de TREC Microblog 2015 ont eu pour but d’estimer l’impact des différentes caractéristiques intégrées au modèle afin de dégager une configuration performante. Les expérimentations sur la collection TREC RTS 2016 étaient destinées à valider les performances de cette configuration. Les résultats obtenus dans ce dernier cadre, bien en-deçà de ceux constatés en 2015 nous ont conduits à une analyse approfondie pour expliquer ce constat, à la fois du point de vue de l’approche et du cadre d’évaluation. Nous avons ainsi identifié un biais au niveau de l’évaluation, que nous discutons à la fin de l’article.

Cet article est organisé comme suit. La section 2 formalise notre problématique. Les travaux de la littérature ainsi que leurs différences avec notre approche sont présentés dans la section 3. Notre modèle est décrit dans la section 4. La section 5 présente les expérimentations menées dans le cadre des tâches TREC Microblog 2015 et TREC Real-Time Summarization 2016 ainsi qu’une analyse des résultats obtenus. Pour finir, la partie 6 conclut cet article et présente les améliorations envisagées.

2. Formalisation du problème

Dans cette section, nous proposons une formalisation inspirée de (Zhao, Tajima, 2014), afin de préciser les contours du problème de recommandation de retweet automatique en temps-réel introduit précédemment. Cette formalisation permet d’explicitier les différentes problématiques à considérer et auxquelles notre approche doit répondre.

Étant donné le flux Twitter \mathcal{T} de tweets t_i , un centre d’intérêt d’un auditeur (appelé profil utilisateur) $p = \{w_0^p, \dots, w_k^p\}$ composé de k termes w_j^p , et un intervalle de temps Δ modélisant la période de validité de p (par exemple un mois), notre objectif est de filtrer \mathcal{T} en ne conservant qu’un nombre limité N de tweets pertinents en fonction de p au cours d’intervalles plus restreints δ (par exemple une heure) de Δ .

Chaque tweet est représenté comme suit : $t_i = (\mathcal{CO}_{t_i}, \mathcal{M}_{t_i}, ts_{t_i})$, où $\mathcal{CO}_{t_i} = \{w_0^{t_i}, \dots, w_n^{t_i}\}$ est l’ensemble des termes $w_j^{t_i}$ composant le contenu du tweet t_i , \mathcal{M}_{t_i} est l’ensemble de méta-données associées à ce tweet (hashtags, urls, images, auteur...),

et ts_{t_i} est l'étiquette temporelle associée, c'est-à-dire la date de publication initiale du tweet.

Nous définissons la fonction de décision φ comme suit :

$$\varphi(t_i, p, \mathcal{T}_s, \mathcal{R}) = \begin{cases} \{rt_i\} & \text{si } t_i \text{ est sélectionné pour être retweeté} \\ \emptyset & \text{sinon} \end{cases} \quad (1)$$

où \mathcal{T}_s est l'ensemble de tweets déjà sélectionnés de \mathcal{T} pendant Δ , \mathcal{R} est un ensemble de ressources, et $rt_i = (\mathcal{CO}_{t_i}, \mathcal{M}_{t_i}, ts_{rt_i})$ est le tweet correspondant au retweet de t_i à l'étiquette temporelle ts_{rt_i} , avec $ts_{rt_i} > ts_{t_i}$.

La fonction φ doit considérer certaines problématiques :

- pour éviter la surcharge de l'utilisateur, φ ne doit pas renvoyer plus de N tweets au cours d'un intervalle donné δ (**P1**),
- pour ne pas notifier un utilisateur plusieurs fois pour le même sujet, la nouveauté d'un tweet t_i vis-à-vis de \mathcal{T}_s doit être prise en compte (**P2**),
- pour empêcher l'obsolescence d'un tweet, φ doit minimiser $\sigma = ts_{rt_i} - ts_{t_i}$ (**P3**),
- lorsqu'aucun tweet pertinent n'apparaît durant δ , φ doit se comporter comme la fonction *vide* qui ne renvoie jamais aucun message (**P4**). En revanche, elle doit bien sûr identifier les tweets pertinents lorsque ceux-ci apparaissent.

3. État de l'art

Twitter attire l'attention des chercheurs depuis de nombreuses années maintenant, et ce dans de nombreux domaines différents, comme la détection d'évènement, le suivi de réputation ou encore l'analyse de sentiments. Ces deux dernières problématiques ont notamment bénéficié de cadres d'évaluation dédiés, à savoir respectivement, CLEF Replab pour le suivi de la réputation de compagnies ou d'individus (Amigó *et al.*, 2013) ou SemEval tâche 5 pour l'analyse de sentiments (Pontiki *et al.*, 2016). Néanmoins, très peu de travaux avant 2015 se concentrent sur la recommandation de retweets (Kywe *et al.*, 2012).

Le premier travail proche de notre approche a été réalisé par (Zhao, Tajima, 2014). Quatre algorithmes ont été proposés pour automatiser la sélection de tweets, mais seulement deux d'entre eux fonctionnent en véritable temps-réel (c'est-à-dire en retweetant instantanément après le post initial). La sélection de tweet est basée sur la similarité par cosinus entre le contenu du tweet et les centres d'intérêts. Le premier algorithme utilise un seuil global pour chacun des tweets et ajuste ensuite ce seuil en exploitant des données provenant de l'unité de temps précédente (l'heure précédente), en supposant que « les seuils optimaux pour des intervalles de temps consécutifs ne varient que très peu ». Le second algorithme utilise un seuil stochastique. Toutefois, aucun de ces algorithmes proposés n'utilise d'informations relatives au contexte, et

les algorithmes en véritable temps-réel sont nettement moins efficaces que ceux en pseudo temps-réel.

En 2015, la tâche TREC Microblog a fourni à la communauté RI un cadre d'évaluation et a ainsi permis au problème de recommandation de retweets d'être au centre d'une attention nouvelle. Plusieurs approches ont été proposées lors de la tâche. La plus efficace a été réalisée par l'Université de Waterloo (L. Tan *et al.*, 2015). Cette approche considère en premier lieu la qualité du message en supprimant tous ceux avec trop peu de mots significatifs ou au contraire trop de mots-clés (hashtags). Dans un deuxième temps, une expansion de requête est réalisée grâce à 17 mois de données Twitter collectées. Pour sélectionner les tweets pertinents, l'approche proposée utilise une combinaison de modèles vectoriels appliqués à toutes les différentes parties des requêtes fournies par TREC (c'est-à-dire le titre, la description mais aussi la partie narrative). Enfin, afin de sélectionner les messages à retweeter, deux stratégies de fenêtrage temporel sont appliquées : des fenêtres temporelles fixes et des fenêtres avec seuils dynamiques. La première méthode sélectionne le tweet avec le plus haut score au sein de chaque fenêtre de x minutes au cours de la journée. La seconde utilise des fenêtres dynamiques (x évolue tout au long de la journée selon le temps écoulé entre deux notifications) pour sélectionner le meilleur candidat parmi les tweets. Une deuxième approche a été proposée par l'Université de Pékin (Fan *et al.*, 2015). Une expansion de requête (ou de profil utilisateur) est réalisée en utilisant l'API de Google et une divergence de Kullback-Leibler est appliquée aux tweets sélectionnés. La principale différence réside dans le traitement manuel effectué pour mettre à jour le seuil utilisé lors de la sélection des tweets. Un être humain doit parcourir les cents meilleurs tweets sélectionnés la veille pour chacun des profils utilisateurs et ensuite déterminer la limite inférieure du seuil pour les sélections du jour à venir. Une autre approche, proposée par l'Université de Changsha (Zhu *et al.*, 2015), combine certains des principes de chacune des deux approches précédentes, comme la prise en considération de la qualité du tweet en plus du traitement sur le contenu, mais aussi l'expansion de requête grâce à l'API de Google, et enfin la mise à jour dynamique des seuils de sélection.

Les scénarios étudiés pour la tâche TREC Microblog 2015 ont été reconduits en 2016 dans une nouvelle tâche intitulée TREC Real-time summarization (RTS) cette fois-ci. Deux participants ont proposé des variantes d'approches qui se sont toutes hissées dans le haut du classement en termes de performances vis-à-vis des nouvelles mesures d'évaluation définies pour la tâche. L'approche la plus efficace a été proposée par l'université Polytechnique de Hong Kong (PolyU) (H. Tan *et al.*, 2016). L'approche complète se base sur deux phases : une phase hors ligne et une phase en temps-réel. La phase hors ligne mêle expansion de requête à partir de ressources externes et deux phases d'apprentissage d'un modèle de mesure de pertinence basé sur un ensemble de métadonnées des tweets et d'un modèle de détection de redondance. La phase en temps-réel applique un pré-traitement des tweets pour éliminer ceux non écrits en anglais ou contenant trop peu de termes, calcule les méta-données des tweets pour ensuite appliquer les modèles de pertinence et de redondance appris en amont. Les trois variantes soumises ont obtenu de très bonnes performances mais la meilleure

variante est celle qualifiée de naïve, uniquement basée sur la présence des termes des profils étendus dans les tweets. Cette approche a été classée dans la catégorie des approches avec préparation manuelle. Cette approche s'apparente à la nôtre notamment dans l'utilisation de méta-données mais celle-ci est basée sur une phase d'apprentissage.

Au contraire, l'université du Qatar a été celle qui a proposé l'approche entièrement automatique la plus performante au regard des mesures d'évaluation (Suwaileh *et al.*, 2016). Il s'agit d'une approche plutôt classique allégée pour une rapidité de traitement. Une pré-sélection des tweets est effectuée pour éliminer ceux qui ne sont pas en langue anglaise ainsi que ceux de faible qualité, c'est-à-dire, avec trop peu de termes, trop de hahstags ou trop d'url. Les tweets pré-sélectionnés sont ensuite nettoyés pour éliminer les éléments non informatifs (url, émoticônes, caractères spéciaux...) et indexés pour calculer les fréquences des termes dans les tweets traités. L'index inclut les 5 jours de tweets précédant la période de la campagne TREC RTS 2016. Une succession de deux filtrages est ensuite appliquée, l'un relatif à la pertinence (basée sur l'idf des termes) puis l'autre relatif à la nouveauté (basée sur une similarité de type Jaccard entre un nouveau tweet et les tweets déjà renvoyés). Deux variantes incluent également en amont une phase d'expansion de profils, l'une basée sur du pseudo retour de pertinence toutes les heures, l'autre sur une recherche sur Twitter. La variante la plus performante a cependant été celle sans expansion de requête.

Par ailleurs, plusieurs travaux ont étudié l'importance du contexte dans la RI sociale. À propos de l'information disponible sur l'utilisateur, (Jabeur *et al.*, 2012) s'est intéressé à l'influence de l'auteur et à l'importance de la structure du réseau social dans le but de combiner une estimation thématique et sociale de la pertinence d'un tweet. Entre autres choses, (Damak *et al.*, 2013) a montré que la simple présence d'URL dans un tweet est un facteur déterminant de pertinence étant donné un besoin en information précis. La limite majeure de ces différentes approches réside dans le manque d'application en contexte temps-réel. En effet, ces approches utilisent des tweets en tant que collection statique de documents et non pas comme un flux temps-réel. Contrairement à notre approche qui traite les documents les uns après les autres, elles peuvent utiliser des processus de RI classiques appropriés aux collections statiques comme les fonctions d'indexation et de classement. Certains autres travaux se sont concentrés sur des éléments propres à Twitter, tels que les entités, qui sont partie intégrante de la structure des tweets. Les hashtags créent des liens entre les documents ou des fils de discussion. Les mentions relient les personnes ou les organisations entre elles et modélisent le réseau social. Des exemples tels que (Efron, 2010) en recherche par mots-clés, ou (Guille, Favre, 2014) en détection d'événements, ont montré le rôle prépondérant de ces entités. Néanmoins, ils se sont concentrés uniquement sur ces caractéristiques précises et n'utilisent pas de flux temps-réel. Notre travail est plus proche de l'état de l'art de (Cheng *et al.*, 2013) qui utilise plusieurs caractéristiques de contexte, telles que la richesse du tweet, son autorité, sa fraîcheur, et enfin l'analyse de sentiments associée. Cependant l'approche ne cherche pas à prendre une décision temps-réel sur des tweets du flux, son objectif étant de répondre à des requêtes par mots-clés, et non pas de faire du filtrage.

4. Modèle contextuel pour la recommandation de retweet




Figure 1. Processus global basé sur le modèle contextuel pour la recommandation de retweet

Pour répondre au problème formalisé en section 2 nous proposons de baser la décision de retweet à la fois sur l'adéquation du contenu du tweet par rapport au centre d'intérêt et sur les méta-données associées au tweet. En effet, ces méta-données peuvent permettre de distinguer les tweets se rapportant au même centre d'intérêt par le fait qu'ils contiennent également des éléments pouvant apporter des informations supplémentaires au travers d'urls ou d'images, par exemple. Elles peuvent également distinguer les tweets suivant les caractéristiques de leurs auteurs respectifs, comme par exemple leur popularité liée au nombre de personnes qui les suivent (followers).

L'évaluation de la fonction de décision de retweet φ est donc divisée en deux parties : la première portant sur le contenu et la seconde sur le contexte, comme décrit dans la figure 1.

4.1. Modèle sur le contenu

Le principal objectif du modèle sur le contenu est d'évaluer la pertinence du tweet vis-à-vis d'un profil utilisateur.

Tout d'abord, un pré-traitement est effectué à la fois sur le contenu du tweet \mathcal{CO}_{t_i} et sur le profil utilisateur p , dans le but de maximiser le nombre de correspondances possibles. Ce pré-traitement peut être la suppression des mots vides, la lemmatisation, etc. Le résultat de ce pré-traitement est une représentation du profil $p' = \{w_0^{p'}, \dots, w_{k'}^{p'}\}$ composée de $k' \leq k$ termes $w_j^{p'}$ (où k dénote le nombre de termes du profil utilisateur p), ainsi qu'un contenu de tweet pré-traité $\mathcal{CO}'_{t_i} = \{w_0^{t_i}, \dots, w_{n'}^{t_i}\}$ composé de $n' \leq n$ termes $w_j^{t_i}$ (où n dénote le nombre de termes de \mathcal{CO}_{t_i}).

L'objectif est donc de trouver une correspondance entre \mathcal{CO}'_{t_i} et p' . Un critère d'acceptation du contenu *CAC* (*Content Acceptance Criterion*) est alors évalué comme suit :

$$CAC(p', \mathcal{CO}'_{t_i}, \mathcal{T}_s) = \begin{cases} \frac{\sum_{j=1}^{n'} \mathbb{1}_{\{w_j^{t_i} \in p'\}}}{\sum_{j=1}^{k'} \mathbb{1}_{\{w_j^{p'} \in p'\}}} & \text{si } sim(\mathcal{CO}'_{t_i}, \mathcal{T}_s) < \lambda_{nov} \\ 0 & \text{sinon} \end{cases} \quad (2)$$

où $\mathbb{1}$ est une fonction indicatrice qui est égale à 1 si la condition liée est satisfaite et 0 sinon (par exemple, $\mathbb{1}_{\{x \in \mathbb{R}\}} = 1$; si $x \in \mathbb{R}$).

Concrètement, nous calculons le rapport entre le nombre de mots communs entre le contenu du message \mathcal{CO}'_{t_i} et le profil utilisateur p' , sur le nombre de mots dans p' . t_i doit également être assez différent des autres messages déjà retweetés appartenant à \mathcal{T}_s . La nouveauté de t_i selon \mathcal{T}_s est évaluée grâce à une fonction de similarité $sim(\mathcal{CO}'_{t_i}, \mathcal{T}_s)$ dont le résultat doit être inférieur à un seuil λ_{nov} . Cette fonction de similarité peut par exemple être la très utilisée mesure de Cosinus. Dans le cas de profils utilisateurs courant sur le long terme, une fonction d'oubli pourrait également être intégrée à \mathcal{T}_s .

4.2. Modèle sur le contexte

En plus d'un traitement sur le contenu, nous associons à chaque tweet un contexte autour du message \mathcal{CX}_{t_i} composé d'informations supplémentaires. Ces informations sont soit directement extraites soit calculées à partir des métadonnées \mathcal{M}_{t_i} . \mathcal{M}_{t_i} est défini par $(st_{t_i}, hash_{t_i}, men_{t_i}, url_{t_i}, med_{t_i}, us_{t_i})$ où :

- st_{t_i} est le statut du retweet (message initial ou retweet d'un autre utilisateur),
- $hash_{t_i}$ est l'ensemble des hashtags dans t_i ,
- men_{t_i} est l'ensemble des mentions dans t_i ,
- url_{t_i} est l'ensemble des urls dans t_i ,
- med_{t_i} est l'ensemble des médias (image, son, vidéo, etc.) dans t_i ,
- us_{t_i} regroupe des informations sur l'auteur de t_i . $us_{t_i} = (fol_{t_i}, stat_{t_i}, fr_{t_i}, list_{t_i}, fav_{t_i}, desc)$ où fol_{t_i} est le nombre de followers, $stat_{t_i}$ est le nombre de statuts (nombre de tweets et retweets créés par l'auteur), fr_{t_i} est le

nombre d'amis, $list_{t_i}$ est le nombre de listes publiques dont l'auteur est membre, fav_{t_i} est le nombre de favoris, et $desc_{t_i}$ est la description de profil de l'auteur composée de $nDesc$ termes w^d_j .

$\mathcal{C}\mathcal{X}_{t_i}$ est défini comme un ensemble de caractéristiques f_l , dont les valeurs sont estimées en utilisant \mathcal{M}_{t_i} . Les caractéristiques sont organisées en trois catégories : Qualité, Entités et Auteur. Chaque caractéristique f_l est associée à un seuil qui lui est propre λ_l , au-dessus duquel un message est considéré comme pertinent au niveau de cette caractéristique particulière. Nous distinguons deux types de caractéristiques, les majeures et les mineures, en fonction de leur importance déterminée selon l'état de l'art. Le tableau 1 résume toutes les caractéristiques f_l avec leurs seuils associés λ_l , ainsi que leur importance (Majeure ou Mineure). Dans la catégorie Entités, la caractéristique f_9 , qui correspond au nombre d'urls apparaissant dans le tweet, est par exemple catégorisée comme une caractéristique majeure, puisque (Damak *et al.*, 2013) a montré que la simple présence d'une url dans un tweet est un bon indicateur de pertinence. Dans la catégorie Qualité, f_1 , qui indique qu'un tweet est un message initial ou un retweet, permettra de promouvoir les messages initiaux par rapport aux retweets considérant que ces derniers fournissent par nature une information redondante par rapport au message initial. Dans la catégorie Auteur, f_{11} , qui correspond au nombre de followers de l'auteur du tweet, permettra de retenir en priorité les tweets postés par des auteurs populaires.

λ_l peut être déterminé grâce à un ensemble de ressources \mathcal{R} détaillé dans la section 5.

Pour chaque caractéristique f_l , un score $S_{c_l}(f_l, p, \mathcal{R})$ est défini comme suit :

$$S_{c_l}(f_l, p, \mathcal{R}) = \begin{cases} \sum_{y=1}^{|\text{hash}_{t_i}|} \mathbb{1}_{\{f_l > \lambda_l\}} & \text{si } l = 6 \\ \sum_{y=1}^{|\text{men}_{t_i}|} \mathbb{1}_{\{f_l > \lambda_l\}} & \text{si } l = 8 \\ \mathbb{1}_{\{f_l > \lambda_l\}} & \text{sinon} \end{cases} \quad (3)$$

Chaque caractéristique est associée à un score égal à 1 si sa valeur est plus élevée que λ_l . La seule différence provient de f_6 , respectivement f_8 , dont le score est un cumul pour chacun des hashtags présents, respectivement pour chaque mention, s'il est présent dans le profil utilisateur p .

Un score basé sur les caractéristiques de contexte FBS (*Feature-Based Score*) est calculé pour chaque tweet comme suit :

$$FBS(\mathcal{C}\mathcal{X}_{t_i}, p, \mathcal{R}) = \sum_{l=1}^m [(S_{c_l}(f_l, p, \mathcal{R}) \cdot \mathbb{1}_{\{l \in \mathcal{C}\mathcal{X}_{t_i}^m\}}) + 2 (S_{c_l}(f_l, p, \mathcal{R}) \cdot \mathbb{1}_{\{l \in \mathcal{C}\mathcal{X}_{t_i}^M\}})] \quad (4)$$

où $\mathcal{C}\mathcal{X}_{t_i}^m$ est l'ensemble des caractéristiques mineures et $\mathcal{C}\mathcal{X}_{t_i}^M$ est l'ensemble des caractéristiques majeures, avec $\mathcal{C}\mathcal{X}_{t_i} = \mathcal{C}\mathcal{X}_{t_i}^M \cup \mathcal{C}\mathcal{X}_{t_i}^m$ et $\mathcal{C}\mathcal{X}_{t_i}^M \cap \mathcal{C}\mathcal{X}_{t_i}^m = \emptyset$.

Tableau 1. Caractéristiques f_l étudiées pour le modèle contextuel. L’obtention des caractéristiques est extraite à partir des métadonnées (M) ou calculée (C). Le mode de détermination des seuils λ_l est indiquée soit par * pour la méthode statique utilisant \mathcal{R} , soit † pour la méthode par étude pilote, ou encore ‡ si définie dans la littérature. Si besoin, la référence est indiquée dans la description

	f_l	Obtention	λ_l	Importance	Description
Qualité	f_1	M	0 ‡	Majeure	Message initial ou retweet d’un autre utilisateur. 1 si message initial; 0 sinon (Cheng <i>et al.</i> , 2013)
	f_2	C	10 †	Mineure	Nombre de termes après pré-traitement (n')
	f_3	C	0.6 †	Mineure	Rapport entre n' et n (nombre de termes avant pré-traitement) (Cheng <i>et al.</i> , 2013)
	f_4	C	0.6 †	Mineure	Rapport entre la taille de $hash_{t_i}$ et n
Entités	f_5	C	1 †	Mineure	Taille de $hash_{t_i}$ (Aisopos <i>et al.</i> , 2012)
	f_6	C	0 ‡	Mineure	Pour chaque h de $hash_{t_i}$, présence de h dans le profil p
	f_7	C	0 †	Mineure	Taille de men_{t_i} (Aisopos <i>et al.</i> , 2012)
	f_8	C	0 †	Mineure	Pour chaque m de men_{t_i} , présence de m dans le profil p
	f_9	M	0 ‡	Majeure	Taille de url_{t_i} (Damak <i>et al.</i> , 2013)
	f_{10}	M	0 †	Mineure	Taille de med_{t_i}
Auteur	f_{11}	M	945 *	Majeure	fol_{t_i} (Aisopos <i>et al.</i> , 2012)
	f_{12}	M	27689 *	Majeure	$stat_{t_i}$ (Cheng <i>et al.</i> , 2013; Aisopos <i>et al.</i> , 2012)
	f_{13}	M	759 *	Majeure	fr_{t_i} (Aisopos <i>et al.</i> , 2012)
	f_{14}	M	7 *	Mineure	$list_{t_i}$
	f_{15}	M	3166 *	Mineure	fav_{t_i}
	f_{16}	C	0.3 †	Mineure	Similarité Cosinus entre la description de l’auteur $desc_{t_i}$ et le profil p

4.3. Fonction de décision

Au final, la fonction de décision φ est définie de la manière suivante :

$$\varphi(t_i, p, \mathcal{T}_s, \mathcal{R}) = \begin{cases} \{rt_i\} & \text{si } CAC(p', CO'_{t_i}, \mathcal{T}_s) > \lambda_{CO} \text{ et } FBS(\mathcal{C}\mathcal{X}_{t_i}, p, \mathcal{R}) > \lambda_{CX} \\ \emptyset & \text{sinon} \end{cases} \quad (5)$$

où λ_{CO} et λ_{CX} sont les seuils associés au CAC et au FBS. Un tweet est alors retweeté si son contenu et son contexte sont tous les deux considérés suffisamment pertinents selon le profil utilisateur p ciblé.

Utiliser des valeurs appropriées pour λ_{CO} et λ_{CX} permet de répondre à **(P1)** et **(P4)**. Ces valeurs peuvent être fixes, ou peuvent évoluer avec le temps, comme proposé dans (L. Tan *et al.*, 2015). **(P2)** est pris directement en compte dans le calcul du CAC, puisque chaque tweet est comparé à l'ensemble des messages déjà retweetés \mathcal{T}_s (cf. Éq. 2). Pour répondre à **(P3)**, tout en conservant σ aussi faible que possible, le FBS est calculé uniquement si $CAC > \lambda_{CO}$.

5. Expérimentations

Nous avons choisi d'évaluer notre modèle dans le cadre des tâches Microblog 2015 et Real-Time Summarization 2016 de TREC (*Text REtrieval Conference*). Ces tâches correspondent très bien au problème que nous abordons car elles utilisent un flux de données temps-réel véritable, et l'objectif est d'envoyer des notifications à des utilisateurs selon leurs centres d'intérêt.

Nous avons instancié notre modèle pour répondre aux directives de ces tâches. Notre implémentation s'est concentrée sur le temps de réponse : ne jamais dépasser la minute quel que soit le nombre de tweets entrants. Le processus et son évaluation dans son ensemble n'impliquent à aucun moment une intervention humaine, ils sont complètement automatiques.

5.1. Présentation des tâches TREC Microblog 2015 et RTS 2016

En 2015, la tâche TREC Microblog³ s'intéresse aux problématiques de filtrage temps-réel. Deux scénarios ont été mis en place afin de répondre à des problématiques précises de filtrage temps-réel. L'idée principale du premier scénario (scénario A) était de simuler l'envoi de notifications sur téléphone mobile en temps-réel, tandis que le second (scénario B) était de créer un résumé par mail régulier à la fin de chaque journée, selon des profils utilisateurs (Lin *et al.*, 2015). Dans cet article nous nous concentrons uniquement sur le scénario A. Afin de simuler au mieux le concept de filtrage temps-réel, nous avons dû utiliser une API de Twitter pour collecter les données (le flux recueilli représente en fait 1% du flux global de Twitter) et ensuite les traiter au fur et à mesure de leur arrivée. Ce faible pourcentage est suffisant pour tester

3. <https://github.com/lintool/twitter-tools/wiki/TREC-2015-Track-Guidelines>, 2015

notre approche avec une moyenne de 3000 tweets collectés par minute (comparable aux systèmes de (Paik, Lin, 2015)). Quand les tweets arrivent, nous devons décider dès que possible (le laps de temps maximum pour retweeter un message proposé par TREC est fixé à 100 minutes, c'est-à-dire $\sigma < 6000$ secondes, cf. section 2) s'ils sont pertinents vis-à-vis d'un ou plusieurs profils utilisateurs. Pour éviter la surcharge de l'utilisateur, le nombre maximum de documents retweetés par centre d'intérêt et par jour ($\delta = 1$ jour) a été fixé à dix notifications (**P1**, $N = 10$, cf. section 2). La période officielle d'évaluation a duré dix jours sans interruption (concrètement, $\Delta = 10$ jours). Les profils utilisateurs ont un format TREC classique, c'est-à-dire composé d'un titre, une description et une partie narrative comme montré en figure 2. Considérant que dans la réalité il est difficile d'avoir une description de centres d'intérêt d'utilisateurs de plus de quelques mots, nous n'avons utilisé que la partie titre. TREC a fourni un ensemble de 225 centres d'intérêt à traiter au cours de la période d'évaluation, mais seulement 51 d'entre eux ont été jugés s. Toutes les requêtes n'ont pas eu le même nombre de tweets pertinents (entre 0 et 1543 selon le profil).

```

75 <top>
76 <num> Number: MB242
77 <title>
78 Saudi bombing Yemen
79 <desc> Description:
80 Find information related to any recent bombing raids by Saudi Arabia
81 against the Houthi of Yemen.
82 <narr> Narrative:
83 The user is interested in the ongoing war in Yemen, and the bombing
84 raids by the Saudi Air force against the Shea Houthi fighters in Yemen.
85 He is interested in the number of raids, targets, and damage assessments.
86 </top>

```

Figure 2. Exemple de requête type de TREC Microblog

La vérité terrain a été établie selon un processus en deux temps. Dans un premier temps, les tweets participant au *pool* ont été évalués comme très pertinents / pertinents / non pertinents. Ensuite, chaque tweet pertinent ou très pertinent a été affecté à un cluster unique. Un cluster peut être vu comme un groupe de tweets partageant la même information sémantique. Les clusters ont été construits selon la méthodologie TTG (*Tweet Timeline Generation*) qui prend en compte l'étiquette temporelle des tweets pour trier les tweets pertinents (Wang *et al.*, 2015). Dans cette méthodologie, les tweets sont examinés un par un du plus ancien au plus récent. Un nouveau cluster est créé si le tweet courant est considéré comme substantiellement différent de tous les autres tweets déjà affectés à des clusters. L'idée derrière la constitution des clusters est de pouvoir évaluer la nouveauté d'un tweet (**P2**).

Deux mesures d'évaluation ont été calculées pour chaque profil utilisateur et pour chaque jour. La première mesure est la ELG (*Expected Latency-discounted Gain*) :

$$ELG = \frac{1}{N} \sum G(t) \quad (6)$$

où N est le nombre de tweets retournés et $G(t)$ est le gain de chaque tweet (0 pour les tweets non pertinents, 0.5 pour les tweets pertinents, et 1 pour les tweets très per-

tinents). Un tweet est considéré comme pertinent ou très pertinent dans le calcul du gain si et seulement si il est contenu dans un des clusters sémantiques et qu'il est le premier tweet du cluster retourné par le système. En d'autres termes, les tweets redondants (c'est-à-dire appartenant au même cluster) sont considérés comme non pertinents. Tous les clusters sont considérés comme équivalents.

De plus, une pénalité liée au temps de réponse est appliquée à tous les tweets, calculée comme suit : $\text{MAX}(0, (100-d)/100)$ où d est le temps écoulé en minutes entre l'émission du tweet et sa notification finale. Cette valeur décroît linéairement de telle sorte qu'au bout de 100 minutes le système reçoive un score de 0 quelle que soit la pertinence du tweet renvoyé.

La seconde mesure est la nCG (*normalized Cumulative Gain*) :

$$nCG = \frac{1}{Z} \sum G(t) \quad (7)$$

où Z est le gain maximum (selon la limite de dix retweets par jour).

Un effet de bord des mesures concerne le score à attribuer aux systèmes les jours vides, c'est-à-dire les jours où aucun tweet pertinent n'est publié (**P4**). Ces jours sont également appelés jours silencieux. Il a été décidé que les systèmes reçoivent un gain de 1 durant les jours vides quand ils ne renvoient effectivement aucun tweet, et 0 sinon. Les jours vides sont donc cruciaux dans l'évaluation, un seul faux pas (c'est-à-dire un seul tweet retourné) entraînant un score de 0. En fonction des jours (vides ou pas), un seul tweet non pertinent entraîne respectivement un score de 0 ou une simple baisse de la mesure de qualité.

En 2016, la tâche TREC Microblog et la tâche TREC TS (*Temporal Summarization*) ont fusionné pour former la tâche TREC RTS (*Real-Time Summarization*). Le but de la tâche est resté inchangé – filtrage temps-réel d'information –, la fusion ayant pour seul but de renforcer les synergies entre les approches présentées dans les deux tâches d'origine.

Comme en 2015, la période officielle d'évaluation a duré dix jours sans interruption ($\Delta = 10$ jours), et pour éviter la surcharge de l'utilisateur, le nombre maximum de documents retweetés par centre d'intérêt et par jour ($\delta = 1$ jour) a de nouveau été fixé à dix notifications (**P1**, $N = 10$, cf. section 2). Deux grands types d'évaluation ont été menés : une évaluation temps-réel (*online*) pendant les 10 jours et une évaluation *batch* à la fin des 10 jours. Nous nous intéressons seulement à cette dernière, pour laquelle 56 profils ont été jugés.

Une différence notable entre 2015 et 2016 est le changement des mesures d'évaluation utilisées. La latence et la qualité (pertinence et nouveauté) des résultats sont maintenant évalués séparément (tout était auparavant intégré dans la mesure *ELG*). L'idée derrière cette séparation est de voir ce que chaque système privilégie dans son approche. D'autre part, comme le soulignent les organisateurs de la tâche, il est difficile de pénaliser correctement une métrique évaluant la qualité en fonction de la latence : quel est le retard que peuvent supporter les auditeurs pour être informés ? (Lin *et al.*, 2016).

L'évaluation de la *qualité* est toujours basée sur le gain, et la mesure principale de la tâche (EG - *Expected Gain*) est redéfinie comme suit:

$$EG = \frac{1}{N} \sum G(t) \quad (8)$$

où N est le nombre de tweets retournés et G(t) est le gain de chaque tweet (0 pour les tweets non pertinents, 0.5 pour les tweets pertinents, et 1 pour les tweets très pertinents).

La définition de nCG ne change pas.

Pour traiter les jours silencieux, les organisateurs ont défini deux variantes possibles des mesures :

- pour les variantes *EG-0* et *nCG-0*, les systèmes reçoivent un gain de 0 durant les jours vides, quel que soit le nombre de tweets retournés.
- pour les variantes *EG-1* et *nCG-1*, les systèmes reçoivent un gain de 1 durant les jours vides quand ils ne renvoient effectivement aucun tweet, et 0 sinon. C'est également ce qui avait été fait en 2015.

La mesure *EG-1* a été retenue comme mesure officielle de la tâche. Nous nous concentrons donc dans la suite de l'article sur les variantes *EG-1* et *nCG-1*.

Enfin, la *latence* est évaluée uniquement pour les tweets participant au gain comme la différence entre la date du retweet (ts_{rt_i}) et l'étiquette temporelle (*timestamp*) du premier tweet du cluster sémantique auquel il appartient. Pour avoir une bonne latence, il ne suffit donc pas pour un système de minimiser $\sigma = ts_{rt_i} - ts_{t_i}$, mais il faut aussi identifier le premier tweet de chaque cluster (**P2+P3**).

5.2. Instanciation du modèle pour répondre aux tâches TREC

Pour répondre aux directives définies pour les tâches TREC considérées, du point de vue du modèle sur le contenu, le même pré-traitement classique est appliqué sur les profils p ainsi que sur le contenu des tweets \mathcal{CO}_{t_i} : suppression des mots vides, uniformisation de la casse, et lemmatisation au moyen de l'algorithme de Porter (Porter, 1980).

Une détection de la langue est aussi effectuée afin de ne conserver que les messages écrits dans la même langue que les profils étudiés. Pour conserver σ le plus faible possible, et puisque les profils fournis pour la tâche ne concernent que très peu de tweets similaires durant la période Δ , la similarité $sim(\mathcal{CO}'_{t_i}, \mathcal{T}_s)$ n'a pas été considérée dans l'équation 2.

Au niveau du modèle contextuel, l'ensemble de ressources \mathcal{R} utilisé pour calculer \mathcal{CX}_{t_i} est composé de données Twitter collectées au cours des six semaines précédant la période officielle de traitement de la tâche TREC Microblog 2015. \mathcal{R} est utilisé pour fixer les seuils λ_{11} à λ_{15} associés aux caractéristiques f_{11} à f_{15} en calculant le troisième quartile des différentes caractéristiques en question. Les seuils pour les

caractéristiques restantes ont été déterminés manuellement par observation de leurs distributions ou encore selon l'état de l'art lié. Notons que \mathcal{R} est commun à tous les profils.

Au niveau des deux seuils globaux $\lambda_{c\mathcal{O}}$ et $\lambda_{c\mathcal{X}}$, associés à CAC et FBS, nous avons tout d'abord implémenté notre modèle avec plusieurs paires de valeurs ($\lambda_{c\mathcal{O}}$, $\lambda_{c\mathcal{X}}$). Dans un premier temps, $\lambda_{c\mathcal{X}}$ a été fixé à 5 (afin d'éliminer les tweets avec des contextes pauvres), puis nous avons testé notre modèle en faisant varier $\lambda_{c\mathcal{O}}$ de 0.1 à 0.9 par pas de 0.1. Dans un second temps, nous avons fixé $\lambda_{c\mathcal{O}}$ à 0.6 (qui est le meilleur seuil obtenu lors des tests précédents), puis nous avons testé notre modèle en faisant varier $\lambda_{c\mathcal{X}}$. Le cas particulier de $\lambda_{c\mathcal{X}}$ égal à 0 correspond à l'omission complète du contexte. Une seconde implémentation de notre modèle (variante avec *fenêtrage temporel*) prend en considération l'évolution dynamique des deux seuils $\lambda_{c\mathcal{O}}$ et $\lambda_{c\mathcal{X}}$ au cours du traitement des tweets, comme proposé dans (L. Tan *et al.*, 2015) par exemple, mais avec une différence significative. Nous avons travaillé sur la supposition (vérifiée) que le nombre de messages postés n'est pas régulier au cours de la journée, mais au contraire que des pics apparaissent chaque jour approximativement à la même heure. Afin de déterminer nos deux seuils $\lambda_{c\mathcal{O}}$ et $\lambda_{c\mathcal{X}}$ pour un créneau horaire particulier du jour en cours, nous récoltons les données du même créneau horaire des jours précédents. Chaque heure, les seuils sont mis à jour grâce aux données (CAC et FBS) des jours précédents durant cette heure précise avec un poids plus important pour la veille. Concrètement, $\lambda_{c\mathcal{O}}$, respectivement $\lambda_{c\mathcal{X}}$, est mis à jour par la moyenne entre le dernier $\lambda_{c\mathcal{O}}$, respectivement $\lambda_{c\mathcal{X}}$, et le premier quartile des valeurs de CAC, respectivement FBS, de la veille, dans l'ensemble \mathcal{T}_s . Ce principe donne une importance plus grande au jour précédent qu'à l'ensemble des jours encore antérieurs.

Comme présenté en section 5.1, la mesure d'évaluation ELG comprend une pénalité liée au temps de réponse du système depuis la première minute jusqu'à la centième. Afin de pleinement répondre à (P3) et de ne pas être pénalisés en termes d'ELG, nous avons fixé notre propre temps de réponse maximum σ à 60 secondes.

5.3. Résultats dans le cadre de TREC Microblog 2015

Un premier résultat notable concerne notre objectif d'efficacité (P3), qui était d'envoyer chaque notification en moins d'une minute ($\sigma < 60$), et qui a été pleinement atteint. En effet, même au cours des périodes à forte affluence de tweets, un message estimé pertinent a été retweeté en un maximum de 5 secondes ($\sigma < 5$). De plus, le processus complet a été bien plus rapide qu'escompté puisque ce σ a été calculé alors que le modèle traitait simultanément les 225 profils utilisateurs et non pas un seul. Ceci autorise d'inclure d'autres traitements sur le flux de tweets dans notre modèle, comme des caractéristiques supplémentaires dans le modèle sur le contexte. De plus, une parallélisation du traitement par groupe de profil voire par profil pourrait accroître l'efficacité de notre modèle.

D'un point de vue efficacité, le tableau 2 résume certains des résultats les plus représentatifs obtenus avec notre modèle CBM (*Context-Based Model*) pour les me-

sures d'évaluation ELG et nCG. Notre modèle a été également comparé au système ayant eu les meilleurs résultats à la tâche TREC Microblog 2015 (*UWaterloo*) soumis par l'Université de Waterloo (L. Tan *et al.*, 2015) ainsi que le système *Vide*, qui ne renvoie aucun tweet pendant toute la période d'évaluation ($\mathcal{T}_s = \emptyset$). Étant donné qu'il existe un nombre non négligeable de jours au cours desquels certains profils n'ont pas eu de tweets pertinents associés, ce système obtient des résultats élevés. Les résultats pour notre approche CBM sont divisés en plusieurs catégories : la première partie est relative aux différentes valeurs prises par $\lambda_{c\mathcal{O}}$, et la seconde est relative à celles de $\lambda_{c\mathcal{X}}$ (cf. section 5.2). Les valeurs entre crochets correspondent aux valeurs de $\lambda_{c\mathcal{O}}$, respectivement $\lambda_{c\mathcal{X}}$. CBM_d correspond à la variante du modèle simulant une expansion de requête grâce à la partie description des profils fournis par TREC. CBM_tw correspond à la variante qui teste le *fenêtrage temporel* pour la mise à jour progressive des seuils globaux (cf. section 5.2). Tous les autres tests de CBM ont été effectués avec des seuils globaux fixes.

Tableau 2. Performances de notre modèle. Le T-test pairé bilatéral par rapport au système vide est indiqué par *, indiqué par † par rapport au meilleur run officiel TREC de l'Université de Waterloo (*UWaterloo*) et indiqué par ‡ par rapport au système sans prise en compte du contexte (correspondant à CBM[0.6;0]). Un seul symbole montre une différence significative (p -value < 0.05) et deux une différence très significative (p -value < 0.01).

Run	ELG	nCG
Système Vide	0.2471 †† ‡‡	0.2471
UWaterloo	0.3150 **	0.2679
CBM [0.4;5]	0.2381 †† ‡‡	0.2363 ‡
CBM [0.5;5]	0.3049 **	0.2891 *
CBM [0.6;5]	0.3145 **	0.2917 **
CBM [0.7;5]	0.2525 † ‡	0.2486
CBM_d [0.6;5]	0.3078 **	0.2480
CBM [0.6;0]	0.2902 **	0.2798
CBM [0.6;3]	0.2943 **	0.2824 *
CBM [0.6;8]	0.2996 **	0.2872 *
CBM [0.6;10]	0.2758	0.2680
CBM_tw	0.2764	0.2630

La première conclusion émanant de ce tableau est que pratiquement toutes les versions de notre modèle surpassent significativement la baseline du système *Vide*, nous permettant ainsi de répondre à (P4). Dans un deuxième temps, la variante de CBM atteignant le meilleur résultat (parmi toutes les variantes testées) correspond aux seuils globaux $\lambda_{c\mathcal{O}} = 0.6$ pour CAC et $\lambda_{c\mathcal{X}} = 5$ pour FBS. Ce dernier égale pratiquement le meilleur système officiel automatique de TREC selon ELG et le dépasse au niveau de nCG. De plus, les résultats montrent l'efficacité du modèle contextuel. En effet, à traitement égal sur le contenu (même valeur de $\lambda_{c\mathcal{O}}$ égale à 0.6), la non prise en

compte du contexte (qui équivaut à $\lambda_{cx} = 0$) donne une efficacité bien inférieure ($\sim -9\%$). En revanche, l'extension des profils à partir de la description des requêtes TREC uniquement (run CBM_d) ne permet pas d'améliorer le modèle.

Une autre conclusion est que lorsque notre modèle est trop restrictif, c'est-à-dire avec des seuils trop élevés, l'efficacité décroît de nouveau. À l'inverse, si notre modèle est trop permissif, de trop nombreux tweets non pertinents sont retransmis et l'efficacité est une fois encore réduite. La plupart des tests de significativité présentés ici ne sont pas statistiquement concluant, mais cela peut s'expliquer par le très grand nombre de requêtes obtenant le même score d'un modèle à l'autre à cause du faible nombre de retweets qui leur sont associés. Des différences significatives ne sont observables que sur les requêtes ayant un nombre élevé de notifications pertinentes.

La variante du modèle utilisant les fenêtres temporelles n'améliore pas non plus l'efficacité (run CBM_tw). De manière plus approfondie, les profils avec peu de tweets pertinents sont trop fortement détériorés, tandis que dans le même temps les autres ne profitent pas d'une amélioration suffisante. Un tel comportement pourra certainement être amélioré avec des seuils adaptés à chaque profil utilisateur plutôt que d'utiliser le même seuil tous profils confondus. Nous étudierons cette piste dans de futurs travaux.

Une analyse de l'impact des différents groupes de caractéristiques (c'est-à-dire Qualité, Entités et Auteur) sur le modèle contextuel global pour la configuration la plus efficace (run CBM[0.6;0] du tableau 2) a montré l'intérêt d'appliquer le modèle contextuel complet (comprenant donc Qualité, Entités et Auteur). Celui-ci a en effet produit les meilleurs résultats par rapport aux autres combinaisons possibles de groupes de caractéristiques. Le lecteur intéressé par cette analyse pourra trouver des détails dans (Palmer *et al.*, 2017).

5.4. Analyse par type de profil

En analysant les évaluations de pertinence des centres d'intérêts fournis, nous avons pu différencier 5 catégories de profils utilisateurs selon la fréquence d'arrivée des tweets pertinents associés. La première catégorie C1 rassemble les profils avec très peu de tweets pertinents (moins de 20 au cours des 10 jours d'évaluation). C2 est caractérisée par 2 pics de messages pertinents, un au début et l'autre à la fin de la période, tandis que le début de C3 est quasiment vide puis des pics réguliers apparaissent par la suite. C4 quant à elle est caractérisée par un très fort pic au commencement puis seulement quelques messages pertinents arrivent sur le reste de l'évaluation, tandis que C5 voit arriver des pics réguliers au cours de l'ensemble de la période évaluée. Les résultats par catégorie de requêtes sont présentés dans le tableau 3.

Notre approche est efficace pour les profils avec peu de tweets pertinents (C1) mais semble être trop restrictive pour les requêtes ayant un ensemble de résultats plus grand. Par exemple, ces résultats pourraient être améliorés d'environ 36% pour le profil intitulé MB371 (de la catégorie C4) en abaissant le seuil global du contenu. De

Tableau 3. Résultats par catégories de profils utilisateurs

	Catégories				
	C1	C2	C3	C4	C5
Nombre de Profils	21	5	10	7	8
ELG	0.56	0.09	0.13	0.10	0.24
nCG	0.55	0.05	0.08	0.09	0.19

futurs travaux tendront à adapter les seuils à chaque requête ou au moins à chaque catégorie de requêtes préalablement détectée.

5.5. Résultats dans le cadre de TREC Real-Time Summarization 2016

Afin de valider nos observations dans un autre cadre, nous avons appliqué notre approche dans le cadre de la tâche TREC Real-Time Summarization 2016.

Le tableau 5 montre les résultats de notre run officiel en 2016, correspondant à notre meilleure configuration en 2015 (CBM[0.6;5] en considérant tous nos groupes de caractéristiques). Comme en 2015, ce run est comparé au run vide (c'est-à-dire au run correspondant à un système ne renvoyant jamais rien). Un tel système obtient un score relativement élevé sur les mesures *EG-1* et *nCG-1* car le score maximal est attribué au système sur les jours vides. Les mesures de latence moyenne et de temps de retweet moyen sont également indiquées dans le tableau. Ces mesures, non fournies par les organisateurs de la tâche en 2015, font partie des mesures officielles en 2016.

Tableau 4. Performances de notre modèle, par rapport au meilleur run officiel TREC de l'université Polytechnique de Hong Kong (PolyU), et par rapport à la baseline fournie par les organisateurs de l'université de Waterloo. Le temps de retweet moyen et la latence moyenne sont exprimées en secondes

Runs	EG-1	nCG-1	Tweets renvoyés	Temps de retweet moyen	Latence moyenne
PolyU	0.2698	0.2909	443	14	91549
Système Vide	0.2339	0.2339	0	–	–
Baseline	0.2289	0.2330	576	44	120909
CBM	0.2181	0.2317	1059	14	123013

Un premier constat est que notre temps de retweet moyen est de 14 secondes. Il s'agit du deuxième meilleur temps de retweet moyen (le meilleur étant 13 secondes) sur l'ensemble des participations officielles. Ceci confirme la grande réactivité de

notre système⁴. Par ailleurs, du point de vue de la mesure de latence moyenne, notre système se classe 15^e sur les 42 participations. La latence, telle que définie pour la tâche, est calculée par rapport au premier tweet pertinent de chaque cluster et est donc dépendante de l'efficacité du système. La valeur est donc à mettre en perspective des mesures d'efficacité.

Concernant les mesures d'efficacité, nous constatons que le run vide est meilleur que la baseline Waterloo, ce qui n'était pas le cas pour le run équivalent en 2015. Les jours vides sont donc cruciaux pour l'évaluation. Un gros impact de ces jours vides par rapport aux jours contenant de l'information pertinente a d'ailleurs été observé dans le classement final des systèmes (L. Tan *et al.*, 2016).

De plus, et de façon assez surprenante, les résultats obtenus par notre approche sont loin de ceux constatés en 2015. Ceci peut être en partie imputé à la proportion plus faible de profils de catégorie C1 (cf. section 5.4) pour laquelle notre approche était plus performante. Afin d'expliquer ces performances, nous avons effectué en complément une étude poussée du comportement de la mesure officielle *EG-1*.

5.6. Analyse de la mesure d'évaluation officielle *EG-1*

En regardant les caractéristiques des runs classés au-dessus du système vide dans les participations officielles (Lin *et al.*, 2016), nous avons remarqué que ces systèmes avaient la particularité de renvoyer peu de tweets (en moyenne 309 tweets pour les 16 runs au-dessus du système vide contre 1224 tweets pour les 25 runs en-dessous).

Autoriser 10 tweets par jour ($N = 10$, $\Delta = 1$) est une limite arbitraire posée par les organisateurs de la tâche. Nous nous sommes donc demandés dans quelle mesure faire varier N impactait $EG - 1$.

La figure 3 et le tableau 5 montrent l'évolution des performances en faisant varier le nombre n maximum de tweets renvoyés par chaque système (ce qui revient donc à faire varier N). Nous avons considéré chaque fois les n premiers tweets de chaque système, c'est-à-dire les n premiers par date de publication. Ceci correspond à un scénario relativement défavorable pour les systèmes, les n choisis n'étant pas forcément ceux parmi les N d'origine qui auraient été renvoyés ou qui maximiseraient la mesure d'évaluation. Si moins de n tweets ont été renvoyés par un système un jour donné, pour ce jour-là l'évaluation est similaire à celle d'origine.

On voit clairement que moins les systèmes renvoient de tweets, plus la mesure *EG-1* augmente, et ce sans aucune garantie que les tweets conservés sont pertinents. Ceci peut être expliqué par le fait que le gain est divisé chaque jour par le nombre de tweets renvoyés par le système, et donc par le fait qu'*EG-1* est une mesure très orientée précision. La couverture des clusters sémantiques n'est jamais évaluée par la mesure,

4. Le lecteur pourrait s'interroger sur l'ordre de grandeur par rapport au 5 secondes relevés dans le cadre 2015. Nous attribuons cette différence au temps de réaction du broker fourni par les organisateurs et chargé de transmettre les tweets aux évaluateurs.




Figure 3. Mesure d'évaluation EG-1 en fonction du nombre de tweets renvoyés. Seuls les n premiers tweets des runs sont conservés chaque fois

Tableau 5. Performances (mesure EG-1) des approches en fonction du nombre de tweets renvoyés. Seuls les n premiers tweets sont chaque fois conservés

n	PolyU	Baseline	CBM
10	0,2698	0,2289	0,2181
9	0,2698	0,2290	0,2184
8	0,2705	0,2291	0,2190
7	0,2707	0,2292	0,2197
6	0,2729	0,2309	0,2203
5	0,2735	0,2306	0,2206
4	0,2749	0,2305	0,2215
3	0,2769	0,2308	0,2189
2	0,2768	0,2335	0,2223
1	0,2839 (+5,18 %)	0,2357 (+2,97 %)	0,2277 (+4,40 %)

ce qui provoque un biais certain dans l'évaluation, pouvant être facilement exploité par les participants à la tâche. Ce biais existait déjà en 2015 mais de manière moins visible. Pour optimiser la mesure EG-1, il est préférable de renvoyer peu de tweets probablement pertinents. Essayer d'optimiser la couverture des clusters sémantiques (c'est-à-dire le rappel) provoquera très probablement une dégradation des résultats (dégradation d'autant plus forte que rompre le silence les jours vides est fortement pénalisé avec un score de 0).

5.7. Vérification de notre intuition sur la tâche TREC 2017

Afin de vérifier si ce biais est avéré, nous avons décidé d'envoyer un run très simple à la campagne d'évaluation 2017, similaire en tous points à celle de 2016. Pour chaque profil, nous avons renvoyé le premier tweet par jour contenant tous les termes décrivant le profil (Hubert *et al.*, 2017). Cet algorithme naïf nous a permis d'obtenir la 2^e place (sur 40) pour l'évaluation *online* et la 4^e place pour l'évaluation *batch* (Lin *et al.*, 2017). Notons que les trois premiers runs ont une latence médiane très élevée (53893 secondes en moyenne), et donc ne respectent pas **P3**, alors que la nôtre est seulement de 1 seconde. Il nous semble donc que toutes les approches utilisant ces collections de référence pour l'évaluation devraient commencer par comparer leurs résultats avec une simple *baseline* composée d'un tweet au maximum par jour (avant même de se comparer aux participations officielles).

6. Conclusion et évolutions

Les contributions de cet article sont les suivantes :

- nous avons proposé un nouveau modèle non supervisé basé sur le contexte pour des systèmes de recommandation de retweet (comptes portails). Une des caractéristiques principales de ce modèle est sa capacité à écouter en temps-réel le flux Twitter tout en conservant un temps de retweet très faible. Nous avons également montré son efficacité sur des profils utilisateurs atypiques, intéressés par peu de tweets.
- nous avons identifié un biais dans l'évaluation des campagnes TREC 2016 et 2017, montrant que la couverture des profils utilisateurs n'était jamais évaluée. Les systèmes doivent renvoyer peu de tweets pour obtenir de bonnes performances. Cette découverte plaide pour un travail approfondi sur les mesures d'évaluation possibles dans ce cadre.

Une analyse plus en profondeur des résultats nous indique certaines pistes pour l'amélioration de notre modèle. En premier lieu, nous devrions poursuivre nos analyses sur chacune de nos caractéristiques de contexte f_i , leur impact sur le modèle global et les interactions qui les relient. Ensuite, les résultats des analyses d'ores et déjà conduites semblent montrer que les seuils devraient être fixés selon chacun des différents types de requêtes ; leur classification nous aidera à améliorer les résultats.

Remerciements

Nous remercions nos collègues Jose G. Moreno et Yoann Pitarch pour nos discussions et travaux sur les biais de l'évaluation TREC RTS.

Bibliographie

- Aisopos F., Papadakis G., Tserpes K., Varvarigou T. (2012). Content vs. context for sentiment analysis: A comparative analysis over microblogs. In *Proceedings of international conference HT'12*, p. 187–196. Consulté sur <http://doi.acm.org/10.1145/2309996.2310028>

- Amigó E., Albornoz J. Carrillo de, Chugur I., Corujo A., Gonzalo J., Martín T. *et al.* (2013). Overview of replab 2013: Evaluating online reputation monitoring systems. *Information Access Evaluation. Multilinguality, Multimodality, and Visualization*, p. 333–352. Consulté sur http://dx.doi.org/10.1007/978-3-642-40802-1_31
- Cheng F., Zhang X., He B., Luo T., Wang W. (2013). A Survey of Learning to Rank for Real-time Twitter Search. In *Proceedings of Joint Int. Conf. ICPCA/SWS'12*, p. 150–164. Consulté sur http://dx.doi.org/10.1007/978-3-642-37015-1_13
- Damak F., Pinel-Sauvagnat K., Boughanem M., Cabanac G. (2013). Effectiveness of State-of-the-art Features for Microblog Search. In *Proceedings of Int. Conf. SAC'13*, p. 914–919.
- Efron M. (2010). Hashtag Retrieval in a Microblogging Environment. In *Proceedings of Int. Conf. SIGIR'10*, p. 787–788.
- Fan F., Fei Y., Lv C., Yao L., Yang J., Zhao D. (2015). PKUICST at TREC 2015 Microblog Track: Query-biased Adaptive Filtering in Real-time Microblog Stream. In *Proceedings of Int. Conf. TREC'15*.
- Guille A., Favre C. (2014). Mention-anomaly-based Event Detection and Tracking in Twitter. In *Proceedings of Int. Conf. ASONAM'14*, p. 375–382.
- Hubert G., Moreno J. G., Pinel-Sauvagnat K., Pitarch Y. (2017). Some thoughts from IRIT about the scenario A of the TREC RTS 2016 and 2017 tracks. In *36th Text REtrieval Conference (TREC 2017)*.
- Jabeur L. B., Tamine L., Boughanem M. (2012). Featured tweet search: Modeling time and social influence for microblog retrieval. In *Proceedings of Int. Joint Conf. WI-IAT'12*, vol. 1, p. 166–173.
- Kywe S. M., Lim E.-P., Zhu F. (2012). A survey of recommender systems in twitter. In *International Conference on Social Informatics*, p. 420–433.
- Lin J., Efron M., Wang Y., Sherman G., Voorhees E. (2015). Overview of the TREC-2015 Microblog Track. In *Proceedings of Int. Conf. TREC'15*.
- Lin J., Mohammed S., Sequiera R., Tan L., Ghelani N., Abualsaud M. *et al.* (2017). Overview of the TREC 2017 Real-Time Summarization Track (Notebook Draft). In *36th Text REtrieval Conference (TREC 2017)*.
- Lin J., Roegiest A., Tan L., McCreadie R., Voorhees E., Diaz F. (2016). Overview of the TREC 2016 real-time summarization time. In *35th Text REtrieval Conference (TREC 2016)*.
- Paik J. H., Lin J. (2015). Do Multiple Listeners to the Public Twitter Sample Stream Receive the Same Tweets? In *Proceedings of Int. Conf. SIGIR'15*.
- Palmer T., Hubert G., Pinel-Sauvagnat K. (2017). Retweeter ou ne pas retweeter : Le dilemme des portails de diffusion d'information temps-réel. In *Coria 2017 - conférence en recherche d'informations et applications- 14th french information retrieval conference. marseille, france, march 29-31, 2017.*, p. 123-138.
- Pontiki M., Galanis D., Papageorgiou H., Androutsopoulos I., Manandhar S., Mohammad A.-S. *et al.* (2016). Semeval-2016 task 5: Aspect based sentiment analysis. In *Proceedings of the 10th international workshop on semantic evaluation (SemEval-2016)*, p. 19–30.
- Porter M. F. (1980). An algorithm for suffix stripping. *Program*, vol. 14, n° 3, p. 130–137.

- Suwaileh R., Hasanain M., Elsayed T. (2016). Light-weight, Conservative, yet Effective: Scalable Real-time Tweet Summarization. In *35th Text REtrieval Conference (TREC 2016)*.
- Takemura H., Tajima K. (2012). Tweet Classification Based on Their Lifetime Duration. In *Proceedings of Int. Conf. CIKM'12*, p. 2367–2370. Consulté sur <http://doi.acm.org/10.1145/2396761.2398642>
- Tan H., Luo D., Li W. (2016). PolyU at TREC 2016 Real-Time Summarization. In *35th Text REtrieval Conference (TREC 2016)*.
- Tan L., Roegiest A., Clarke C. L. A. (2015). University of Waterloo at TREC 2015 Microblog Track. In *Proceedings of Int. Conf. TREC'15*.
- Tan L., Roegiest A., Lin J., Clarke C. L. (2016). An exploration of evaluation metrics for mobile push notifications. In *Proceedings of the 39th Int. Conf. ACM SIGIR*, p. 741–744.
- Wang Y., Sherman G., Lin J., Efron M. (2015). Assessor differences and user preferences in tweet timeline generation. In *Proceedings of the 38th International Conference ACM SIGIR*, p. 615–624.
- Zhao X., Tajima K. (2014). Online Retweet Recommendation with Item Count Limits. In *Proceedings of Joint Int. Conf. WI-IAT'14*, p. 282–289.
- Zhu X., Huang J., Zhu S., Chen M., Zhang C., Zhenzhen L. *et al.* (2015). NUDTSNA at TREC 2015 Microblog Track: A Live Retrieval System Framework for Social Network based on Semantic Expansion and Quality Model. In *Proceedings of Int. Conf. TREC'15*.