

Recherche de sentiments opposés par une approche floue à partir de textes libres

Haoyuan Li, Anne Laurent, Mathieu Roche, Pascal Poncelet

► **To cite this version:**

Haoyuan Li, Anne Laurent, Mathieu Roche, Pascal Poncelet. Recherche de sentiments opposés par une approche floue à partir de textes libres. LFA'08 : Rencontres Francophones sur la Logique Floue et ses Applications, pp.26-33, 2008. <lirmm-00324587>

HAL Id: lirmm-00324587

<https://hal-lirmm.ccsd.cnrs.fr/lirmm-00324587>

Submitted on 28 Mar 2009

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.

Recherche de sentiments opposés par une approche floue à partir de textes libres

A fuzzy approach for determining opposite sentiments from free text

Dong (Haoyuan) Li¹

Anne Laurent²

Mathieu Roche²

Pascal Poncelet¹

¹ LGI2P - École des Mines d'Alès

² LIRMM - CNRS UMR 5506 - Université Montpellier 2

Parc Scientifique Georges Besse, 30035 Nîmes cedex 1, France

161 rue Ada, 34392 Montpellier cedex 5, France

Résumé :

Un grand nombre de travaux autour de la fouille d'opinions se sont focalisés sur la détection des orientations d'opinion exprimées dans des contenus textes. Même si ces orientations sont déterminantes, le décideur est également de plus en plus intéressé par des remarques qui sont représentatives d'un sentiment opposé de l'orientation du texte. Par exemple, un texte notant globalement positivement un hôtel peut toutefois contenir un sentiment opposé (négatif) sur un point précis (e.g. le petit-déjeuner). Or ces sentiments opposés sont exprimés en langage naturel et ne peuvent pas être décrits par des méthodes strictes. Dans cet article, nous introduisons donc le problème de la recherche automatique de sentiments opposés dans des textes libres avec des mesures floues. Nous proposons deux méthodes floues, *Local-Fuzzy* et *Global-Fuzzy*, pour déterminer le niveau sémantique des sentiments opposés en partitions floues. Les résultats des expérimentations menées sur des bases réelles d'avis de films montrent l'utilité de notre approche.

Mots-clés :

Fouille d'opinions, sentiments opposés, partition floue, croyances, règles séquentielles, motifs séquentiels.

Abstract:

Most research in opinion mining has been focused on the classification of opinion orientations expressed in text content. Although this classification is useful and important, the sentiments opposite to the opinion expressed in text content are more and more interesting for the decision makers. On the other hand, such opposite sentiments often contain imprecise information and cannot be described by crisp methods. In this paper we introduce the problem of determining opposite sentiments in free format text content with fuzzy measures. We propose two fuzzy methods, called *Local-Fuzzy* and *Global-Fuzzy*, for determining the semantic strength of opposite sentiments within different fuzzy membership partitions. The experimental results on movie review data show the usefulness and accuracy of our approach.

Keywords:

Opinion mining, opposite sentiments, fuzzy partition, beliefs, sequential rules, sequential patterns.

1 Introduction

Ces dernières années, un grand nombre d'approches sur la fouille d'opinions ont été proposées autour de la détection des orientations d'opinion exprimées dans des contenus textuels [2, 7, 10, 16]. Les opinions sont distinguées selon qu'elles sont positives ou négatives. L'extraction d'orientation d'opinion est généralement considérée dans le cadre de traitement algorithmique du langage naturel (TALN), où la connotation positive ou négative est annotée par des termes subjectifs au niveau du document [2, 9, 16] ou de la phrase [2, 7, 17]. Si la découverte d'opinion d'un texte est primordiale pour le décideur, il n'en reste pourtant pas moins que ce dernier est de plus en plus intéressé par des remarques qui sont représentatives d'un sentiment opposé de l'opinion exprimée dans le texte. Avec de tels sentiments opposés, il devient, par exemple, possible d'améliorer les produits, de maintenir les avantages, ou de comparer des caractéristiques entre des produits.

D'autre part, les intérêts de sentiments opposés sont différents. En effet, pour la décision, les sentiments opposés relativement forts sont souvent plus intéressants que ceux relativement faibles. Par exemple, dans un film moyen, un mauvais acteur peut être plus acceptable que dans un bon film, et évidemment pour le "bon film" les remarques sur cet ac-

teur sont plus critiques. Pourtant, de telles opinions sont sémantiquement subjectives et contiennent donc des informations imprécises. Une méthode floue est donc utile pour mesurer le niveau des tels sentiments opposés. L’opinion du texte peut être automatiquement classifiée en degrés flous au lieu d’être obligatoirement saisie par l’utilisateur, et la sémantique du sentiment opposé peut ensuite être mesurée relativement à l’orientation d’opinion globale.

Dans cet article, nous introduisons le problème de détection de sentiments opposés dans des textes libres avec des méthodes floues. En premier lieu, nous proposons une formalisation générale des textes, et montrons après que les orientations d’opinion exprimées dans de tels textes peuvent être résumées en divers modèles de croyances. Une phrase qui viole une croyance construite depuis ces modèles représente une phrase inattendue et exprime donc un sentiment opposé dans le texte. Nous proposons de plus deux méthodes floues, nommées *Local-Fuzzy* et *Global-Fuzzy*, pour déterminer la puissance sémantique des sentiments opposés par rapport aux partitions floues. Notre approche est évaluée par des revues de films disponibles en ligne.

Cet article s’organise de la manière suivante. Dans la section 2, nous proposons les formalisations relatives à la problématique. Dans la section 3, nous proposons notre approche floue pour découvrir les sentiments opposés. La section 4 détaille les algorithmes puis montre nos résultats expérimentaux sur des bases d’avis de films. Enfin, la section 5 conclut sur les perspectives de nos travaux.

2 Modèle de données

Étant donné un ensemble de textes au format libre ayant une polarité positive ou négative, chaque texte consiste en une liste ordonnée de phrases, et chaque phrase consiste en une liste ordonnée de mots. Nous associons un tag Part-of-Speech (tag PoS) considéré dans l’approche TreeTagger [13] avec chaque mot, une liste de

tels tags est disponible dans [12]. Par ailleurs, contrairement à [12], nous considérons de la même manière les différents types d’adjectifs (J au lieu de JJ , JJR et JJS), d’adverbes (R au lieu de R , RB , RBR et RBS), de noms (N au lieu de N , NN , NNS , NP et NPS) et de verbes (V au lieu de V , VB , VBD , VBG , VBN , VBP et VBZ).

Soit un ensemble de mots, on nomme *mot* v le lemme du mot associé avec son tag PoS. Par exemple, le verbe “is” est considéré comme le mot ($be|V$), où le lemme de “is” est “be” et “V” est le tag PoS de verbe. Nous ne considérons que des adjectifs, adverbes, noms et verbes dans notre approche, et laissons donc tous les autres tags PoS vides, par exemple, nous notons simplement ($this|DT$) comme ($this$) puisque nous ne nous considérons pas le tag DT . “*” est utilisé pour nommer un *mot généralisé*, et en particulier on nomme (NEG) des adjectifs ou adverbes de négation. Par exemple, ($*|V$) représente un verbe ; (NEG) peut être ($not|R$), ($n’t|R$) ou même ($never|R$). Par défaut, les adjectifs ou adverbes de négation (NEG) ne sont pas inclus dans le terme *mot*.

Soit $\mathcal{V} = \{v_1, v_2, \dots, v_n\}$ un ensemble de mots distincts, une *clause* s est une liste ordonnée de mots $v_1 v_2 \dots v_k$. Si une clause contient des mots généralisés, alors on dit que c’est une *clause généralisée*. Par exemple, ($film|N$)($be|V$)($good|J$) est une clause, mais ($film|N$)($be|V$)($*|J$) est une clause généralisée. La *longueur* d’une clause, notée $|s|$, est le nombre de mots contenus dans la clause. Un mot peut être de longueur 1 si la clause est réduite à un lemme avec son tag PoS associé. Une *clause vide* est notée \emptyset , on a $s = \emptyset \iff |s| = 0$. La *concaténation* des clauses est notée sous la forme $s_1 \cdot s_2$. Par exemple, on a ($film|N$)($be|V$) \cdot ($good|J$) = ($film|N$)($be|V$)($good|J$) et cette dernière est une clause avec l’ordre ($film|N$) suivi par ($be|V$) puis suivi par ($good|J$).

Nous considérons une *relation d’inclusion* entre des clauses. Une relation d’inclusion est un ordre

partiel \preceq sur des clauses, on dit que s est incluse dans s' si $s \preceq s'$. Cette relation est monotone : soient deux clauses $s = v_1 v_2 \dots v_m$ et $s' = v'_1 v'_2 \dots v'_n$, s'il existe des entiers $1 \leq i_1 < i_2 < \dots < i_m \leq n$ tels que $v_i = v'_{i_i}$ pour tous les v_i , alors s est incluse dans s' , notée $s \preceq s'$. Si on a $s \preceq s'$, on dit que s est une *sous-clause* de s' , ou s' *supporte* s . Au sein du contexte de la fouille de motifs séquentiels [1], un mot est un *item* et une clause est une *séquence*. Nous étendons la relation d'inclusion entre des mots et des mots généralisés. Soient un mot $v = (L|T)$ et un mot généralisé $v' = (* : T_g)$, si $T = T_g$ alors nous notons $v \preceq v'$. Par exemple, nous avons les relations ci-dessous :

- $(film|N)(good|J) \preceq (film|N)(be|N)(good|J)$,
- $(film|N)(good|J) \preceq (*|N)(good|J)$,
- $(film|N)(good|J) \preceq (*|N)(*|J)$,
- $(film|N)(good|J) \not\preceq (be|N)(good|J)(film|N)$,
- $(film|N)(good|J) \not\preceq (*|N)$.

Une *phrase*, notée S , est une clause maximale qui se termine par un des caractères suivants “ ; ; . ? ! ” dans le texte. Un *document*, noté \mathcal{D} , est une liste ordonnée de phrases. Soit un document \mathcal{D} , le *support* ou la *fréquence* d'une clause s , noté $\sigma(s, \mathcal{D})$, correspond au nombre total de phrases $S \in \mathcal{D}$ telles que S supporte s . Avec un seuil de support défini par l'utilisateur nommé le *support minimum*, noté min_supp , une clause est *fréquente* si on a $\sigma(s, \mathcal{D}) \geq min_supp$.

(1) *This film is nice. I like all nice views. It is really nice!*

$$\begin{aligned} s_{1.1} &= (this)(film|N)(be|V)(nice|J) \\ s_{1.2} &= (i)(like|V)(all)(nice|J)(views|N) \\ s_{1.3} &= (it)(be|V)(really|R)(nice|J) \end{aligned}$$

Le texte (1) peut être transformé en phrases $s_{1.1}$, $s_{1.2}$ et $s_{1.3}$. Étant donné un support minimum 0.5, nous avons deux clauses fréquentes : $(be|V)(nice|J)$ avec 0.67 et $(nice|J)$ avec 1.

Nous notons M^+ le sentiment positif et M^- le sentiment négatif, alors un sentiment $M \in \{M^+, M^-\}$ peut être exprimé dans un document (noté $\mathcal{D} \models M$), dans une phrase (noté $S \models M$), dans une clause (noté $s \models M$) ou

également dans un mot (noté $v \models M$). Nous notons \overline{M} la négation d'un sentiment M . Ainsi nous avons $\overline{M^+} = M^-$ et $\overline{M^-} = M^+$. Cette négation de sentiment a été prise en compte dans de nombreuses applications de fouille de textes (e.g. l'extraction de synonymes et d'antonymes [15]). Nous avons donc :

Proposition 1. *Soient un sentiment $M \in \{M^+, M^-\}$ et un document $\mathcal{D} \models M$, alors il existe au moins une phrase $S \in \mathcal{D}$ telle que $S \models M$; soit une phrase $S \models M$, alors il existe au moins un vocabulaire $v \preceq S$ tel que $v \models M$, ou au moins une clause $(NEG) \cdot v \preceq S$ (ou $v(NEG) \cdot \preceq S$) telle que $v \models \overline{M}$.*

Traditionnellement, l'orientation des opinions est souvent détectée par rapport aux adjectifs [4, 15]. Nous retenons ce principe dans notre approche et considérons que les sentiments sont exprimés par des adjectifs tels que “*this is a good film*”. Ainsi des sentiments exprimés via une phrase (e.g. “*this film is well produced*”) ne sont pas pour l'instant considérés dans notre approche.

3 Sentiments opposés

Nous représentons les orientations des sentiments à partir de règles séquentielles. Une *règle séquentielle*, notée r , est une règle sous la forme $s_\alpha \rightarrow s_\beta$, où s_α et s_β sont deux clauses. Soient une clause s et une règle $r = s_\alpha \rightarrow s_\beta$, si on a $s_\alpha \cdot s_\beta \preceq s$, alors on dit que la clause s supporte la règle r , notée comme $s \models r$.

(2) *It's a wonderful film!*

$$s_2 = (it)(be|V)(a)(wonderful|J)(film|N)$$

(3) *Seems to be very awful.*

$$s_3 = (seem|V)(to)(be|V)(very|R)(awful|J)$$

On a deux phrases s_2 et s_3 à partir des textes (2) et (3). Soit une règle séquentielle $r = (be|V) \rightarrow (wonderful|J)$, alors on a $s_2 \models r$ et $s_3 \not\models r$. Une règle séquentielle contenant des clauses généralisées est une *règle séquentielle généralisée*. Par exemple, $r' = (*|V) \rightarrow (*|J)$

est une règle séquentielle généralisée, et à partir de la relation d'inclusion étendue aux mots généralisés, nous avons $s_2 \models r'$ et $s_3 \models r'$.

Soit un sentiment M , nous résumons, dans le tableau 1, un ensemble \mathcal{R} des règles séquentielles généralisées sur M , noté $\mathcal{R}(M)$. Ainsi, notre proposition sur les orientations de sentiments peut être réécrite avec la description formelle suivante : $\forall r \in \mathcal{R}(M), S \models r \implies S \models M$.

Comme décrit dans la tableau 1, nous considérons, pour le moment, 8 règles séquentielles généralisées sur des adjectifs entraînés, nommées J-N, N-J, V-J, J-V, NEG-J-N, N-NEG-J, V-NEG-J et J-V-NEG. L'ensemble $\mathcal{R}(M)$ peut être bien sûr étendu par des nouvelles règles. Notons que, pour générer des règles, nous ne considérons pas d'analyse syntaxique [14] afin d'extraire les relations lexicales.

Étant données une phrase S et une règle $r \in \mathcal{R}(M)$, supposons que $r = s_\alpha \rightarrow s_\beta$ et $S \models r$, alors il existe deux clauses $s'_\alpha, s'_\beta \preceq S$ telles que $s'_\alpha \preceq s_\alpha$ et $s'_\beta \preceq s_\beta$. La clause $s = s'_\alpha \cdot s'_\beta$ incluse dans la phrase S est un *motif de sentiment*. Des motifs de sentiment sont nommés de la même manière des règles séquentielles généralisées.

(4) *This is a good film.*

$$s_4 = (this)(be|V)(a)(good|J)(film|N)$$

Par exemple, le texte (4) contient un motif J-N $(good|J)(film|N)$ et un motif V-J $(be|V)(good|J)$.

Une *croissance* sur des clauses, nommée b , est un ensemble des contraintes cohérentes qui contient une règle séquentielle $r = s_\alpha \rightarrow s_\beta$ et une relation de contradiction sémantique $s_\beta \neq_{sem} s_\gamma$, où la clause s_γ contredit sémantiquement la clause s_β (avec s_β et s_γ disjoints). Par exemple, soit une clause $(be|V)(good|J)$, alors sa contradiction sémantique peut être $(be|V)(bad|J)$. Nous notons une croissance comme $b = [s_\alpha; s_\beta; s_\gamma]$, ce qui spécifie que dans une clause s , l'occurrence de s_α doit être suivi par l'occurrence de s_β et

qu'elle ne doit pas pouvoir être remplacée par s_γ . On a : $s_\alpha \preceq s \implies s_\alpha \cdot s_\beta \preceq s \wedge s_\alpha \cdot s_\gamma \not\preceq s$.

Une clause s qui vérifie une croissance b est dite *clause attendue*, notée $s \models b$. Une clause qui viole la croissance b est dite *clause inattendue*, notée $s \not\models b$. Nous avons les relations suivantes :

$$\begin{aligned} s_\alpha \cdot s_\beta \preceq s \wedge s_\alpha \cdot s_\gamma \not\preceq s &\implies s \models b, \\ s_\alpha \cdot s_\beta \not\preceq s \wedge s_\alpha \cdot s_\gamma \preceq s &\implies s \not\models b. \end{aligned}$$

Soient une phrase S et une croissance $b = [s_\alpha; s_\beta; s_\gamma]$. Si $S \models b$, alors il existe deux clauses $s'_\alpha, s'_\beta \preceq S$ telles que $s'_\alpha \preceq s_\alpha$ et $s'_\beta \preceq s_\beta$. Si $S \not\models b$, alors il existe deux clauses $s'_\alpha, s'_\gamma \preceq S$ telles que $s'_\alpha \preceq s_\alpha$ et $s'_\gamma \preceq s_\gamma$. La clause $s = s'_\alpha \cdot s' \cdot s'_\beta$ (respectivement la clause $s = s'_\alpha \cdot s' \cdot s'_\gamma$) incluse dans S est une *caractéristique*, où $|s'| \geq 0$ telle que $s'_\alpha \cdot s' \cdot s'_\beta$ (respectivement $s'_\alpha \cdot s' \cdot s'_\gamma$) est continûment incluse dans la phrase S .

Par exemple, considérons la croissance $b = [(be|V); (wonderful|J); (awful|J)]$ pour les textes (2) et (3), on a $s_2 \models b$ et $s_3 \not\models b$, où $(be|V)(a)(wonderful|J)$ et $(be|V)(very|R)(awful|J)$ sont les *caractéristiques*.

Si nous considérons les règles séquentielles généralisées listées dans le tableau 1 avec des croissances, la contradiction sémantique peut être détectée par les antonymes des adjectifs contenus dans chaque règle. Nous proposons donc un ensemble de modèles de croissances pour construire une base de croissances à partir du $\mathcal{R}(M)$, où chaque croissance spécifie une orientation de sentiment. Le tableau 2 liste les modèles de croissances. Notons que le mot généralisé $(\bar{*}|J)$ représente l'antonyme du mot $(*|J)$. Soit un sentiment M , notons $\mathcal{B}(M)$ la base de croissances construite à partir des modèles de croissances dans le tableau 2, alors une phrase S violant une croissance $b \in \mathcal{B}(M)$ exprime le sentiment opposé à l'orientation d'opinion M , c'est-à-dire,

$$\forall b \in \mathcal{B}(M), S \not\models b \implies S \models \bar{M}.$$

Type	Règle séquentielle généralisée	Orientations de sentiment
JN	$(* J) \rightarrow (* N)$	$(* J) \models M$
NJ	$(* N) \rightarrow (* J)$	$(* J) \models M$
VJ	$(* V) \rightarrow (* J)$	$(* J) \models M$
JV	$(* J) \rightarrow (* V)$	$(* J) \models M$
NEG-J-N	$(NEG)(* J) \rightarrow (* N)$	$(* J) \models \overline{M}$
N-NEG-J	$(* N)(NEG) \rightarrow (* J)$	$(* J) \models \overline{M}$
V-NEG-J	$(* V)(NEG) \rightarrow (* J)$	$(* J) \models \overline{M}$
J-V-NEG	$(* J) \rightarrow (* V)(NEG)$	$(* J) \models \overline{M}$

Tableau 1 – Règles séquentielles généralisées pour représenter des orientations de sentiment.

Type	Règle séquentielle généralisée	Modèle de croyance
J-N	$(* J) \rightarrow (* N)$	$\{(\overline{* J}); \emptyset; (* N)\}$ $\{(NEG)(* J); \emptyset; (N)\}$
N-J	$(* N) \rightarrow (* J)$	$\{(* N); (* J); (\overline{* J})\}$ $\{(* N); (* J); (NEG)(* J)\}$
V-J	$(* V) \rightarrow (* J)$	$\{(* V); (* J); (\overline{* J})\}$ $\{(* V); (* J); (NEG)(* J)\}$ $\{(* V)(NEG); (\overline{* J}); (* J)\}$
J-V	$(* J) \rightarrow (* V)$	$\{(* J); (* V); (* V)(NEG)\}$
NEG-J-N	$(NEG)(* J) \rightarrow (* N)$	$\{(NEG)(\overline{* J}); \emptyset; (* N)\}$
N-NEG-J	$(* N)(NEG) \rightarrow (* J)$	$\{(* N)(NEG); (* J); (\overline{* J})\}$
V-NEG-J	$(* V)(NEG) \rightarrow (* J)$	$\{(* V)(NEG); (* J); (\overline{* J})\}$
J-V-NEG	$(* J) \rightarrow (* V)(NEG)$	$\{(\overline{* J}); \emptyset; (* V)(NEG)\}$

Tableau 2 – Modèles de croyance pour construire la base de croyances d’orientations de sentiment.

4 Extraction de sentiments opposés avec des mesures floues

Nous proposons une approche floue pour déterminer des sentiments opposés qui tient compte du niveau des orientations de sentiment exprimées par les caractéristiques correspondant à la base de croyances. Les niveaux des orientations de sentiment sont mesurés par deux méthodes floues *Local-Fuzzy* et *Global-Fuzzy*.

4.1 La mesure Local-Fuzzy

Soit une orientation d’opinion M du document, le niveau du sentiment opposé \overline{M} est considéré comme le score subjectif de l’adjectif contenu dans la caractéristique qui viole la base de croyances sur des orientations de sentiment. \overline{M} est extrait d’un dictionnaire d’antonymes, comme détaillé dans la section 5. Le score subjectif de l’adjectif est nommé *degré local* du sentiment opposé. Il est déterminé par la fonction de mesure *local-fuzzy*, notée $\omega_L(S, \overline{M})$, où S est une phrase qui supporte l’orientation de sentiment et $0 < \omega_L(S, \overline{M}) \leq 1$, puisque le

score subjectif des adjectifs est souvent mesuré comme une valeur entre 0 et 1 [3].

On note $\omega_S(v_j, \overline{M})$ la fonction retournant le score d’orientation sémantique d’un adjectif v_j . Le degré local du sentiment opposé est :

$$\omega_L(S, \overline{M}) = \omega_S(v_j, \overline{M}), \quad (1)$$

où v_j est l’adjectif contenu dans la caractéristique de S qui supporte le sentiment opposé. La figure 1 montre les 3 fonctions d’appartenance pour le sentiment opposé (forte, moyen et faible). D’autres partitions floues, par exemple en 5 niveaux, pourraient aussi être traitées.

Notons que notre approche ne considère qu’un adjectif dans chaque phrase. Dans le cas où plusieurs seraient présents, seul le premier sera considéré. Une méthode d’agrégation devra être mise en œuvre pour optimiser cette approche.

Le score subjectif des adjectifs a été abordé dans divers approches [3, 6, 8], parmi les-




Figure 1 – Les 3 fonctions d’appartenance pour des sentiments opposés en degré local.

quelles l’approche SentiWordNet définissant les scores objectifs/subjectifs pour chaque synset de WordNet [5] et fonctionnant bien au sein de notre approche.

4.2 La mesure Global-Fuzzy

La méthode *Global-Fuzzy* considère un *degré global* pour mesurer la puissance du sentiment opposé, en rapportant chaque score local (fonction $\omega_L(S, \overline{M})$, voir équation 1) au score $\omega_D(D, M)$ calculé sur tout le document. Plus précisément, soient une orientation d’opinion M , un document $\mathcal{D} \models M$, et une phrase $S \in \mathcal{D}$ telle que $S \models \overline{M}$, nous notons $\omega_D(\mathcal{D}, M)$ la fonction retournant le score d’orientation d’opinion du document \mathcal{D} .

Ce degré $\omega_D(\mathcal{D}, M)$ peut être calculé par plusieurs méthodes, par exemple, en utilisant l’approche proposée dans [11] qui propose une méthode d’extraction d’opinions et de leurs pôlarités. Dans notre approche, nous proposons une méthode légère pour déterminer ce degré :

$$\omega_D(\mathcal{D}, M) = \frac{\sum \omega_S(v_j, M)}{|\mathcal{D}|}, \quad (2)$$

Le degré global du sentiment opposé est alors déterminé par la fonction de mesure *global-fuzzy* $\omega_G(S, \overline{M})$ définie par :

$$\omega_G(S, \overline{M}) = \frac{\omega_L(S, \overline{M})}{\omega_D(\mathcal{D}, M)} = \frac{\omega_S(v_j, \overline{M})}{\omega_D(\mathcal{D}, M)}, \quad (3)$$

où v_j est l’adjectif contenu dans la ca-

ractéristique de la phrase S supportant le sentiment opposé \overline{M} . On a $\omega_G(S, \overline{M}) > 0$. La figure 2 montre les 3 fonctions d’appartenance floues pour la méthode *Global-Fuzzy*.




Figure 2 – Les 3 fonctions d’appartenance pour des sentiments opposés en degré global.

Le tableau 3 illustre les différences entre les mesures *Local-Fuzzy* et *Global-Fuzzy*.

v_j	ω_S ω_L	Niveau _L	ω_D	ω_G	Niveau _G
$(noisy J)$	0.25	faible -	0.5	0.5	faible -
$(noisy J)$	0.25	faible -	0.8	0.3125	faible
$(bad J)$	0.5	moyen	0.5	1.0	moyen
$(bad J)$	0.5	moyen	0.8	0.625	moyen -
$(sad J)$	0.75	fort -	0.5	1.5	fort -
$(sad J)$	0.75	fort -	0.8	0.9375	moyen
$(poor J)$	0.875	fort	0.5	1.75	fort
$(poor J)$	0.875	fort	0.8	1.09375	moyen

Tableau 3 – Niveaux des sentiments opposés.

Notons que :

1. le score sémantique $\omega_S(v, \overline{M})$ de chaque adjectif v est fourni par SentiWordNet avec le numéro de sens 1 ;
2. les valeurs des degrés de l’orientation d’opinion du document sont données à titre d’illustration pour montrer la différence entre des niveaux globaux.

Ainsi, avec le même degré local, le niveau global d’un sentiment opposé dépend du degré d’orientation d’opinion du document. Par exemple, dans un document avec le degré du document 0.5, le sentiment opposé exprimé par le mot $(poor|J)$ est *fort*, cependant dans un document avec un degré plus fort, e.g. 0.8, le niveau du sentiment opposé exprimé par le même mot est réduit à *moyen*.

5 Évaluation

Dans un premier temps, nous construisons une base de croyances à partir des dictionnaires et de documents d'apprentissage. Ensuite, nous utilisons cette base de croyances pour extraire des sentiments opposés et les mesurer avec la méthode *Global-Fuzzy*. Tous les documents cibles ont été classifiés et la valeur $\omega_D(\mathcal{D}, M)$ de chaque document a été déterminée par notre méthode (cf équation 2). SentiWordNet est utilisé pour déterminer le score de chaque adjectif.

Soit M une orientation d'opinion, nous considérons un ordre prioritaire dans l'ensemble $\mathcal{R}(M)$, c'est-à-dire, J-N > N-J > V-J > J-V > NEG-J-N > N-NEG-J > V-NEG-J > J-V-NEG. Pour construire la base de croyances des orientations de sentiment, nous appliquons d'abord un algorithme d'extraction de motifs séquentiels sur les documents d'apprentissage afin de découvrir toutes les clauses fréquentes maximales. Puis nous cherchons les caractéristiques à partir de l'ensemble $\mathcal{R}(M)$, noté $\mathcal{P}(M)$. La base de croyances $\mathcal{B}(M)$ peut être construite à partir de $\mathcal{P}(M)$ avec les modèles listés dans le tableau 2.

Par exemple, le dictionnaire, noté \mathcal{V}^+ , contient un ensemble d'adjectifs positifs et le dictionnaire, noté $\overline{\mathcal{V}^+}$, contient des antonymes de chaque mot $v \in \mathcal{V}^+$. Supposons que $(good|J) \in \mathcal{V}^+$ et que son antonyme soit $(bad|J) \in \overline{\mathcal{V}^+}$. Si nous avons une caractéristique $p = (be|V)(very|R)(good|J)$, alors p contient un V-J motif de sentiment $(be|V)(good|J)$, et nous avons les croyances suivantes à partir de p : $b_1 = [(be|V); (good|J); (bad|J)]$, $b_2 = [(be|V); (good|J); (NEG)(good|J)]$, $b_3 = [(be|V)(NEG); (bad|J); (good|J)]$.

La base de données utilisée pour évaluer notre approche est constituée d'avis sur des films. Elle est accessible en ligne¹ et présentée dans [9]. Nous créons deux documents d'appren-

¹<http://www.cs.cornell.edu/People/pabo/movie-review-data/>

tissage \mathcal{D}_L^+ (1 000 revues positives avec 75 740 phrases et 21 156 mots distincts) et \mathcal{D}_L^- (1 000 revues négatives avec 67 425 phrases et 19 714 mots distincts). Deux dictionnaires \mathcal{V}^+ et \mathcal{V}^- sont créés à partir des adjectifs les plus fréquents dans \mathcal{D}_L^+ et \mathcal{D}_L^- . Avec un support minimum 0.004, nous avons trouvé 24 (\mathcal{D}_L^+) et 12 (\mathcal{D}_L^-) motifs de sentiments pour générer des bases de croyances. Par exemple les croyances $b1 = [climax; bad; good]$ et $b2 = [looks; bad; good]$ et ont été extraites dans \mathcal{D}_L^- . Pour déterminer l'exactitude de notre approche, 100 phrases inattendues extraites à partir des documents cibles $\bigcup \mathcal{D}^+$ et $\bigcup \mathcal{D}^-$ ont été examinées manuellement. Les résultats montrent que environ 74 phrases expriment un sentiment opposé ; 69 phrases exprimant le sentiment opposé sont correctement mesurées à 3 niveaux (*fort*, *moyen*, et *faible*). Par exemple, dans un document négatif, nous avons la phrase $S = the\ set-on-a-train\ climax\ looks\ good$ qui contient deux sentiments opposés : $climax \rightarrow good$ et $looks \rightarrow good$. Le premier sera favorisé car il est de la forme N-J qui est prioritaire par rapport au second V-J. Le degré $\omega_L(S, POS)$ est égal au score de $good$ dans SentiWordnet, c'est-à-dire 0.5 ce qui en fait un sentiment localement moyennement opposé (cf. Figure 1). Le degré $\omega_D(S, NEG)$ est calculé sur l'ensemble du document et vaut 0.2 ; le degré $\omega_G(S, POS)$ vaut donc $\frac{0.5}{0.2} = 2.5$ ce qui donne un sentiment fortement opposé au niveau global (sous-ensemble flou Strong de la Figure 2).

6 Conclusion

Dans cet article nous proposons une approche floue pour chercher des sentiments opposés dans des textes. Tous les sentiments déterminés sont mesurés par deux méthodes : *Local-Fuzzy* et *Global-Fuzzy*.

Nous formalisons la problématique par un modèle de données compatible avec les approches d'extraction de séquences fréquentes et pouvons ainsi appliquer des algorithmes d'extraction. Nous proposons également des

représentations de l'orientation d'opinion et de sentiment opposé par rapport aux règles séquentielles et croyances, et enfin nous proposons deux mesures floues pour mesurer le niveau des sentiments opposés extraits. Notre évaluation sur des bases d'avis de films montre que notre approche est pertinente.

Ici, la création de la liste des antonymes est effectuée manuellement et nous ne considérons que les sentiments exprimés par des adjectifs. Les travaux que nous menons actuellement cherchent à automatiser la tâche d'apprentissage des synonymes et antonymes (e.g. par exemple en utilisant Wordnet) et à prendre en compte les autres composants tels que les quantificateurs, modificateurs (*très peu* agréable) et négations (*pas* agréable).

Références

- [1] R. Agrawal and R. Srikant. Mining sequential patterns. In *ICDE*, pages 3–14, 1995.
- [2] K. Dave, S. Lawrence, and D. M. Pennock. Mining the peanut gallery : Opinion extraction and semantic classification of product reviews. In *WWW*, pages 519–528, 2003.
- [3] A. Esuli and F. Sebastiani. SentiWordNet : A publicly available lexical resource for opinion mining. In *LREC*, 2006.
- [4] A. Esuli and F. Sebastiani. PageRanking WordNet synsets : An application to opinion mining. In *ACL*, pages 424–431, 2007.
- [5] C. Fellbaum. *WordNet : An electronic lexical database*. MIT Press, 1998.
- [6] V. Hatzivassiloglou and K. McKeown. Predicting the semantic orientation of adjectives. In *ACL*, pages 174–181, 1997.
- [7] M. Hu and B. Liu. Mining and summarizing customer reviews. In *KDD*, pages 168–177, 2004.
- [8] J. Kamps, R. J. Mokken, M. Marx, and M. de Rijke. Using WordNet to measure semantic orientation of adjectives. In *LREC*, pages 1115–1118, 2004.
- [9] B. Pang and L. Lee. A sentimental education : Sentiment analysis using subjectivity summarization based on minimum cuts. In *ACL*, pages 271–278, 2004.
- [10] B. Pang, L. Lee, and S. Vaithyanathan. Thumbs up? Sentiment classification using machine learning techniques. In *EMNLP*, pages 79–86, 2002.
- [11] A.-M. Popescu and O. Etzioni. Extracting product features and opinions from reviews. In *HLT/EMNLP*, pages 339–346, 2005.
- [12] B. Santorini. Part-of-Speech tagging guidelines for the Penn Treebank project, 1991.
- [13] H. Schmid. Probabilistic Part-of-Speech tagging using decision trees. In *NeMLaP*, 1994.
- [14] D. D. Sleator and D. Temperley. Parsing English with a link grammar. In *3rd International Workshop on Parsing Technologies*, 1993.
- [15] P. D. Turney. Mining the Web for synonyms : PMI-IR versus LSA on TOEFL. In *ECML*, pages 491–502, 2001.
- [16] P. D. Turney. Thumbs up or thumbs down? Semantic orientation applied to unsupervised classification of reviews. In *ACL*, pages 417–424, 2002.
- [17] T. Wilson, J. Wiebe, and P. Hoffmann. Recognizing contextual polarity in phrase-level sentiment analysis. In *HLT/EMNLP*, 2005.