
Polarité des jugements et des interactions pour le filtrage collaboratif et la prédiction de liens sociaux

Luc-Aurélien Gauthier — Benjamin Piwowarski — Patrick Gallinari

*Sorbonne Universités, UPMC Univ Paris 06, CNRS
Laboratoire d'Informatique de Paris 6
4, place Jussieu
75 005 Paris*

{Luc-Aurelien.Gauthier,Benjamin.Piwowarski,Patrick.Gallinari}@lip6.fr

RÉSUMÉ. Nous nous intéressons à l'étude des similarités entre utilisateurs dans des systèmes de filtrage collaboratif, et en particulier à l'exploitation de la polarité (note positive ou négative) des jugements. Nous proposons une mesure qui prend en compte les biais liés à la popularité de l'item et à la propension de l'utilisateur à noter de manière positive ou négative. La validité de cette mesure de similarité est évaluée par le biais de deux tâches (recommandation et prédiction de lien), et montre que ces deux mesures permettent de distinguer trois types de relations entre utilisateurs.

ABSTRACT. This paper studies user similarities in the context of collaborative filtering systems, and more precisely, we study the effect of polarity (positive or negative item note) on the nature of user relationships. We propose a measure that takes into account the item popularity bias and the user likelihood of giving a positive rating to an item. The measure is evaluated on collaborative filtering and social network datasets, showing that they are useful to isolate three different types of relationships between users.

MOTS-CLÉS : système de recommandation

KEYWORDS: recommendation system

1. Introduction

Les systèmes de recommandation sont devenus un des outils indispensables pour guider les utilisateurs à travers la richesse du contenu disponible sur le web. Ils ont pour rôle de suggérer aux utilisateurs des produits et services (items) qui pourraient les satisfaire. Parmi ces systèmes, le *filtrage collaboratif* construit des profils utilisateur et item à l'aide de l'historique de notes. Parfois, ces modèles exploitent les relations sociales pour affiner les recommandations ou pour prédire d'autres liens entre utilisateurs. Mais, en l'absence de graphe social, la plupart des modèles estiment les similarités à partir des seuls jugements communs.

Cet article traite de ces similarités entre utilisateurs et, plus particulièrement, s'inscrit dans le prolongement des travaux (Gauthier *et al.*, 2014) dans lesquels les mesures de similarité prennent en compte la polarité des jugements, c'est-à-dire le fait qu'une note soit positive ou négative. Jusque là, les principales méthodes exploitant les voisinages sont fondées sur l'idée que la similarité est liée aux seuls accords, comme pour l'indice de Pearson ou le cosinus (Bellogín et de Vries, 2013). En réalité, distinguer la polarité des jugements a permis de mettre en lumière une différence de sémantique selon que les utilisateurs aient porté, sur le même produit, un jugement identique positif (indiquant plus de similarité entre les notes sur des produits communs) ou négatif.

Dans cet article, nous poursuivons l'étude de la polarité des jugements initiée dans (Gauthier *et al.*, 2014) en étudiant les points qui, indépendamment de toute similarité entre les utilisateurs, peuvent avoir un impact sur la présence d'accords positifs et négatifs. En particulier, nous souhaitons mesurer les similarités uniquement à travers les jugements qui ne sont pas liés à certains biais ; notre hypothèse est que le jugement d'un utilisateur dépend à la fois de la popularité de l'item évalué, mais aussi de la distribution de notes de l'utilisateur. L'étude des accords doit donc prendre en compte ces deux facteurs afin de sélectionner ceux qui sont synonymes de liens forts. Plus précisément, dans cet article nous proposons une mesure de similarité qui permet d'évaluer dans quelle mesure des accords sont informatifs ou non, de manière à identifier différents types de relations entre les utilisateurs.

Nos contributions sont les suivantes :

- Nous proposons deux mesures qui indiquent, pour les accords et les désaccords, dans quelle proportion les accords sont dus au hasard ou à une véritable concordance des jugements ;
- Nous validons nos mesures en montrant la relation entre celles-ci et (1) la différence des notes données par 2 utilisateurs (Yahoo ! KDD Cup 2011) (2) la polarité de la relation entre utilisateurs (Epinions) ;
- Nous montrons l'existence de trois types de relations entre utilisateurs : similarité (ils partagent des jugements positifs communs), proximité (ils partagent des jugements communs mais principalement des jugements négatifs communs) et neutralité (leurs jugements communs sont dus au hasard).

Cet article est organisé de la façon suivante. Nous débutons par un état de l'art sur la prise en compte de la polarité de notes et de relations entre utilisateurs dans la section 2. Nous expliquons en section 3 notre approche et proposons en section 4 notre modèle. Nous détaillons et discutons des résultats obtenus en section 5.

2. État de l'art

Il existe deux familles de systèmes de recommandation (Bobadilla *et al.*, 2013). D'une part, les systèmes de *filtrage par contenu* qui se basent sur la construction de profils explicites pour chaque utilisateur et item, comme par exemple l'âge et la profession pour les utilisateurs, et le genre et la popularité pour les items. D'autre part, les systèmes de *filtrage collaboratif* qui construisent un profil pour les utilisateurs et les items selon l'ensemble des jugements. Le filtrage collaboratif donne d'excellents résultats lorsqu'il peut exploiter une très grande quantité de données et tirer profit du voisinage explicite (Crandall *et al.*, 2008) ou de toute mesure de similarité calculée à l'aide de l'historique des notes.

Dans cette famille de méthodes, certaines d'entre elles peuvent prendre en compte la popularité des items. C'est le cas par exemple des méthodes à base de modèles parmi lesquelles on trouve les modèles de factorisation matricielle (Koren *et al.*, 2009) qui représentent les utilisateurs et les items dans un espace latent commun. Les premières dimensions de l'espace latent construit à l'aide de l'historique des notes contiennent alors le profil des items populaires. Dans certains applications, l'information de voisinage - qu'il soit explicite ou calculé à l'aide de mesures de similarité, peut-être pris en compte sous forme de contraintes. Certaines de ces mesures, comme l'indice de Pearson ou le cosinus (Bellogín et de Vries, 2013), prennent en compte les moyennes des notes de chaque utilisateur afin de corriger les effets d'une propension à attribuer des notes plus élevées que la moyenne des utilisateurs.

En revanche, ces mesures de similarité ne prennent pas en compte la polarité des jugements. Un premier travail à l'avoir exploitée pour le calcul de la similarité (Gauthier *et al.*, 2014) a permis de mettre en évidence une différence de sémantique selon qu'un jugement identique, entre deux utilisateurs, soit positif ou négatif. Ainsi, les accords qui concernent des jugements positifs sont davantage synonymes de similarité (les utilisateurs donnent les mêmes notes) que les jugements négatifs communs. Cependant, la simplicité de ces indicateurs ne permet justement pas de capturer certains biais comme la popularité des items ou les distributions de jugements des utilisateurs.

La polarité est davantage étudiée dans l'analyse des réseaux sociaux où elle est présente naturellement. On pense notamment à (Leskovec *et al.*, 2010; Kunegis *et al.*, 2009) qui ont étudié les liens sociaux signés afin de prédire les différentes relations antagonistes comme confiance/méfiance ou ami/ennemi. Ces travaux s'appuient sur deux théories afin d'expliquer la répartition des liens positifs et négatifs dans un graphe social; la théorie du statut et la théorie de l'équilibre. D'autres travaux ont

exploité les jugements des utilisateurs afin de relier les goûts et les liens sociaux. En particulier, (Yang *et al.*, 2011 ; Yang *et al.*, 2012) ont montré que les liens sociaux négatifs n'étaient pas corrélés aux jugements des utilisateurs. Dans cet article, nous montrons qu'il est possible de lier jugements des utilisateurs et polarité des liens sociaux avec des mesures plus fines que la corrélation.

3. Intuition

L'ensemble des items notés par un utilisateur est à la base de tout modèle de filtrage collaboratif. Cet historique de notes nous renseigne de façon assez précise sur les goûts et le profil de chacun ; on sait ce que les utilisateurs aiment (jugements positifs) et aussi ce qu'ils n'aiment pas (jugements négatifs). Notons qu'il est nécessaire de définir un seuil qui permet de distinguer la polarité des jugements. Celui-ci peut être défini de manière globale (voir section 5), ou pour chaque utilisateur.

Deux utilisateurs partageant des items communs pourront être soit en accord, soit en désaccord. Dans le premier cas, les utilisateurs auront tous deux porté sur l'item un jugement identique ; l'accord sera alors dit positif (resp. négatif) si le jugement est positif (resp. négatif). Dans le second cas, les utilisateurs auront formulé des jugements contraires.

Pour une tâche de recommandation, la concordance des jugements est précisément ce que doit permettre de mesurer la similarité : les utilisateurs similaires vont noter de la même manière. Ce que (Gauthier *et al.*, 2014) a permis de montrer est que le signe d'un accord influe sur la concordance de notation entre les utilisateurs. Ainsi, pour étudier les similarités, il faut s'intéresser aux nombres d'accords positifs, d'accords négatifs et de désaccords. Cependant, ce qui n'est pas pris en compte lorsque l'on s'intéresse à ces quantités, c'est qu'elles dépendent avant tout de la distribution de signe des jugements de chaque utilisateur. En résumé, les accords doivent être interprétés dans leur contexte, i.e. l'ensemble des notes données par les utilisateurs.

Afin d'illustrer cela, nous allons nous intéresser à trois exemples illustrant trois cas particuliers.

Dans le premier exemple, deux utilisateurs ont jugés positivement 10 produits chacun, et partagent un jugement sur quatre items :

$$\begin{array}{l}
 u_1 : \quad + \\
 u_2 : \quad \quad \quad \quad \quad \quad \quad + \quad +
 \end{array}$$

Ce cas est considéré comme peu informatif car on peut supposer que quelques qu'aient été les items communs, le nombre d'accords positifs aurait été le même. Notre mesure S^+ (score positif) associera à deux utilisateurs tels que u_1 et u_2 une valeur nulle.

Dans notre second exemple, les utilisateurs ont cette fois attribué des jugements positifs et négatifs, et l'ensemble des items jugés en commun correspond exactement à l'ensembles des items appréciés par l'un et l'autre :

$$\begin{array}{l}
 u_1 : \quad - \quad - \quad - \quad - \quad - \quad + \quad + \quad + \quad + \\
 u_2 : \quad \quad \quad \quad \quad \quad \quad + \quad + \quad + \quad + \quad - \quad - \quad - \quad - \quad - \quad -
 \end{array}$$

Nous considérons que cet exemple est très informatif, et illustre précisément ce que l'on attend de personnes qui noteraient de la même manière. Le score positif S^+ associé à cette relation sera élevé (proche de 1).

Pour le dernier cas, les utilisateurs sont en désaccord sur l'ensemble de leurs items communs.

$$\begin{array}{l}
 u_1 : \quad - \quad - \quad - \quad - \quad - \quad + \quad + \quad + \quad + \\
 u_2 : \quad \quad \quad \quad \quad \quad \quad - \quad - \quad - \quad - \quad + \quad + \quad + \quad + \quad + \quad +
 \end{array}$$

Ce cas est également très informatif car les utilisateurs ne notent pas de la même manière. Le score positif S^+ associé à cette situation sera négatif.

Avec ces exemples, nous avons souligné l'importance de juger des accords en fonction du contexte, i.e. en fonction de la propension des utilisateurs à juger de telle ou telle manière. De façon symétrique, nous pouvons aussi nous intéresser aux items. En effet, la popularité des items influe énormément sur le jugement des utilisateurs. Par exemple, un accord sur un item dont les notes seraient très majoritairement positives a toutes les chances d'être positif lui aussi.

Dans cet article, nous comparons les jugements communs observés entre deux utilisateurs (accords positifs et négatifs, désaccords) avec ceux que nous obtiendrions en respectant les caractéristiques des utilisateurs et des items, à savoir : (1) la propension de l'utilisateur à juger positivement et (2) la popularité de l'item. Afin de tenir compte de la polarité, nous étudierons deux écarts par rapport à l'aléatoire : celui sur les accords positifs et celui sur les accords négatifs. Cela va nous permettre de différencier trois types de relations entre utilisateur, caractérisés par trois comportements latents distincts.

4. Score positif et négatif

Dans cette section, nous proposons deux nouvelles mesures de similarité entre utilisateurs qui prennent en compte la propension de l'utilisateur à juger positivement, et la popularité de l'item. Pour cela, nous allons associer à chaque item un gain qui dépendra de la distribution de notes sur cet item et du signe de l'accord entre deux utilisateurs. Un accord positif (resp. négatif) sur un item ayant majoritairement reçu des notes négatives (resp. positives) sera associé à un gain fort. Dans le cas contraire, à un gain faible.

Gain d'un item pour un accord de polarité s .

Plus précisément, pour un accord de polarité $s \in \{+, -\}$, le gain pour un item est égal à la probabilité de *ne pas observer* d'accord de type s pour cet item. En supposant que les deux utilisateurs notent de façon indépendante, le gain est donc :

$$g_i^s = 1 - p(u_i = v_i = s) \quad [1]$$

$$= 1 - p(u_i = s)p(v_i = s) \quad [2]$$

$$= 1 - \left(\frac{n_i^s}{n_i}\right)^2 \quad [3]$$

où u et v sont deux utilisateur quelconques, u_i et v_i les notes qu'ils ont attribuées à l'item i , n_i^s le nombre de notes de signe s reçues par i et n_i le nombre total de notes reçues. Ce gain est donc d'autant plus fort que la probabilité d'observer un accord de polarité s est faible.

Gain observé global.

Cette définition nous permet de calculer un gain global observé $G_o^s(u, v)$ entre deux utilisateurs u et v . Ce gain global est égal à la somme des gains associés aux item qui sont jugés avec une polarité s par les deux utilisateurs. Formellement :

$$G_o^s(u, v) = \sum_{i \in I_{uv}^s} g_i^s$$

avec I_{uv}^s l'ensemble des items communs pour lesquels les utilisateurs u et v ont donné une note de polarité s .

Ces gains observés dépendent à la fois du nombre d'accords sur les items communs et de la popularité de ces derniers. Plus des utilisateurs ont noté des items avec la même polarité s , plus le gain G_o^s est élevé.

4.1. *Espérance et score final*

Afin de prendre en compte la popularité d'un item et la façon de noter des utilisateurs (certains donnent plus de notes positives, d'autres de notes négatives), nous proposons de comparer le gain observé $G_o^s(u, v)$ avec un gain espéré $\mathbb{E}(G^s(u, v))$. Ce gain correspond à celui obtenu en moyenne pour deux utilisateurs qui, tout en ayant jugé exactement les mêmes items avec le même nombre de notes positives ou négatives que u et v , se comportaient de façon indépendante. Plus la différence avec le gain observé sera grande, plus forte sera la certitude que les deux utilisateurs ont un accord de polarité s qui n'est pas due au hasard.

Dans la suite, nous décrivons tout d'abord le calcul de ce gain espéré (section 4.1.1), que nous intégrons dans un score final S_{uv}^s . Ce score final permet de normaliser la différence entre gain observé et espéré en tenant compte du nombre d'items jugés en commun.

4.1.1. Modèle utilisateur

Pour définir notre modèle utilisateur, nous voulons respecter certaines caractéristiques pour un utilisateur u , comme l'ensemble I_u des items jugés ou encore le nombre n_u^s de jugements de polarité s . Pour cela, nous définissons V_u l'ensemble des utilisateurs aux caractéristiques proches de celles de u ,

$$V_u = \{\tilde{u} | (I_u = I_{\tilde{u}}) \wedge (n_u^+ = n_{\tilde{u}}^+) \wedge (n_u^- = n_{\tilde{u}}^-)\}$$

Cela revient à considérer un ensemble de jugements qui seraient générés par une permutation des jugements de l'utilisateur u parmi les items qu'il a jugés. Les jugements de u correspondent donc à un et un seul $\tilde{u} \in V_u$. Nous supposons ensuite que la probabilité de juger avec une certaine polarité l'ensemble des items I_u jugés par l'utilisateur u est uniforme, c'est à dire que n'importe quelle permutation a la même probabilité $1/|V_u|$.

Ceci nous permet de calculer l'espérance du gain pour le couple (u, v) comme le gain moyen obtenu par l'ensemble des $\tilde{u} \in V_u$ et $\tilde{v} \in V_v$. Notre espérance est définie de la manière suivante :

$$\begin{aligned} \mathbb{E}(G^s(u, v)) &= \sum_{\tilde{u} \in V_u} \sum_{\tilde{v} \in V_v} \sum_{i \in I_{\tilde{u}\tilde{v}}^s} p(\tilde{u})p(\tilde{v})g_i^s \\ &= \frac{1}{|V_u||V_v|} \sum_{\tilde{u} \in V_u} \sum_{\tilde{v} \in V_v} \sum_{i \in I_{\tilde{u}\tilde{v}}^s} g_i^s \end{aligned}$$

Le calcul de cette espérance est développé en annexe. Nous y utilisons un modèle combinatoire, et ce, de manière à calculer un nombre de partitions (via le multinôme de Newton) respectant les distributions de chaque utilisateur. Plus précisément, cela permet de calculer le nombre d'accords moyen de polarité s :

$$\sum_{\tilde{u} \in V_u} \sum_{\tilde{v} \in V_v} |I_{\tilde{u}}^s \cap I_{\tilde{v}}^s| = \sum_{l=0}^n \binom{n}{l, n_u^s - l, n_v^s - l, n + l - n_u^s - n_v^s} \times \frac{\binom{n-1}{k-1}}{\binom{n}{k}}$$

avec $n = |I_u \cap I_v|$ le nombre de jugements communs. Soit au final :

$$\mathbb{E}(G_{uv}^s) = \frac{\sum_{l=0}^n \frac{(n-1)!}{(l-1)!(n_u^s-l)!(n_v^s-l)!(n+l-n_u^s-n_v^s)!(n-l+1)}}{\binom{n}{n_u^s} \times \binom{n}{n_v^s}} \times \sum_{i \in I_{uv}} g_i^s$$

4.1.2. Score final

La différence entre gain observé $G_o^s(u, v)$ et espéré $\mathbb{E}(G^s(u, v))$ peut dépendre du nombre d'items jugés en commun. Notre score final tient compte de ce fait en normalisant par la valeur maximum qui peut être prise par le gain :

Le corpus Yahoo! KDD Cup 2011 est composé d'un million d'utilisateurs pour un peu plus de 262 millions de notes. Nous avons exploité ce corpus pour évaluer la corrélation entre nos différents scores et la concordance des jugements. Les notes sont comprises entre 0 et 100 et la moyenne se situe autour de 50. Pour tenir compte de la polarité et ainsi avoir des jugements positifs ou négatifs, nous avons transformé ces notes en reprenant la méthode utilisée dans (Yang *et al.*, 2012).

$$Yahoo = \begin{cases} +1 & \text{si note} > 70 \\ 0 & \text{si } 30 < \text{note} < 70 \\ -1 & \text{si note} < 30 \end{cases}$$

Le corpus Epinions est composé quant à lui de 132 000 utilisateurs qui ont attribué un peu plus de 13 millions de notes à environ 1 560 000 items. Les données contiennent également un graphe social signé dirigé qui correspond aux liens sociaux explicites déclarés par une personne en direction d'une autre personne. Ces liens peuvent prendre deux valeurs, confiance (+1) et méfiance (-1). Nous exploitons ce corpus pour mesurer la corrélation entre nos scores et la polarité des liens sociaux. La transformation des notes correspond exactement à celle de (Yang *et al.*, 2012) où ce corpus est étudié :

$$Epinions = \begin{cases} +1 & \text{si note} > 4 \\ 0 & \text{si note} = 4 \\ -1 & \text{si note} < 4 \end{cases}$$

5.1. Mesure de la similarité

Afin d'évaluer la pertinence de nos caractéristiques nous avons choisi de nous intéresser à deux tâches. D'une part à la recommandation, parce que les similarités entre utilisateurs se traduisent en particulier par une concordance des jugements. D'autre part, à la prédiction de lien social, parce les liens signés explicites dont nous disposons sont équivalents à des liens de similarité : les utilisateurs déclarent avoir confiance (ou non) en quelqu'un vis-à-vis de ses jugements.

Pour comparer deux utilisateurs sur la tâche de recommandation, nous avons calculé pour chaque couple d'utilisateur la moyenne des différences quadratiques entre leurs notes communes. Une valeur élevée signifiera par exemple que, en moyenne, les utilisateurs n'ont pas noté de la même façon. Formellement, cela nous donne pour chaque couple (u, v) la différence suivante :

$$RMSE_{uv} = \sqrt{\frac{\sum_{i \in I_{uv}} (r_{ui} - r_{vi})^2}{|I_u \cap I_v|}}$$

où r_{ui} est la note attribuée par l'utilisateur u à l'item i .

La seconde évaluation s'apparente davantage à une tâche de prédiction de lien social. Nous avons utilisé les données du corpus Epinions parmi lesquelles on trouve

un graphe de confiance où les utilisateurs sont reliés entre eux par des liens positifs et négatifs. Nous avons alors mesuré la proportion de liens négatifs observés en fonction de la valeur de nos scores.

5.2. Sélection des voisins

Pour le corpus Epinions, nous pouvons utiliser le graphe social pour sélectionner nos couples d'utilisateurs. En revanche, pour le corpus Yahoo ! KDD Cup 2011, nous devons sélectionner les couples parmi les utilisateurs partageant des items en communs.

Afin de limiter les calculs, nous avons sélectionné un sous-ensemble de voisins pour chaque utilisateur, le nombre de voisins potentiels étant bien trop grand. En particulier, pour chaque utilisateur u , on sélectionne seulement 100 voisins, parmi lesquels nous avons : (1) les 50 utilisateurs partageant le plus d'items en commun avec u et (2) 50 utilisateurs tirés aléatoirement dans l'ensemble de ceux ayant au moins deux items communs avec l'utilisateur.

5.3. Résultats

Pour analyser nos résultats, nous allons tout d'abord étudier chacun de nos scores S^+ et S^- séparément, en les comparant aux indicateurs mis en place dans (Gauthier *et al.*, 2014). Ensuite, nous nous intéressons à l'interaction de ces deux scores afin de mettre en évidence différents types de relations entre utilisateur. Nous avons évalué ces mesures grâce à deux échantillons de 6 000 000 de couples d'utilisateurs.

5.3.1. Concordance des jugements

Nous étudions tout d'abord nos mesures dans le contexte de la recommandation, à l'aide des figures 1 et 2. Ces quatre *boxplots* représentent la valeur de la RMSE en fonction de deux mesures de similarité. Le diagramme de gauche donne l'évolution de la RMSE en fonction de la mesure de similarité P^s utilisée dans (Gauthier *et al.*, 2014), à savoir la proportion d'accords de signe s sur l'ensemble des accords. Le diagramme de droite montre l'évolution de la RMSE en fonction de nos scores S^s sur l'intervalle $[0, 1]$ (en dehors duquel les valeurs ne sont pas suffisamment nombreuses). Chaque boîte représente un décile de 600000 couples d'utilisateurs.

Score positif

Les deux *boxplots* de la figure 1 nous permettent d'observer dans les deux cas qu'une augmentation de nos mesures P^+ et S^+ est associée à une diminution de l'écart de notation. Pour notre S^+ en particulier, une valeur élevée implique une RMSE plus faible, c'est-à-dire qu'un nombre d'accords positifs supérieur aux attentes réduit l'écart de notation entre les utilisateurs. Nous pouvons remarquer que la mesure *accords positifs sur notes communes* se comporte de la même manière, bien que la

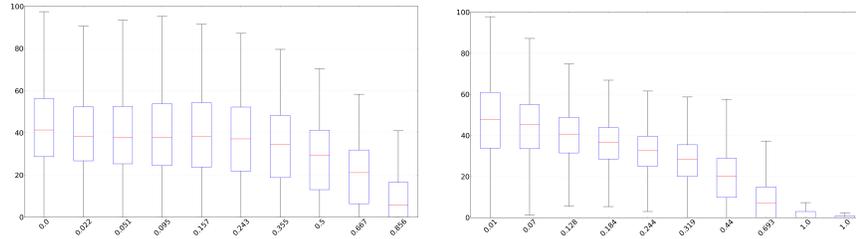


Figure 1. Evolution de l'erreur en fonction de la P^+ (à gauche) et de S^+ (à droite). Corpus Yahoo

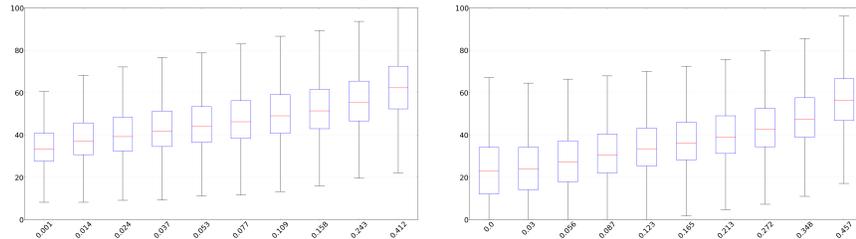


Figure 2. Evolution de l'erreur en fonction de P^- (à gauche) et de S^- (à droite). Corpus Yahoo

baisse de la RMSE ne soit marquée qu'à partir d'une valeur plus élevées et que la variance du RMSE soit plus importante.

Score négatif

Pour ces mesures sur les accords négatifs, le comportement est le symétrique du cas positif : une augmentation de valeur de P^- et S^- s'accompagne d'un écart de notation plus important. Par exemple, un nombre d'accords négatifs supérieur aux attentes implique une moindre concordance des notes entre utilisateurs. Autrement dit, les personnes qui partagent plus d'accords négatifs que prévu ne notent pas de la même manière. La caractéristique négative *accords négatifs sur notes communes* mène à la même conclusion, mais là encore la tendance est moins nette.

Interaction scores positifs et négatifs

L'objectif de notre approche est de pouvoir distinguer différents types de relations, caractérisées par des comportements latents. Considérés de manière indépendante, les scores positifs et négatifs S^+ et S^- ne permettent pas de dissocier ces groupes. C'est pourquoi nous allons nous intéresser ici à l'interaction entre les deux mesures.

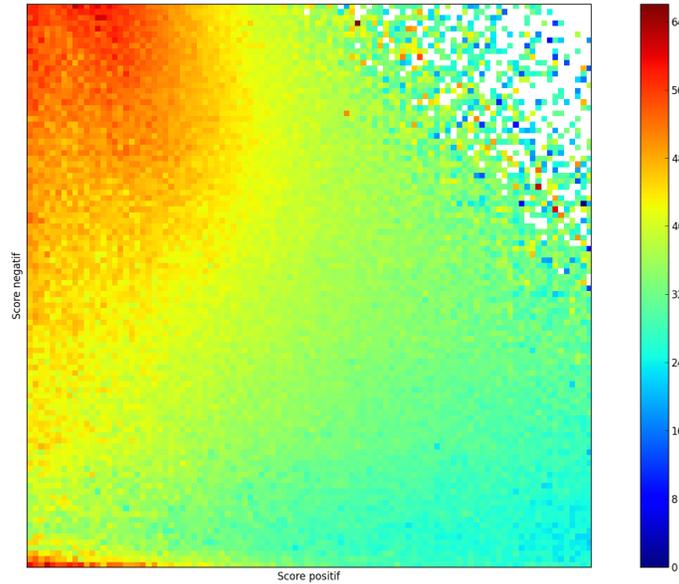


Figure 3. Heatmap représentant la valeur de la RMSE en fonction du score positif et du score négatif sur l'intervalle $[0, 1] \times [0, 1]$.

Pour cela, nous avons représenté cette interaction grâce à une heat-map (figure 3) qui montre le RMSE en fonction des scores positifs (abscisse) et négatifs (ordonnée). On y distingue trois groupes : (1) en haut à gauche, (2) en bas à gauche et (3) en bas à droite. Ces trois groupes correspondent à trois types de relation, la similarité, la proximité et la neutralité, définies de la manière suivante :

$$\left\{ \begin{array}{ll} \text{Similarité :} & S^+ \text{ élevé} \quad S^- \text{ faible} \\ \text{Proximité :} & S^+ \text{ faible} \quad S^- \text{ élevé} \\ \text{Neutralité :} & S^+ \text{ faible} \quad S^- \text{ faible} \end{array} \right.$$

Les personnes neutres ne partagent pas d'intérêts particuliers dans la mesure où les seuls accords qu'ils partagent ne sont dus qu'au hasard - scores positif et négatif faibles. Les notes communes sont généralement peu nombreuses et en majorité des désaccords. Sur la figure 3, ces utilisateurs sont dans la zone en bas à gauche ; le RMSE moyen est élevé.

Les personnes proches s'intéressent aux items d'un même thème. Ils peuvent partager également plus d'accords que de désaccords. Cependant, bien que proches thématiquement, ces personnes n'affectionnent pas les mêmes items ; ces utilisateurs partagent des items dont les caractéristiques sont proches à la fois des goûts de l'un et de l'autre, ce qui explique leur rencontre. Ces personnes minimisent le nombre d'accords positifs et le nombre de désaccords : le nombre d'accords négatifs est donc

plus important que prévu. Sur la figure 3, ces utilisateurs se situent en haut à gauche ; le RMSE est élevé et la variance est plutôt faible.

Les personnes similaires affectionnent quant à elles les mêmes items. Ces personnes ont donc tendance à être davantage en accord positif. Cette complémentarité des avis fait que ces personnes sont peu souvent en désaccord. La similarité maximise les accords positifs et minimise donc les accords négatifs. Ils se situent principalement en bas à droite de la figure 3.

5.3.2. *Le contexte social*

Maintenant, nous allons valider nos scores sur une tâche de prédiction de lien social. En particulier, nous cherchons à observer des corrélations entre nos deux scores, positif et négatif, sur le signe du lien social entre les utilisateurs. Pour cela, nous nous intéresserons à la figure 4 qui permet d’observer la répartition entre liens de confiance et liens de méfiance.

Les mesures associées aux accords négatifs semblent particulièrement bien adaptées. Sur la figure 4 nous pouvons voir qu’un S^- proche de zéro implique une proportion de liens sociaux négatifs faible (inférieur à 10%). Une valeur S^- proche de 1 indique que le nombre d’accord négatif est élevé et dans ce cas on a bien des liens de défiance également en nombre élevé. Le cas des valeurs S^- négatives est plus complexe à comprendre : nombre d’accords négatifs plus faible qu’attendu et nombre de liens de défiance plus élevé. Nous observons un comportement similaire avec le rapport *accords négatifs sur accords*, cependant l’évolution est plus linéaire.

Concernant les accords positifs, une augmentation des valeurs de P^+ et de S^+ (quand ce dernier est supérieur à 0) a pour effet de diminuer la proportion de liens sociaux négatifs, ce qui signifie en quelque sorte que la présence d’accords positifs conforte le lien de confiance entre les utilisateurs. En revanche, quand S^+ est inférieur à 0, le comportement est inverse : au plus bas pour un score S^+ à -1, la proportion de liens sociaux négatifs augmente quand le score se rapproche de 0.

En conclusion, notre score S^s , en particulier S^- semble refléter les liens sociaux dans le corpus d’Epinion. Comme dans le cas de la recommandation, le fait d’inclure une correction pour le biais utilisateur et item, permet d’obtenir une relation plus claire entre la mesure choisie (RMSE ou proportion de liens de confiance) et notre score S^s en comparaison avec le taux P^s .

6. Conclusion

Dans ce travail, nous nous sommes intéressés à la caractérisation fine des relations entre utilisateurs dans un contexte de filtrage collaboratif. Le développement de telles métriques a des applications directes en recommandation - par exemple pour modifier les similarités des modèles de voisinage ou bien le critère à optimiser dans le cas des modèles basés sur un espace latent où les utilisateurs et items sont représentés

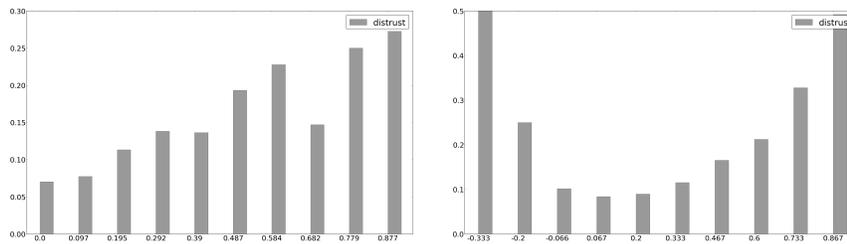


Figure 4. Répartition des liens de défiance en fonction du rapport "accords négatifs sur accords" (à gauche) et du score négatif (à droite). Corpus Epinions

(e.g. factorisation matricielle), ainsi que dans les réseaux sociaux, pour proposer des nouveaux liens entre utilisateurs.

En particulier, nous avons souligné le fait que les mesures actuelles de similarité ne prenaient pas ou mal en compte la polarité des notes, ainsi que les biais liés au fait que certains items sont plus jugés positivement ou négativement, et que les utilisateurs ont une propension à noter positivement ou négativement qui leur est particulière.

Nous avons proposé deux scores, un score positif et un négatif, qui mesurent avec quel écart par rapport à l'aléatoire deux utilisateurs ont noté les mêmes items positivement ou négativement. Nous avons ensuite montré comment ces scores sont corrélés avec la différences de jugement des utilisateurs (filtrage collaboratif) et avec les liens de confiance dans un réseau social. En particulier, nous avons pu mettre au jour trois différents types de relation entre les utilisateurs : les utilisateurs similaires, les utilisateurs proches et les utilisateurs neutres. Les utilisateurs similaires notent de la même manière et sont reliés par des liens sociaux positifs (confiance). Les utilisateurs proches s'intéressent aux mêmes thèmes, mais n'aiment pas les mêmes produits ; ils sont souvent reliés par des liens sociaux négatifs. Quant aux utilisateurs neutres, leurs jugements communs ne sont dus qu'au hasard et ils ne sont généralement pas reliés dans le graphe social.

Il y a deux axes de développement, à savoir l'intégration de telles mesures dans les systèmes de recommandation, et l'amélioration des mesures, comme par exemple les rendre moins sensibles lorsque le nombre de jugements commun est petit.

7. Bibliographie

- Bellogín A., de Vries A. P., « Understanding Similarity Metrics in Neighbour-based Recommender Systems », *Proceedings of the 2013 Conference on the Theory of Information Retrieval, ICTIR '13*, ACM, New York, NY, USA, p. 13 :48-13 :55, 2013.
- Bobadilla J., Ortega F., Hernando A., Gutiérrez A., « Recommender systems survey », *Knowledge-Based Systems*, 2013.

- Crandall D., Cosley D., Huttenlocher D., Kleinberg J., Suri S., « Feedback Effects Between Similarity and Social Influence in Online Communities », *Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, KDD '08*, ACM, New York, NY, USA, p. 160-168, 2008.
- Dror G., Koenigstein N., Koren Y., Weimer M., « The Yahoo! Music Dataset and KDD-Cup'11 », *JMLR Workshop and Conference Proceedings*, vol. 18, p. 3-18, 2012.
- Gauthier L., Piwowarski B., Gallinari P., « Filtrage collaboratif et intégration de la polarité des jugements », *CORIA 2014 - Conférence en Recherche d'Informations et Applications-11th French Information Retrieval Conference. CIFED 2014 Colloque International Francophone sur l'Écrit et le Document, Nancy, France, March 19-23, 2014.*, p. 11-26, 2014.
- Koren Y., Bell R., Volinsky C., « Matrix Factorization Techniques for Recommender Systems », *Computer*, vol. 42, n° 8, p. 30-37, August, 2009.
- Kunegis J., Lommatzsch A., Bauckhage C., « The Slashdot Zoo : Mining a Social Network with Negative Edges », *Proceedings of the 18th international conference on World wide web*, 2009.
- Leskovec J., Huttenlocher D., Kleinberg J., « Signed networks in social media », ACM Press, New York, New York, USA, p. 1361, 2010.
- Richardson M., Agrawal R., Domingos P., « Trust Management for the Semantic Web », *IN PROCEEDINGS OF THE SECOND INTERNATIONAL SEMANTIC WEB CONFERENCE*, p. 351-368, 2003.
- Yang S. H., Long B., Smola A., Sadagopan N., Zheng Z., Zha H., « Like like alike Joint Friendship and Interest Propagation in Social Networks », 2011.
- Yang S.-H., Smola A. J., Long B., Zha H., Chang Y., « Friend or Frenemy ? : Predicting Signed Ties in Social Networks », *Proceedings of the 35th International ACM SIGIR Conference on Research and Development in Information Retrieval, SIGIR '12*, ACM, New York, NY, USA, p. 555-564, 2012.

Calcul de l'espérance du gain

Le gain espéré (section 4.1.1) considère toutes les permutations des notes sur un ensemble d'items. Pour le calculer de manière efficace, nous utilisons des techniques combinatoires que nous détaillons ici.

Nous commençons tout d'abord par calculer quel est le gain espéré avec un nombre k donné d'accords de polarité s . Il faut considérer toutes les façons de choisir k items parmi n , ce qui donne :

$$E(G^s(u, v) | k) = \frac{\binom{n-1}{k-1}}{\binom{n}{k}} \sum_{i \in I} g_i^s$$

Pour calculer l'espérance du gain $\mathbb{E}(G^s(u, v))$, il nous reste donc à calculer la probabilité d'avoir k accords de polarité s entre deux utilisateurs. Pour cela nous utilisons la formule du multinôme de Newton qui permet de calculer le nombre de partitions ordonnées. Ainsi, pour un couple (u, v) donné, sachant n le nombre de notes com-

munes, α le nombre de notes de signe s de u et β le nombre de notes de signe s de v , alors le nombre de cas où nous observons avec k accords de signe s est :

$$\binom{n}{k, \alpha - k, \beta - k, n + k - \alpha - \beta} = \frac{n!}{k!(\alpha - k)!(\beta - k)!(n + k - \alpha - \beta)!} \quad [4]$$

Pour obtenir une probabilité, il faut calculer la somme sur tous les k de l'eq. (4), ce qui correspond aux nombres de façons de choisir α et β éléments parmi n :

$$\binom{n}{\alpha} \times \binom{n}{\beta}$$

Finalement, le gain espéré dépend de toutes les combinaisons possibles, i.e. en considérant que k peut prendre ses valeurs dans $\{0, 1, \dots, n\}$ où n est le nombre de notes communes :

$$E(G^s(u, v)) = \frac{\sum_{k=\max(0, \alpha+\beta-n)}^{k=\min(\alpha, \beta)} \binom{n}{k, \alpha - k, \beta - k, n + k - \alpha - \beta} \times E(G^s(u, v)|k)}{\binom{n}{\alpha} \times \binom{n}{\beta}}$$