

商品の評価を対象としたレビュー文の分析

理学専攻 情報科学コース 落合 恵理香 (指導教員: 小林 一郎)

1 はじめに

近年, インターネットの発達により, Web サイトを通して, 商品に対する意見を発信する機会が増加してきている. このような商品に対する意見(以下, レビュー文)は, 個人が商品を購入する際に非常に有益である. しかし, 商品に対するレビュー文の量は膨大であることから, 人がレビュー文の内容を一つずつ分類する作業を行うのは, 非常に困難である. そのため, 膨大な量のレビュー文から商品に関する情報を抽出し, 比較する手法の必要性があり, 様々な研究が行われている[1][2].

本研究では, レビュー文から商品の情報を抽出し, トピックモデルを利用することによって, 商品に対する潜在的なトピックの観点から比較を行う手法を提案する.

2 潜在的な意味に基づく商品の比較

本研究では, 商品が持つ潜在的な特性の観点から比較を行うために, レビューにおいて商品の特徴を捉える単位を対象に LDA (Latent Dirichlet Allocation) [3] を用いて潜在的な意味の抽出を行うことを考える. 通常, LDA では単語を潜在的意味の割り当て対象として利用しているが, 本研究においては, 商品の特性を捉えやすい単位として述語項構造を利用する.

2.1 LDA

LDA とは, 文書中の単語は独立に出現しているのではなく, 潜在的なトピックに基づいて出現するという考えに基づいた文書生成モデルである.

LDA の生成過程を以下に示す.

$$\phi_k \sim Dir(\beta)$$

$$\theta_d \sim Dir(\alpha)$$

$$z_{d,i} \sim Multi(\theta_d) \text{ and } w_{d,i} \sim Multi(\phi_{z_{d,i}})$$

k はトピックの番号, d は文書の番号を表す. また, ϕ_k はトピック k における単語出現確率ベクトルを, θ_d は, 文書 d におけるトピックの出現確率ベクトルを表す. $z_{d,i}$ は文書 d 中の i 番目のトークンが割り当てられたトピック, $w_{d,i}$ は文書 d 中の i 番目に出現したトークンをそれぞれ表す. 本研究においてサンプリングには, ギブスサンプリングを用いている.

LDA を用いることによって, 表層的な表現の違いにより区別されていた語を関係付けることが可能となる.

2.2 素性ベクトル生成

通常, LDA では, 文書内の語彙関係を考慮せず, 単語の出現頻度のみを用いる bag-of-words 方式を採用しているが, 本研究では, LDA で確率割り当ての素性単位を単語から述語項構造を考慮した単語の組に変更することで, 係り受け関係を含めた単語間の依存関係を捉えた潜在的意味の抽出を行う. LDA によって確率を割り当てる対象を単語から述語項構造を基本とする単語の組に変更することから, 係り受け解析器 CaboCha[4]

を用いて, 動詞, 形容詞または形容動詞が存在する句を取り出す. 動詞によって商品の取り扱いに対する特徴が抽出され, 形容詞によって商品の状態や評価を表している. 最終的に単語の組にする際には, それらの品詞を含む句を対象に, その句に係る句の中に, 名詞または副詞が存在した場合に一つの組とする. この素性を用いて, レビュー文書を素性ベクトルにして利用する.

3 実験

3.1 使用データ

対象とするレビュー文書に株式会社アイスタイルの化粧品クチコミサイト@cosme[5] のレビュー文書を用いる.

今回用いたデータの詳細を以下に示す.

期間: 2010年2月1日から2011年1月31日

商品: 期間内の上位20以内にランキングされた商品

カテゴリ: 口紅・グロス・リップライナー

文書数(文の数): 97030文

3.2 潜在トピック推定

LDA を使用する際に, 一文を一文書として「口紅・グロス・リップライナー」のカテゴリ内のレビュー文書を全文書集合とする. これに LDA を適用することにより一つのレビュー文書内に含まれるトピックを抽出する.

今回の実験において, トピック数は, モデルの指標であるパープレキシティを用いて予備実験を行なうことにより決定した. 予備実験によって得たトピック数15を与えることで, LDA による潜在的トピックの推定を行った. 推定後, 各文のトピック分布に基づく分類を行ない, 出力文を選択することによって, 商品の比較が行えるようにした.

4 結果と考察

4.1 実験結果

表1にあるトピック(「使用時の唇の乾燥」と推定)に関する各商品のレビュー文の比較を示す. これは, まず, 各文に対して最終的に割り当てられた各トピックの確率 θ_d の値の中で一番高いものをその文の該当トピックとし, 該当トピックごとに文を集め, そのレビュー文集合中で該当トピックの確率が高い順番に並べる. その後, 商品ごとに分類したものの上位3件を記載したものである.

4.2 考察

表1において, 商品Cを使用することによって, 唇が乾燥しやすくなってしまおうという特徴がみられる. また, 商品Bは他のものよりも, 使用することによって潤いが保たれる記述がみられる.

表 1: トピック（使用時の唇の乾燥）に関する記述であると推定された各商品に対するレビュー文

トピック	商品 A	商品 B	商品 C
使用時の唇の乾燥	<ul style="list-style-type: none"> • ただひとつ欠点は、唇があれやすく、特にここのを使うと月に何度か、どうしようもなくポロポロ皮がむけるという状態になってしまいます… • 唇のケアはきちんとしているので皮がむけたりはしませんが、やっぱり乾燥するので下地のリップクリームは必須ですね；あとグロスを重ねると色持ちもいいですし乾燥も防げると思っています • 塗る前から唇が荒れて皮が剥けたりしているときはリップクリームと保湿効果のあるグロス（[商品 A のメーカー]のものではないけど）を塗って、唇の皮が柔らかくなってから皮剥けの処理をしています 	<ul style="list-style-type: none"> • この季節になると、乾燥して口が皮むけしてしまったりするのですが、ベースにリップをぬってこれをつけたら、ちゃんと縦じわが目立たなくなります • 唇が荒れやすいので、口紅を塗ってもがさがさするのが嫌で、普段はリップクリームのみで済ませてしまうことが多いのですが…これは荒れてても潤ってくれます • （ちょっと大人なお姉さまが使う感じだったので）いつもは乾燥して唇の皮がめくれていたり、血がでていて、口紅を塗る気になれなかったのですが、これだったらいけます 	<ul style="list-style-type: none"> • また、皮がむけたり、唇がガサガサになったりしなかったのも良かったです • 重ねて塗れば唇がぱっきりオレンジになっていてまさに見たまんまの発色 • 唇がバサバサになっているので一度リップを全て落とし、乾いた唇の皮もきれいにオフして、リップで保湿してから…高い商品じゃないし、こんなもんかな

5 評価

5.1 評価アンケート内容

この研究を評価するに当たり、20代女性11人にアンケートを行った。アンケートは被験者が表1のトピックの意味を伏せたものを閲覧した上で、以下の問いに回答する形式で行った。

問1. 商品を比較する上で有益かどうかを5段階評価（5:とてもよい 4:よい 3:ふつう 2:あまりよくない 1:よくない）

問2. 問1.の理由

問3. 抽出されたトピックはそれぞれ違う項目として判断できる内容かを5段階評価（5:非常に判断しやすい 4:判断しやすい 3:ふつう 2:あまり判断しにくい 1:判断しにくい）

問4. 抽出されたトピックは、それぞれ何についてのトピックだと推測したかを自由形式で回答

5.2 アンケート結果

問1に関しては、4(よい)を選択する人が一番多く、5段階評価の平均4.00、標準偏差0.63という結果になった。その理由として問2に記述されていた内容は「項目ごとに分かれているため購入の際に自分の気になる項目をチェックできると思うから」という意見が挙げられていた。

問3に関しては、5(非常に判断しやすい)と4(判断しやすい)を選択する人が一番多く、平均4.1、標準偏差0.81となった。また、問4においてトピックに対して項目を推測し記述する結果は、「荒れ具合の項目」「口唇の保湿」「口紅を塗ったことによる唇の乾燥具合」など、唇の乾燥についての記述で統一されていた。

5.3 考察

アンケートの結果から、今回の手法が商品比較にとつて有益であることが示された。その一方で、レビュー文の中には、該当トピックのレビュー文として判断し

にくいものも含まれていることが述べられていた。原因として考えられることは、文に対して与えられたトピックの割合の最大値のみを考慮しているため、他のトピックとの割合の差が無いものも出力されることが挙げられる。改善策として、文における各トピックの割合の差分を考慮することで、他のトピックにおいても確率が高い文を除外することが考えられる。

6 おわりに

本研究では、化粧品に関するレビュー文書中の潜在トピックを分析することにより、商品の比較を行った。文書中の潜在的な意味を取り扱うことより、レビュー文書の表層的な表現に捉われないトピックの抽出が可能となり、柔軟な比較が可能となった。また、表1に示されたあるトピックの下に抽出された文によるそれぞれの商品の比較の有効性を被験者実験によって判定した結果、ほとんどの被験者から有効であるという回答を得ることができた。

今後の課題として、提案した素性を使用した際に、明確に判別できないトピックの存在や複数のトピックに共通する素性の出現などもあることから、LDAの確率割り当ての単位となる素性の設定の仕方などをさらに検討する必要がある。

参考文献

- [1] 立石健二, 福島俊一, 小林のぞみ, 高橋哲朗, 藤田篤, 乾健太郎, 松本裕治: Web文書集合からの意見情報抽出と着眼点に基づく要約生成, 情報処理学会研究報告NL-163, pp. 1-8(2004)
- [2] 杉木健二, 松原茂樹: カスタマーレビューに基づく商品検索のための感性表現ソーラスの構築, 言語処理学会第15回年次大会発表論文集, pp. 781-784(2009)
- [3] David M. Blei, Andrew Y. Ng, and Michael I. Jordan. : Latent Dirichlet Allocation, *Journal of Machine Learning Research*, 3:993-1002(2003)
- [4] CaboCha, <http://code.google.com/p/cabocho/>
- [5] @cosme, <http://www.cosme.net/>