

# 不当な商品レビューによる評価の是正方法に関する一考察

広瀬研究室 4年 C1172313 佐藤利紀

## 概要

商品レビューには記述者の人為的なミスによって評価値とレビューの記述内容が食い違っている場合がある。これはレビュー数が少ない商品の評価値に大きく作用し、適切な評価が反映されず、消費者の購買意思決定や企業の商品ブランドに強い影響を及ぼす。そこで本研究では、その商品カテゴリの高評価のレビュー群に現れる「ポジティブ語」、低評価のレビュー群に現れる「ネガティブ語」を抽出し、レビュー数の多寡に囚われない商品評価のサポートを図る。そして商品に下された不当な評価の是正を目指す。

## 1 はじめに

近年、著しい情報技術の発展によって、あらゆる情報が開示され、AIによる作業の効率化がなされている。しかし、どんな作業にも人手が加わり、そこに人為的なミスが生じる。その一例が商品レビューである。商品レビューネットショッピングサイトにおいて、その商品に対する評価を評価値とレビュー文で表したものである。商品レビューの集計や整理は自動で行われるものの、商品レビュー自体を記述し投稿する作業は人手で行われる。そのため、評価値とレビュー文の内容が食い違ってしまう可能性がある。たとえば、本の商品レビューにおいて、評価値が低いにもかかわらず「面白い」というレビュー文が書かれているなどの不一致が考えられる。多くのレビューが寄せられた商品の場合、このような評価値と文章が不一致のレビューあまり問題視されないが、寄せられたレビューが少ない商品の場合、問題が生じる。ネットショッピングサイト「Amazon」<sup>1</sup>における商品の評価値は寄せられた商品レビューの評価値の加重平均となっている[1]。これはレビューの多寡によって商品レビュー1つあたりの評価の重みが異なるといえる。そのため、寄せられたレビューが少ない商品だと商品レビュー1つがその商品の評価値に及ぼす影響が大きいと考えられる。その商品レビューの中に評価値と文章が不一致のレビューがあった場合、商品の評価値が正当に反映されず、消費者の購買意思決定の妨げや企業の商品ブランド低下などにつながる恐れがある。

そこで本研究では商品カテゴリごとの商品レビューをテキストマイニングしこの問題の解決を図る。具体的には、評価値ごとの主要な単語を見出し、それらの単語を評価値によってその商品カテゴリのネガティブ語とポジティブ語に分類する。これを用い高評価のレ

ビューに含まれるネガティブ語もしくは低評価レビューに含まれるポジティブ語を見出す手法を提案する。そして不当なレビューが混在した商品の評価の是正を目指す。

## 2 テキストマイニングと関連研究

テキストマイニングとは形式化されていない大量のテキストデータを分析して有用な情報を抽出することである[2, 3]。商品レビューのような大量のテキストデータの分析にこのテキストマイニングの技術が用いられる[4]。商品レビュー分析に使われるテキストマイニングでは、主に形態素解析<sup>2</sup>によって単語の出現頻度の偏りなどから意見の傾向を可視化する研究がなされている[5]。

商品レビューの分析に関する研究はいくつかある。河野ら[6]の研究では対象、属性、評価表現の単語とその係り受け情報を用いて評価情報を抽出している。那須川ら[7]の研究では「けれども」や「しかし」といった接続表現の周辺に出現する単語を抽出し、好評もしくは不評の極性を付与している。

しかし、河野らの研究では対象、属性、評価表現が完全に揃った文を対象としており、不完全な日本語の表現は想定されていない。たとえば「パソコンの価格は安い」など対象「パソコン」、属性「価格」、評価表現「安い」が揃った文は対象とされているが、「これは安い」といった対象と属性が含まれていない文はこの方法では抽出できない。一方、那須川らの研究では人的過誤による好評、不評の解釈については想定されていない。そこで本研究ではレビューに含まれる単語に焦点をあて、その商品カテゴリ内における高評価、低評価それぞれの特徴となる単語の抽出を試みる。ま

<sup>1</sup><https://www.amazon.co.jp/>

<sup>2</sup>品詞情報や文法などをもとに文章を単語に分解すること。

た、不当なレビューに着目した分析、考察を行うことで人為的ミスによって生じる不正確な商品評価の是正を目指す。

### 3 商品レビューの分析

#### 3.1 研究手順

まずネットショッピングサイトの商品レビューを統計分析ソフト「R」<sup>3</sup>を用いて収集する。本研究では評価値と商品カテゴリのフィルタリングが可能なネットショッピングサイト「Amazon」のレビューを使用する。評価値だけでなく商品化カテゴリごとにも分類する理由は商品カテゴリごとに評価の指標となる単語の偏りが異なると考えたためである。

次に学習用データと評価用データについて述べる。学習用データはレビュー文に含まれる主要な単語の抽出方法を構築するためのレビュー群である。一方、評価用データは構築した抽出方法を評価するためのレビュー群である。収集したレビューをあらかじめこの2つに分類することで後の検証に使用する。

次に主要な単語の抽出方法について述べる。まずレビューの評価値から学習用データの商品レビューを商品カテゴリごとに高評価レビュー、低評価レビューに分類し形態素解析ソフト「RMeCab」<sup>4</sup>を用いて形態素解析を行う。次に高評価レビュー、低評価レビューそれぞれの単語の出現頻度の高い順に並べ順位をナンバリングする。ここで高評価、低評価における頻出単語の順位差を求める。本研究では、この差が大きいほどその商品カテゴリにおける高評価、低評価のレビューの主要な単語とみなし、高評価レビューにおける主要な単語を「ポジティブ語」、低評価レビューにおける主要な単語を「ネガティブ語」と定義する。

最後に評価用データから学習用データで求めたポジティブ語、ネガティブ語を抽出し、その結果の妥当性と評価是正の可能性について考察する。

#### 3.2 商品レビューの収集

Amazonにおける商品カテゴリ「本」<sup>5</sup>と商品カテゴリ「ノート PC」それぞれの商品レビュー合計 1600 件<sup>6</sup>を R で収集した。Amazon ではレビューが 5 段階評価でその商品の評価値を付与する。そこで本研究ではこの評価値が最高の 5 である商品レビューを高評価レビュー、1 もしくは 2 である商品レビューを低評価レビューとみなした。1 商品に対して高評価レビュー 50

件、低評価レビュー 50 件集めるものとし、これを商品カテゴリ「本」においては 10 商品分、商品カテゴリ「ノート PC」においては 6 商品分のレビューを収集した。商品の選定については Amazon 上でその商品カテゴリの売れ筋ランキング上位から、高評価レビュー、低評価レビューを 50 件ずつ集めることが可能な商品とした。この 1600 件の商品レビューの内、半分を学習用データ、もう半分を評価用データとして活用する(表 1)。

表 1: 収集した商品レビューの件数の内訳

商品カテゴリ	データ項目	高評価レビュー	低評価レビュー	合計
本	学習用データ	250	250	500
	評価用データ	250	250	500
ノート PC	学習用データ	150	150	300
	評価用データ	150	150	300
	合計	800	800	1600

#### 3.3 ポジティブ語・ネガティブ語の抽出

次にポジティブ語・ネガティブ語の抽出について述べる。まず、RMeCab を用いて商品カテゴリおよび高評価、低評価ごとの学習用データのレビューから単語の出現頻度、品詞を求めた。さらに単語ごとの高評価、低評価における出現頻度の順位を求め、その順位差を算出した。この順位差を求める式は以下のとおりである。

高評価レビューの順位差 =

$$\text{その単語の低評価レビューにおける出現頻度の順位} - \text{その単語の高評価レビューにおける出現頻度の順位}$$

低評価レビューの順位差 =

$$\text{その単語の高評価レビューにおける出現頻度の順位} - \text{その単語の低評価レビューにおける出現頻度の順位}$$

そして各学習データにおいてこれらをまとめた頻出上位 10 単語を表 2、表 3、表 4、表 5 に示す。

表 2、表 3、表 4、表 5 から記号、助詞、助動詞の単語が頻出していることが確認できる。またこれらの品詞の単語において、高評価、低評価における単語の出現頻度の順位差は絶対値 5 未満となっており、高評価、低評価の順位差は大きくなりにくいと考えられる。そのため本研究では記号、助詞、助動詞はポジティブ語・ネ

<sup>3</sup><https://www.r-project.org/>

<sup>4</sup><http://taku910.github.io/mecab/>

<sup>5</sup>「ビジネス・経済」のジャンル。

<sup>6</sup>2020 年 8 月 25 日時点のデータ。

表 2: 商品カテゴリ「本」の高評価レビューにおける頻出上位 10 単語

単語	品詞	品詞細分類	出現頻度	順位	順位差
、	記号	読点	1705	1	0
の	助詞	連体化	1484	2	1
。	記号	句点	1456	3	-1
を	助詞	格助詞	1367	4	4
に	助詞	格助詞	1228	5	4
て	助詞	接続助詞	1196	6	0
は	助詞	係助詞	1120	7	-3
が	助詞	格助詞	981	8	-1
だ	助動詞	*	932	9	-4
する	動詞	自立	897	10	0

表 3: 商品カテゴリ「本」の低評価レビューにおける頻出上位 10 単語

単語	品詞	品詞細分類	出現頻度	順位	順位差
、	記号	読点	1661	1	0
。	記号	句点	1384	2	1
の	助詞	連体化	1234	3	-1
は	助詞	係助詞	1086	4	3
だ	助動詞	*	1019	5	4
て	助詞	接続助詞	1014	6	0
が	助詞	格助詞	905	7	1
を	助詞	格助詞	900	8	-4
に	助詞	格助詞	888	9	-4
する	動詞	自立	781	10	0

ガティブ語になりにくい単語とみなし、これらの品詞を除外しポジティブ語・ネガティブ語の抽出を試みる。

出現頻度の順位差でポジティブ語・ネガティブ語の抽出を試みるにあたり、単語の有効性の検証のため出現頻度の閾値を設ける必要がある。しかし商品カテゴリごとの学習データのサンプル数が異なるため出現頻度から閾値を求めることはできない。そのため単語の出現頻度を単語の総出現数で割った出現率を求める<sup>7</sup>。本研究ではこの出現率 0.001 を閾値とし、出現率がこの数値以上の単語を有効な単語とみなす。出現率 0.001 以上でフィルタリングし、順位差の降順に並び替えた上位 20 単語を表 6、表 7、表 8、表 9 に示す<sup>8</sup>。

本研究ではこの表 6 で示した 20 単語を商品カテゴリ「本」のポジティブ語、表 7 で示した 20 単語を商品カテゴリ「本」のネガティブ語とする。同様に表 8 で示した 20 単語を商品カテゴリ「ノート PC」のポジティブ語、表 9 で示した 20 単語を商品カテゴリ「ノート PC」のネガティブ語とする。

<sup>7</sup> 小数第六位を四捨五入。

<sup>8</sup> "N/A" は高評価、低評価いずれかのレビュー群に出現しなかったことを表す。

表 4: 商品カテゴリ「ノート PC」の高評価レビューにおける頻出上位 10 単語

単語	品詞	品詞細分類	出現頻度	順位	順位差
。	記号	句点	1216	1	0
、	記号	読点	1112	2	0
た	助動詞	*	1042	3	0
ます	助動詞	*	936	4	4
て	助詞	接続助詞	878	5	0
の	助詞	連体化	833	6	0
は	助詞	係助詞	795	7	2
する	動詞	自立	723	8	-4
に	助詞	格助詞	639	9	1
が	助詞	格助詞	634	10	-3

表 5: 商品カテゴリ「ノート PC」の低評価レビューにおける頻出上位 10 単語

単語	品詞	品詞細分類	出現頻度	順位	順位差
。	記号	句点	673	1	0
、	記号	読点	541	2	0
た	助動詞	*	518	3	0
する	動詞	自立	458	4	4
て	助詞	接続助詞	432	5	0
の	助詞	連体化	422	6	0
が	助詞	格助詞	408	7	3
ます	助動詞	*	377	8	-4
は	助詞	係助詞	364	9	-2
に	助詞	格助詞	294	10	-1

## 4 今後の展望

評価用データを用い抽出したポジティブ語・ネガティブ語の妥当性を検証する。そして得られた結果から、商品の評価是正の可能性について考察する。

## 参考文献

- [1] Ben Fox Rubln,cnet.”<https://www.cnet.com/news/amazon-updates-customer-reviews-with-new-machine-learning-platform/>”.2015
- [2] 石田基広,R によるテキストマイニング入門 第 2 版, 森北出版,2017
- [3] 小林雄一郎,R によるやさしいテキストマイニング, オーム社,2017
- [4] 那須川哲哉, テキストマイニングを使う技術/作る技術:基礎技術と適用事例から導く本質と活用法, 東京電気大学出版局,2006
- [5] 乾孝司, 奥村学. テキストを対象とした評価情報の分析に関する研究動向. 自然言語処理,13(3),pp.201-241,2006

[6] 河野一志, 町田翔, 村松拓実, 小林美穂, 延澤志保. 不特定分野のレビューを対象とした評価情報の自動認識. 情報処理学会第 79 回全国大会, 3Q-06, pp.535-536, 2017

[7] 那須川哲哉, 金澤博. 文脈一貫性を利用した極性付評価表現の語彙獲得. 情報処理学会研究報告自然言語処理, pp.109-116, 2004

表 6: 商品カテゴリ「本」の高評価レビューにおける順位差上位 20 単語

単語	品詞	品詞細分類	出現頻度	出現率	順位	順位差
○	名詞	サ変接続	24	0.00146	96	N/A
分断	名詞	サ変接続	20	0.00122	127	N/A
気づく	動詞	自立	39	0.00238	55	964
見方	名詞	一般	23	0.00140	100	919
教える	動詞	自立	17	0.00104	149	870
本能	名詞	一般	97	0.00591	13	695
+	名詞	サ変接続	54	0.00329	31	677
相手	名詞	一般	43	0.00262	48	660
物事	名詞	一般	21	0.00128	118	590
対人	名詞	一般	19	0.00116	135	573
上司	名詞	一般	17	0.00104	149	559
ひとつ	名詞	副詞可能	17	0.00104	149	559
基づく	動詞	自立	27	0.00164	85	481
すぐ	副詞	助詞類接続	23	0.00140	100	359
事実	名詞	副詞可能	44	0.00268	46	332
悩み	名詞	一般	24	0.00146	96	282
原因	名詞	一般	25	0.00152	92	196
思い込み	名詞	一般	60	0.00366	23	187
勧める	動詞	自立	19	0.00116	135	191
他者	名詞	一般	56	0.00341	28	182

表 7: 商品カテゴリ「本」の低評価レビューにおける順位差上位 20 単語

単語	品詞	品詞細分類	出現頻度	出現率	順位	順位差
君	名詞	代名詞	16	0.00112	133	N/A
ページ	名詞	一般	17	0.00119	119	1513
こういう	連体詞	*	15	0.00105	147	1485
人達	名詞	一般	17	0.00119	119	995
使える	動詞	自立	17	0.00119	119	710
彼	名詞	代名詞	17	0.00119	119	710
哲学	名詞	一般	20	0.00140	91	570
なぜ	副詞	助詞類接続	17	0.00119	119	542
設定	名詞	サ変接続	15	0.00105	147	406
アクセス	名詞	サ変接続	22	0.00154	77	400
日本語	名詞	一般	20	0.00140	91	386
印象	名詞	一般	19	0.00133	102	375
チンパンジー	名詞	一般	15	0.00105	147	330
当たり前	名詞	形容動詞語幹	19	0.00133	102	318
語る	動詞	自立	18	0.00126	109	311
無駄	名詞	形容動詞語幹	18	0.00126	109	311
こんな	連体詞	*	18	0.00126	109	311
筆者	名詞	一般	24	0.00168	71	291
トラウマ	名詞	一般	23	0.00161	73	289
感じ	名詞	一般	23	0.00161	73	289

表 8: 商品カテゴリ「ノート PC」の高評価レビューにおける順位差上位 20 単語

単語	品詞	品詞細分類	出現頻度	出現率	順位	順位差
自分	名詞	一般	22	0.00175	99	N/A
順	名詞	固有名詞	22	0.00175	99	N/A
ありがとう	感動詞	*	18	0.00144	132	N/A
笑	名詞	固有名詞	16	0.00128	144	N/A
心配	名詞	サ変接続	15	0.00120	152	N/A
最高	名詞	一般	14	0.00112	163	N/A
耐久	名詞	一般	14	0.00112	163	N/A
バージョン	名詞	一般	13	0.00104	173	N/A
機能	名詞	サ変接続	20	0.00159	114	700
買い物	名詞	サ変接続	18	0.00144	132	682
ちょっと	副詞	助詞類接続	17	0.00136	139	675
嬉しい	形容詞	自立	15	0.00120	152	662
速い	形容詞	自立	15	0.00120	152	662
メモリー	名詞	一般	15	0.00120	152	662
2020	名詞	数	15	0.00120	152	662
多少	副詞	助詞類接続	13	0.00104	173	641
安心	名詞	サ変接続	13	0.00104	173	641
軽い	形容詞	自立	24	0.00191	86	439
和	名詞	固有名詞	23	0.00183	92	433
大変	名詞	形容動詞語幹	21	0.00167	104	421

表 9: 商品カテゴリ「ノート PC」の低評価レビューにおける順位差上位 20 単語

単語	品詞	品詞細分類	出現頻度	出現率	順位	順位差
返金	名詞	サ変接続	12	0.00190	76	N/A
使い物	名詞	一般	11	0.00174	86	N/A
落ちる	動詞	自立	7	0.00111	156	N/A
広告	名詞	サ変接続	7	0.00111	156	N/A
表記	名詞	サ変接続	8	0.00127	132	1129
失う	動詞	自立	7	0.00111	156	1105
詐欺	名詞	サ変接続	11	0.00174	86	764
最悪	名詞	一般	11	0.00174	86	764
型番	名詞	一般	10	0.00158	104	746
回答	名詞	サ変接続	7	0.00111	156	694
電話	名詞	サ変接続	7	0.00111	156	694
自体	名詞	一般	7	0.00111	156	694
アマゾン	名詞	一般	13	0.00206	71	568
Amazon	名詞	一般	10	0.00158	104	535
仕方	名詞	ナイ形容詞語幹	9	0.00143	116	523
安物	名詞	一般	8	0.00127	132	507
不良	名詞	形容動詞語幹	8	0.00127	132	507
再度	副詞	助詞類接続	7	0.00111	156	483
販売元	名詞	一般	7	0.00111	156	483
ダメ	名詞	形容動詞語幹	7	0.00111	156	483