

ポジティブ語・ネガティブ語抽出による
不当なレビュー評価のは正方法に関する一考察

廣瀬研究室 4年 C1172313 佐藤利紀

概要

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。商品レビューとは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、商品レビュー 자체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は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。なぜなら寄せられたレビューが少ない商品の場合、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ためだ。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。(714字)

目 次

| | |
|--|----|
| 第 1 章 はじめに | 5 |
| 第 2 章 テキストマイニングと関連研究 | 7 |
| 第 3 章 商品レビューの分析 | 9 |
| 3.1 研究手順 | 9 |
| 3.2 商品レビューの収集 | 9 |
| 3.3 RMeCab による形態素解析 | 10 |
| 3.4 ポジティブ語・ネガティブ語の抽出 | 13 |
| 3.5 妥当性の検証 | 16 |
| 3.5.1 商品カテゴリ「本」の高評価レビューにおける有意差の有無 | 19 |
| 3.5.2 商品カテゴリ「本」の低評価レビューにおける有意差の有無 | 19 |
| 3.5.3 商品カテゴリ「ノート PC」の高評価レビューにおける有意差の有無 | 19 |
| 3.5.4 商品カテゴリ「ノート PC」の低評価レビューにおける有意差の有無 | 20 |
| 第 4 章 考察 | 21 |
| 4.1 ポジティブ語・ネガティブ語の抽出に関する考察 | 21 |
| 4.2 不当なレビュー抽出に関する考察 | 21 |
| 第 5 章 結論 | 25 |

第1章 はじめに

近年、ネットショッピングの台頭により企業は新たなマーケティングの機会を獲得している[1]。その中で企業が消費者の意見を知る情報源として、商品レビューがある。商品レビューは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。商品レビューを分析することで商品改善や新商品の企画などのマーケティングに活かす試みが行われている[2]。

しかし、商品レビューはレビュワーが人手で記入・投稿するため、意図的な荒らしやヒューマンエラーによる誤評価などにより評価値とレビュー文の内容の食い違いが起きる可能性がある。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は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 Amazon¹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[3]。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。そのため現在では E-Guardian²のようなレビューを監視する企業も登場している。しかし、AIで判別が難しい言葉は人手で監視しており、商品レビューのような大量のテキストデータを人手で判断するのは多大な労苦を強いられる。

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は正を目指す。

¹<https://www.amazon.co.jp/>

²<https://www.e-guardian.co.jp/>

第2章 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 [4, 5]。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 [6]。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¹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 [7]。

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 [8] 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 [9] 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はざむを指す。

¹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。

第3章 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 R¹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 RMeCab²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の差を求める。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 のレビューには以下のような情報が記載されている。

- レビュー文
- 評価値
- レビュワーの名前
- 投稿日時

レビュワーは投稿の際、5段階評価でその商品の評価値を付与する。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

¹統計解析に適したフリーソフトウェア。

²R から日本語のテキストやファイルを指定して MeCab に解析させ、その結果を R で標準的なデータ形式に変換して出力するインターフェイス。

ビューとみなした。そして、2020年8月25日時点のAmazonにおける商品カテゴリ「本」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件のレビュー文をRを用いてテキストファイル形式で収集した。商品カテゴリ「本」においては、出現単語のばらつきを抑えるため、「ビジネス・経済」ジャンルのみとした。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、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、残り半分を評価用データとして活用する(表3.1)。

表3.1: 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 RMeCabによる形態素解析

次に収集したレビューをRMeCabで形態素解析する。短いテキストを分析する場合は「RMeCabC」コマンド、任意のテキストファイルの形態素解析結果を全て出力する場合は「RMeCabText」コマンドを使用する。その出力結果の一例を以下に示す。

```
> library(RMeCab)
> a <- RMeCabC("とても面白かったです")
> a
[[1]]
 副詞
"とても"

[[2]]
 形容詞
"面白かっ"

[[3]]
 助動詞
"た"

[[4]]
 助動詞
"です"
```

```
> b <- RMeCabText("F:/data/review.txt")
file = F:/data/review.txt
> b
[[1]]
[1] "とても"      "副詞"      "助詞類接続"
[4] "*"          "*"          "*"
[7] "*"          "とても"      "トテモ"
[10] "トテモ"

[[2]]
[1] "面白かつ"    "形容詞"
[3] "自立"        "*"
[5] "*"          "形容詞・アウオ段"
[7] "連用タ接続"  "面白い"
[9] "オモシロカツ" "オモシロカツ"

[[3]]
[1] "た"          "助動詞"    "*"
[4] "*"          "*"          "特殊・タ"
[7] "基本形"      "た"          "タ"
[10] "タ"

[[4]]
[1] "です"        "助動詞"    "*"
[4] "*"          "*"          "特殊・デス"
[7] "基本形"      "です"      "デス"
[10] "デス"
```

本研究ではテキストファイルから単語の出現頻度を求めるため、ファイル指定およびテキストの語彙と頻度一覧の作成ができる「RMeCabFreq」コマンドを使用する。そして分析のため解析結果を csv 形式で出力する。csv 形式で出力する流れと、解析結果の冒頭部分を以下に示す³。

```

> book_Hrev_tra <- RMeCabFreq("F:/review/book_Hrev_tra.txt")
file = F:/review/book_Hrev_tra.txt
length = 3765
> write.table( book_Hrev_tra ,file="F:/review/book_Hrev_tra_freq.csv",sep=",")
> library(dplyr)
> book_Hrev_tra %>% head()
      Term   Info1 Info2 Freq
1  その フィラー     *    1
2  なんか フィラー   *    1
3  ま フィラー     *    1
4  ああ 感動詞     *    1
5  ありがとう 感動詞   *    7
6  え 感動詞     *    1

```

この解析を4つの学習用データに行う。そして、得られた解析結果を使いポジティブ語・ネガティブ語の抽出を行う。

³Term は単語、Info1 は品詞大分類、Info2 は品詞細分類、Freq は単語の出現頻度を表す。

3.4 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を使用し得られた商品カテゴリおよび高評価レビュー、低評価レビューごとの単語の出現頻度からその順位を求める。そして同じ商品カテゴリ内の高評価レビュー、低評価レビューそれぞれにおける単語の出現頻度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。

Hd : 高評価レビューの順位差

Ld : 低評価レビューの順位差

Hr : 当該単語の高評価レビューでの出現頻度順位

Lr : 当該単語の低評価レビューでの出現頻度順位

$$Hd = Lr - Hr$$

$$Ld = Hr - Lr$$

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 3.2、表 3.3、表 3.4、表 3.5 に示す。

表 3.2: 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 3.3: 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 |

表 3.4: 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 3.5: 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 |

表3.2、表3.3、表3.4、表3.5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⁴。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3.6、表3.7、表3.8、表3.9に示す⁵。

⁴小数第六位を四捨五入。

⁵”N/A”は高評価、低評価いずれかのレビューパターンに出現しなかったことを表す。

表 3.6: 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 3.7: 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 |

本研究ではこの表 3.6 で示した 20 単語を商品カテゴリ「本」のポジティブ語、表 3.7 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 3.8 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 3.9 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。

表 3.8: 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 3.9: 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 |

3.5 妥当性の検証

次に学習用データから抽出したポジティブ語・ネガティブ語の妥当性を評価用データを使って検証する。検証方法としてウィルコクソンの符号付き順位検定を使用する。これは 2 变量 x および y に関する n 組のデータ $(x_1, y_1), \dots, (x_n, y_n)$ が与えられたとき、それらの差を $z_i = y_i - x_i (i = 1, \dots, n)$ とし、 z_i の母集団分布 $f(z)$ の中央値 θ が 0 かどうかを調べる手法である [10, 11]。これを利用し、学習用データにおける变量 x と評価用データにおける变量 y との差から、その差の有意性について調べる。变量 x, y については、学習用データおよび評価用データにおけるポジティブ語・ネガティブ語それぞれの出現率を使用する。なぜなら収集したレビューの件数が同じでもそのレビュー内に含まれる単語の総出現数は異なるためだ。そのため学習用データと同様に評価用データの形態素解析を行う。そして前節で選定した各 20 個のポジティブ語・ネガティブ語の出現率を算出した結果を表 3.10、表 3.11、表 3.12、表 3.13 に示す。

表 3.10: 商品カテゴリ「本」の高評価レビューにおけるポジティブ語の出現率

| ポジティブ語 | 品詞 | 品詞細分類 | 学習用データにおける ポジティブ語の出現頻度 | 学習用データにおける ポジティブ語の出現率 | 評価用データにおける ポジティブ語の出現頻度 | 評価用データにおける ポジティブ語の出現率 |
|--------|----|-------|---------------------------|--------------------------|---------------------------|--------------------------|
| ○ | 名詞 | サ変接続 | 24 | 0.00146 | 0 | 0 |
| 分断 | 名詞 | サ変接続 | 20 | 0.00122 | 0 | 0 |
| 気づく | 動詞 | 自立 | 39 | 0.00238 | 34 | 0.00235 |
| 見方 | 名詞 | 一般 | 23 | 0.00140 | 2 | 0.00014 |
| 教える | 動詞 | 自立 | 17 | 0.00104 | 24 | 0.00166 |
| 本能 | 名詞 | 一般 | 97 | 0.00591 | 1 | 0.00007 |
| + | 名詞 | サ変接続 | 54 | 0.00329 | 33 | 0.00228 |
| 相手 | 名詞 | 一般 | 43 | 0.00262 | 19 | 0.00131 |
| 物事 | 名詞 | 一般 | 21 | 0.00128 | 7 | 0.00048 |
| 対人 | 名詞 | 一般 | 19 | 0.00116 | 1 | 0.00007 |
| 上司 | 名詞 | 一般 | 17 | 0.00104 | 0 | 0 |
| ひとつ | 名詞 | 副詞可能 | 17 | 0.00104 | 4 | 0.00028 |
| 基づく | 動詞 | 自立 | 27 | 0.00164 | 1 | 0.00007 |
| すぐ | 副詞 | 助詞類接続 | 23 | 0.00140 | 20 | 0.00138 |
| 事実 | 名詞 | 副詞可能 | 44 | 0.00268 | 11 | 0.00076 |
| 悩み | 名詞 | 一般 | 24 | 0.00146 | 9 | 0.00062 |
| 原因 | 名詞 | 一般 | 25 | 0.00152 | 3 | 0.00021 |
| 思い込み | 名詞 | 一般 | 60 | 0.00366 | 1 | 0.00007 |
| 勧める | 動詞 | 自立 | 19 | 0.00116 | 10 | 0.00069 |
| 他者 | 名詞 | 一般 | 56 | 0.00341 | 4 | 0.00028 |

表 3.11: 商品カテゴリ「本」の低評価レビューにおけるネガティブ語の出現率

| ネガティブ語 | 品詞 | 品詞細分類 | 学習用データにおける ネガティブ語の出現頻度 | 学習用データにおける ネガティブ語の出現率 | 評価用データにおける ネガティブ語の出現頻度 | 評価用データにおける ネガティブ語の出現率 |
|--------|-----|--------|---------------------------|--------------------------|---------------------------|--------------------------|
| 君 | 名詞 | 代名詞 | 16 | 0.00112 | 0 | 0 |
| ページ | 名詞 | 一般 | 17 | 0.00119 | 6 | 0.00052 |
| こういう | 連体詞 | * | 15 | 0.00105 | 7 | 0.00060 |
| 人達 | 名詞 | 一般 | 17 | 0.00119 | 0 | 0 |
| 使える | 動詞 | 自立 | 17 | 0.00119 | 6 | 0.00052 |
| 彼 | 名詞 | 代名詞 | 17 | 0.00119 | 4 | 0.00034 |
| 哲学 | 名詞 | 一般 | 20 | 0.00140 | 2 | 0.00017 |
| なぜ | 副詞 | 助詞類接続 | 17 | 0.00119 | 18 | 0.00155 |
| 設定 | 名詞 | サ変接続 | 15 | 0.00105 | 0 | 0 |
| アクセス | 名詞 | サ変接続 | 22 | 0.00154 | 0 | 0 |
| 日本語 | 名詞 | 一般 | 20 | 0.00140 | 16 | 0.00138 |
| 印象 | 名詞 | 一般 | 19 | 0.00133 | 14 | 0.00120 |
| チンパンジー | 名詞 | 一般 | 15 | 0.00105 | 0 | 0 |
| 当たり前 | 名詞 | 形容動詞語幹 | 19 | 0.00133 | 16 | 0.00138 |
| 語る | 動詞 | 自立 | 18 | 0.00126 | 7 | 0.00060 |
| 無駄 | 名詞 | 形容動詞語幹 | 18 | 0.00126 | 19 | 0.00163 |
| こんな | 連体詞 | * | 18 | 0.00126 | 26 | 0.00223 |
| 筆者 | 名詞 | 一般 | 24 | 0.00168 | 11 | 0.00095 |
| トラウマ | 名詞 | 一般 | 23 | 0.00161 | 0 | 0 |
| 感じ | 名詞 | 一般 | 23 | 0.00161 | 14 | 0.00120 |

表 3.12: 商品カテゴリ「ノート PC」の高評価レビューにおけるポジティブ語の出現率

| ポジティブ語 | 品詞 | 品詞細分類 | 学習用データにおける ポジティブ語の出現頻度 | 学習用データにおける ポジティブ語の出現率 | 評価用データにおける ポジティブ語の出現頻度 | 評価用データにおける ポジティブ語の出現率 |
|--------|-----|--------|---------------------------|--------------------------|---------------------------|--------------------------|
| 自分 | 名詞 | 一般 | 22 | 0.00175 | 13 | 0.00125 |
| 順 | 名詞 | 固有名詞 | 22 | 0.00175 | 4 | 0.00038 |
| ありがとう | 感動詞 | * | 18 | 0.00144 | 10 | 0.00096 |
| 笑 | 名詞 | 固有名詞 | 16 | 0.00128 | 3 | 0.00029 |
| 心配 | 名詞 | サ変接続 | 15 | 0.00120 | 11 | 0.00106 |
| 最高 | 名詞 | 一般 | 14 | 0.00112 | 14 | 0.00135 |
| 耐久 | 名詞 | 一般 | 14 | 0.00112 | 14 | 0.00135 |
| バージョン | 名詞 | 一般 | 13 | 0.00104 | 1 | 0.00010 |
| 機能 | 名詞 | サ変接続 | 20 | 0.00159 | 6 | 0.00058 |
| 買い物 | 名詞 | サ変接続 | 18 | 0.00144 | 14 | 0.00135 |
| ちょっと | 副詞 | 助詞類接続 | 17 | 0.00136 | 13 | 0.00125 |
| 嬉しい | 形容詞 | 自立 | 15 | 0.00120 | 3 | 0.00029 |
| 速い | 形容詞 | 自立 | 15 | 0.00120 | 16 | 0.00154 |
| メモリー | 名詞 | 一般 | 15 | 0.00120 | 10 | 0.00096 |
| 2020 | 名詞 | 数 | 15 | 0.00120 | 8 | 0.00077 |
| 多少 | 副詞 | 助詞類接続 | 13 | 0.00104 | 10 | 0.00096 |
| 安心 | 名詞 | サ変接続 | 13 | 0.00104 | 12 | 0.00115 |
| 軽い | 形容詞 | 自立 | 24 | 0.00191 | 11 | 0.00106 |
| 和 | 名詞 | 固有名詞 | 23 | 0.00183 | 4 | 0.00038 |
| 大変 | 名詞 | 形容動詞語幹 | 21 | 0.00167 | 9 | 0.00087 |

表 3.13: 商品カテゴリ「ノート PC」の低評価レビューにおけるネガティブ語の出現率

| ネガティブ語 | 品詞 | 品詞細分類 | 学習用データにおける ネガティブ語の出現頻度 | 学習用データにおける ネガティブ語の出現率 | 評価用データにおける ネガティブ語の出現頻度 | 評価用データにおける ネガティブ語の出現率 |
|--------|----|---------|---------------------------|--------------------------|---------------------------|--------------------------|
| 返金 | 名詞 | サ変接続 | 12 | 0.00190 | 4 | 0.00083 |
| 使い物 | 名詞 | 一般 | 11 | 0.00174 | 3 | 0.00062 |
| 落ちる | 動詞 | 自立 | 7 | 0.00111 | 5 | 0.00104 |
| 広告 | 名詞 | サ変接続 | 7 | 0.00111 | 0 | 0 |
| 表記 | 名詞 | サ変接続 | 8 | 0.00127 | 2 | 0.00042 |
| 失う | 動詞 | 自立 | 7 | 0.00111 | 2 | 0.00042 |
| 詐欺 | 名詞 | サ変接続 | 11 | 0.00174 | 5 | 0.00104 |
| 最悪 | 名詞 | 一般 | 11 | 0.00174 | 6 | 0.00125 |
| 型番 | 名詞 | 一般 | 10 | 0.00158 | 0 | 0 |
| 回答 | 名詞 | サ変接続 | 7 | 0.00111 | 3 | 0.00062 |
| 電話 | 名詞 | サ変接続 | 7 | 0.00111 | 2 | 0.00042 |
| 自体 | 名詞 | 一般 | 7 | 0.00111 | 4 | 0.00083 |
| アマゾン | 名詞 | 一般 | 13 | 0.00206 | 6 | 0.00125 |
| Amazon | 名詞 | 一般 | 10 | 0.00158 | 7 | 0.00145 |
| 仕方 | 名詞 | ナイ形容詞語幹 | 9 | 0.00143 | 8 | 0.00166 |
| 安物 | 名詞 | 一般 | 8 | 0.00127 | 2 | 0.00042 |
| 不良 | 名詞 | 形容動詞語幹 | 8 | 0.00127 | 7 | 0.00145 |
| 再度 | 副詞 | 助詞類接続 | 7 | 0.00111 | 3 | 0.00062 |
| 販売元 | 名詞 | 一般 | 7 | 0.00111 | 1 | 0.00021 |
| ダメ | 名詞 | 形容動詞語幹 | 7 | 0.00111 | 4 | 0.00083 |

$f(z)$ の中央値を θ としたとき、各商品カテゴリおよび各レビューの仮説検定において共通する帰無仮説、対立仮説は以下のとおりである。

帰無仮説 (H_0) : 学習用データ (x) と評価用データ (y) との間に単語の出現率の差はない ($H_0 : \theta = 0$)。

対立仮説 (H_1) : 学習用データ (x) と評価用データ (y) との間に単語の出現率の差はある ($H_1 : \theta \neq 0$)。

本研究では有意水準 0.05 とし仮説検定を行う。検定統計量および P 値の算出には R を使用する。

3.5.1 商品カテゴリ「本」の高評価レビューにおける有意差の有無

表3.10で算出した出現率をもとに、商品カテゴリ「本」の高評価レビューにおける学習用データと評価用データで検定を行った結果を以下に示す。

```
Exact Wilcoxon signed rank test

data: book_Hrev_tra_ap and book_Hrev_eva_ap
V = 206, p-value = 1.335e-05
alternative hypothesis: true mu is not equal to 0
95 percent confidence interval:
0.000760 0.001805
sample estimates:
(pseudo)median
0.0011625
```

P値が有意水準0.05以下であることから帰無仮説が棄却され、対立仮説が採択される。つまり学習用データと評価用データとの間におけるポジティブ語の出現率の差は有意な働きを持つと考えられる。

3.5.2 商品カテゴリ「本」の低評価レビューにおける有意差の有無

表3.11で算出した出現率をもとに、商品カテゴリ「本」の低評価レビューにおける学習用データと評価用データで検定を行った結果を以下に示す。

```
Exact Wilcoxon signed rank test

data: book_Lrev_tra_ap and book_Lrev_eva_ap
V = 186, p-value = 0.001383
alternative hypothesis: true mu is not equal to 0
95 percent confidence interval:
0.000285 0.000945
sample estimates:
(pseudo)median
0.0006225
```

P値が有意水準0.05以下であることから帰無仮説が棄却され、対立仮説が採択される。つまり学習用データと評価用データとの間におけるネガティブ語の出現率の差は有意な働きを持つと考えられる。

3.5.3 商品カテゴリ「ノートPC」の高評価レビューにおける有意差の有無

表3.12で算出した出現率をもとに、商品カテゴリ「ノートPC」の高評価レビューにおける学習用データと評価用データで検定を行った結果を以下に示す。

Exact Wilcoxon signed rank test

```
data: pc_Hrev_tra_ap and pc_Hrev_eva_ap
V = 184.5, p-value = 0.001755
alternative hypothesis: true mu is not equal to 0
95 percent confidence interval:
0.000175 0.000740
sample estimates:
(pseudo)median
0.000475
```

P 値が有意水準 0.05 以下であることから帰無仮説が棄却され、対立仮説が採択される。つまり学習用データと評価用データとの間におけるポジティブ語の出現率の差は有意な働きを持つと考えられる。

3.5.4 商品カテゴリ「ノート PC」の低評価レビューにおける有意差の有無

表 3.13 で算出した出現率をもとに、商品カテゴリ「ノート PC」の低評価レビューにおける学習用データと評価用データで検定を行った結果を以下に示す。

Exact Wilcoxon signed rank test

```
data: pc_Lrev_tra_ap and pc_Lrev_eva_ap
V = 203, p-value = 3.433e-05
alternative hypothesis: true mu is not equal to 0
95 percent confidence interval:
0.000385 0.000830
sample estimates:
(pseudo)median
0.0005975
```

P 値が有意水準 0.05 以下であることから帰無仮説が棄却され、対立仮説が採択される。つまり学習用データと評価用データとの間におけるネガティブ語の出現率の差は有意な働きを持つと考えられる。

表 3.14: ウィルコクソンの符号付き順位検定の結果⁸

| 商品カテゴリ | レビューの分類 | 検定統計量 | P 値 | 中央値 |
|--------|---------|-------|----------|----------|
| 本 | 高評価レビュー | 206 | 0.000013 | 0.001163 |
| | 低評価レビュー | 186 | 0.001383 | 0.000623 |
| ノート PC | 高評価レビュー | 184.5 | 0.001755 | 0.000475 |
| | 低評価レビュー | 203 | 0.000034 | 0.000598 |

⁸小数第七位を四捨五入。

第4章 考察

4.1 ポジティブ語・ネガティブ語の抽出に関する考察

ポジティブ語・ネガティブ語の妥当性について、評価用データを使い仮説検定を行った結果、P値がいずれも有意水準である0.05以下であり、妥当性が低い抽出であるという結論となった。これは2つの原因が考えられる。1つはサンプルデータの偏りである。表3.12では学習用データから抽出したポジティブ語が評価用データにもみられたが、表3.10、表3.11、表3.13においては学習用データでは出現したが、評価用データでは一切出現しなかったポジティブ語・ネガティブ語が確認できる。これは収集した商品レビューを分類する段階で、学習用データと評価用データとの間において頻出単語が大きく偏っていたと考えられる。そのため、サンプル数を増やし、各データ間の頻出単語の偏りを緩和させることが必要であると考える。もう1つの原因是閾値の設定である。本研究では有効な単語を抽出するため、出現率の閾値を設けた。この閾値を適切な値に再設定することで、より正確なポジティブ語・ネガティブ語の抽出が可能であると考える。

4.2 不当なレビュー抽出に関する考察

不当なレビュー評価の是正可能性について、評価用データにネガティブ語が含まれる高評価レビュー、ポジティブ語が含まれる低評価レビューがどの程度あるのかを分析した。その結果を表4.1、表4.2、表4.3、表4.4に示す¹。

表4.1: 商品カテゴリ「本」の高評価レビューにおけるネガティブ語の出現率

| ネガティブ語 | 品詞 | 品詞細分類 | 出現頻度 | 出現率 |
|--------|-----|--------|------|---------|
| 君 | 名詞 | 代名詞 | 0 | 0 |
| ページ | 名詞 | 一般 | 1 | 0.00007 |
| こういう | 連体詞 | * | 3 | 0.00021 |
| 人達 | 名詞 | 一般 | 0 | 0 |
| 使える | 動詞 | 自立 | 15 | 0.00104 |
| 彼 | 名詞 | 代名詞 | 10 | 0.00069 |
| 哲学 | 名詞 | 一般 | 1 | 0.00007 |
| なぜ | 副詞 | 助詞類接続 | 8 | 0.00055 |
| 設定 | 名詞 | サ変接続 | 1 | 0.00007 |
| アクセス | 名詞 | サ変接続 | 0 | 0 |
| 日本語 | 名詞 | 一般 | 4 | 0.00028 |
| 印象 | 名詞 | 一般 | 9 | 0.00062 |
| チンパンジー | 名詞 | 一般 | 0 | 0 |
| 当たり前 | 名詞 | 形容動詞語幹 | 9 | 0.00062 |
| 語る | 動詞 | 自立 | 3 | 0.00021 |
| 無駄 | 名詞 | 形容動詞語幹 | 3 | 0.00021 |
| こんな | 連体詞 | * | 5 | 0.00035 |
| 筆者 | 名詞 | 一般 | 5 | 0.00035 |
| トラウマ | 名詞 | 一般 | 0 | 0 |
| 感じ | 名詞 | 一般 | 7 | 0.00048 |

¹出現率は小数第六位を四捨五入。

表 4.2: 商品カテゴリ「本」の低評価レビューにおけるポジティブ語の出現率

| ポジティブ語 | 品詞 | 品詞細分類 | 出現頻度 | 出現率 |
|--------|----|-------|------|---------|
| ○ | 名詞 | サ変接続 | 0 | 0 |
| 分断 | 名詞 | サ変接続 | 0 | 0 |
| 気づく | 動詞 | 自立 | 4 | 0.00034 |
| 見方 | 名詞 | 一般 | 0 | 0 |
| 教える | 動詞 | 自立 | 5 | 0.00043 |
| 本能 | 名詞 | 一般 | 2 | 0.00017 |
| + | 名詞 | サ変接続 | 10 | 0.00086 |
| 相手 | 名詞 | 一般 | 7 | 0.00060 |
| 物事 | 名詞 | 一般 | 0 | 0 |
| 対人 | 名詞 | 一般 | 0 | 0 |
| 上司 | 名詞 | 一般 | 1 | 0.00009 |
| ひとつ | 名詞 | 副詞可能 | 0 | 0 |
| 基づく | 動詞 | 自立 | 1 | 0.00009 |
| すぐ | 副詞 | 助詞類接続 | 6 | 0.00052 |
| 事実 | 名詞 | 副詞可能 | 10 | 0.00086 |
| 悩み | 名詞 | 一般 | 3 | 0.00026 |
| 原因 | 名詞 | 一般 | 3 | 0.00026 |
| 思い込み | 名詞 | 一般 | 0 | 0 |
| 勧める | 動詞 | 自立 | 9 | 0.00077 |
| 他者 | 名詞 | 一般 | 1 | 0.00009 |

表 4.3: 商品カテゴリ「ノート PC」の高評価レビューにおけるネガティブ語の出現率

| ネガティブ語 | 品詞 | 品詞細分類 | 出現頻度 | 出現率 |
|--------|----|---------|------|---------|
| 返金 | 名詞 | サ変接続 | 2 | 0.00019 |
| 使い物 | 名詞 | 一般 | 0 | 0 |
| 落ちる | 動詞 | 自立 | 2 | 0.00019 |
| 広告 | 名詞 | サ変接続 | 4 | 0.00038 |
| 表記 | 名詞 | サ変接続 | 1 | 0.00010 |
| 失う | 動詞 | 自立 | 0 | 0 |
| 詐欺 | 名詞 | サ変接続 | 0 | 0 |
| 最悪 | 名詞 | 一般 | 0 | 0 |
| 型番 | 名詞 | 一般 | 0 | 0 |
| 回答 | 名詞 | サ変接続 | 0 | 0 |
| 電話 | 名詞 | サ変接続 | 1 | 0.00010 |
| 自体 | 名詞 | 一般 | 9 | 0.00087 |
| アマゾン | 名詞 | 一般 | 0 | 0 |
| Amazon | 名詞 | 一般 | 4 | 0.00038 |
| 仕方 | 名詞 | ナイ形容詞語幹 | 7 | 0.00067 |
| 安物 | 名詞 | 一般 | 3 | 0.00029 |
| 不良 | 名詞 | 形容動詞語幹 | 6 | 0.00058 |
| 再度 | 副詞 | 助詞類接続 | 5 | 0.00048 |
| 販売元 | 名詞 | 一般 | 0 | 0 |
| ダメ | 名詞 | 形容動詞語幹 | 4 | 0.00038 |

表 4.4: 商品カテゴリ「ノート PC」の低評価レビューにおけるポジティブ語の出現率

| ポジティブ語 | 品詞 | 品詞細分類 | 出現頻度 | 出現率 |
|--------|-----|--------|------|---------|
| 自分 | 名詞 | 一般 | 10 | 0.00208 |
| 順 | 名詞 | 固有名詞 | 1 | 0.00021 |
| ありがとう | 感動詞 | * | 0 | 0 |
| 笑 | 名詞 | 固有名詞 | 0 | 0 |
| 心配 | 名詞 | サ変接続 | 5 | 0.00104 |
| 最高 | 名詞 | 一般 | 1 | 0.00021 |
| 耐久 | 名詞 | 一般 | 1 | 0.00021 |
| バージョン | 名詞 | 一般 | 3 | 0.00062 |
| 機能 | 名詞 | サ変接続 | 16 | 0.00332 |
| 買い物 | 名詞 | サ変接続 | 2 | 0.00042 |
| ちょっと | 副詞 | 助詞類接続 | 9 | 0.00187 |
| 嬉しい | 形容詞 | 自立 | 1 | 0.00021 |
| 速い | 形容詞 | 自立 | 2 | 0.00042 |
| メモリー | 名詞 | 一般 | 3 | 0.00062 |
| 2020 | 名詞 | 数 | 0 | 0 |
| 多少 | 副詞 | 助詞類接続 | 1 | 0.00021 |
| 安心 | 名詞 | サ変接続 | 0 | 0 |
| 軽い | 形容詞 | 自立 | 3 | 0.00062 |
| 和 | 名詞 | 固有名詞 | 1 | 0.00021 |
| 大変 | 名詞 | 形容動詞語幹 | 3 | 0.00062 |

表4.1、表4.3を参考に、ネガティブ語が高評価レビューにどのような文脈で含まれているのか分析した結果、大きく3つのパターンがあると考える。1つ目は文脈によってポジティブ・ネガティブの極性が変化するパターンである。その例として、以下のようなネガティブ語の出現パターンがみられた²。

- ……こういう方法があったのか、と衝撃を受けました。……
- ……金額返金保証……
- ……再度購入しました。……

上記のようにネガティブ語がポジティブな表現としてレビュー文に含まれている。そのため文章全体においてその単語がどのような文脈で用いられているのかをポジティブ語・ネガティブ語の抽出に組み込み、両方の極性を持つ単語を除外するなどの処理が必要であると考えられる。

2つ目は評価対象の商品とは無関係の文脈に現れるパターンである。その一例を以下に示す。

- ……日本語教師という仕事柄、……
- ……前に他社メーカーのものを買ったが初期不良が多かったため、……
- ……がダメになり買い替えました。……

上記から自分の身の上話や以前購入していた商品に対する言及などレビューのエピソードに関する文脈に出現していることが確認できる。そのため言及している対象が明確な場合、その対象が評価対象の商品とどの程度関連性が高いかを考慮する必要がある。また、身の上話のような評価対象の商品と関連性の低い文章を除外するため、単語の共起関係を分析する必要があると考える。

3つ目は逆説表現の文脈に現れるパターンである。その一例を以下に示す。

- ……読めば当たり前に感じるかもしれません、……
- ……PC自体古いとはいえ……

²レビュー文の一部を抜粋。下線は本研究におけるポジティブ語・ネガティブ語を表す。

- ……質感は安物感が半端ないですがコストパフォマンスが抜群……

前記から「が」や「とはいえ」などの逆説表現の接続詞が含まれていることが確認できる。そのためポジティブ語・ネガティブ語の抽出において、このような文脈の可能性も考慮する必要がある。しかしこの逆説表現の接続詞に焦点を当てることで高評価レビューに含まれるネガティブな表現もしくは低評価レビューに含まれるポジティブ表現が抽出が可能となり、不当なレビュー発見につながると考える。

一方、表4.2、表4.4を参考にポジティブ語が低評価レビューにどのような文脈で含まれているのか分析した結果、前述のパターンに加え、否定表現の文脈に現れるパターンがみられた。その一例を以下に示す。

- ……全体として気づきもなく、……
- ……お勧めできません。……

上記のようにポジティブ語の後に「ない」、「できない」などの前の単語を否定する表現が付随しており、ポジティブ語がネガティブな表現となっている。そのため文章内に出現するポジティブ語・ネガティブ語の周囲における否定表現の有無を調べる必要がある。

第5章 結論

本研究では不当なレビュー評価是正を目指し、単語の出現頻度の順位差を利用した商品レビューからポジティブ語・ネガティブ語の抽出を試みた。そしてウィルコクソンの符号付き順位検定を行い、その商品カテゴリ内のポジティブ語・ネガティブ語が妥当なものであるかを明らかにした。これにより商品レビューのテキストマイニングによるポジティブ語・ネガティブ語抽出の可能性を見出した。

本研究では商品レビュー最大250件を学習用データとしポジティブ語・ネガティブ語の抽出を行ったが、評価用データと異なる抽出結果となり、各データにおける出現単語の偏りがみられた。そのためサンプル数を増やし、抽出するポジティブ語・ネガティブ語の妥当性を高める必要がある。また実際に不当なレビューを抽出するためには、レビュー文内における単語同士の関係性を分析する必要がある。複数のテキストマイニングの手法を併用し、ポジティブ語・ネガティブ語の抽出および抽出単語の検証をすることが今後の課題としてあげられる。そして、本提案手法により不当なレビューの検出が容易になり、評価のは正を行う際の一助とすることが期待できる。

参考文献

- [1] 金鍾和, 森高正博, 福田晋, 尹ソク重. ネットショッピングにおける消費者購買認識の構造分析. フードシステム研究第19巻4号, pp.382-393, 2013
- [2] 佐藤利紀. 品詞共起パターンを用いた評価表現抽出方法. 会津大学短期大学部産業情報学科経営情報コース2018年度卒業論文要旨集, pp.41-44, 2019
- [3] Ben Fox Rublin, cnet. “<https://www.cnet.com/news/amazon-updates-customer-reviews-with-new-machine-learning-platform/>”. 2015
- [4] 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
- [5] 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
- [6] 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
- [7] 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
- [8] 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
- [9] 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
- [10] 岩崎学. 統計的データ解析入門 ノンパラメトリック法, 東京図書, 2006
- [11] 村上秀俊. 統計解析スタンダード ノンパラメトリック法, 朝倉書店, 2015
- [12] 吉見憲二. グルメサイトの信頼性確保に関する一考察. 情報処理学会研究報告マルチメディア通信と分散処理研究会報告 2014-DPS-161(2), pp.1-4, 2014
- [13] 高村大也, 乾孝司, 奥村学. スピンモデルによる単語の感情極性抽出. 情報処理学会論文誌, 47(2), pp.627-637, 2006
- [14] 小倉達也, 宮戸開, 今藤紀子, 山口実靖, 浅谷耕一. レビューサイトにおける良質なレビューの特性とそれを考慮した評判情報の抽出に関する一考察. DEWS2008, B8-5, 2008
- [15] 清水航. レビューの語の重みを考慮したテキストマイニングによるゲームソフトの評判分析. 法政大学大学院工学研究科2010年度修士論文, 2011

- [16] 倉橋宏幸, 青野雅樹.Amazon レビューを用いた有用性の判別実験. 情報科学技術フォーラム
講演論文誌,12(2),pp.101-102,2013