

blog 検索による商品選定支援システム

山名 健悟[†] 滝沢 敏裕[†] 湯浅 将英[‡] 大山 実^{†‡}

[†]東京電機大学大学院 情報環境学研究科 [‡]東京電機大学 情報環境学部

本報告では、定期的に収集した blog 記事から、購入したい商品に関する情報を検索し表示することによって、商品の選定を支援するシステムについて述べる。ユーザに本システムを試用してもらい、blog の評判の時系列表示とニュース記事の表示が有用であることが確かめられた。また、検索キーワードと関連する blog 記事やニュース記事を適切に抽出する方法により、システムを改善することについて述べる。

Support System for Selecting Products Based on Blog Retrieval

Kengo YAMANA[†], Toshihiro TAKIZAWA[†], Masahide YUASA[‡], and Minoru OHYAMA^{†‡}

[†]Graduate School of Information Environment, Tokyo Denki University

[‡]School of Information Environment, Tokyo Denki University

In this report, we describe a system that helps users select a product by showing information of the product based on blog retrieval. We confirmed that the system is useful for users to find reputations and information of products by evaluation of users. In addition, we propose a method to extract suitably blog and news articles that is related with user's query, in order to develop the system.

1 はじめに

blog に書かれる評判情報を blog 記事検索の結果表示に利用するサービスが登場している[1]。ユーザはこのようなサービスを用いることで、自分の興味のある事や物に対し、他の人がどのように思っているかを気軽に知ることができる。

我々もまた blog 記事に書かれる評判情報に注目し、それらの評判を用いて商品の選定を支援するシステムを研究している[2, 3]。このシステムは、ユーザが効率的に商品の評判情報を集めて商品を選ぶことを支援するシステムであり、blog 記事内にある評価表現を抽

出し、賛否分類して表示する機能、評価表現の数を時系列にグラフ表示し、同時に検索対象に関するニュースを表示する機能を持つ。記事を賛否分類して表示する機能により、ユーザは検索対象について肯定的な記事と否定的な記事を効率的に閲覧することができる。また、評価表現数の時系列表示及びニュース表示により、評判の移りわりとその原因を知ることができる。これらの機能を用いることでユーザは効率的に商品の評判情報を集めることができる。

本稿では、このシステムをユーザに実際に試用してもらった際の評価結果を述べる。さ

らに、それに基づくシステムの改善策の提案について述べる。

2 blog 検索による選定支援システム

2.1 本システムの機能

本システムは、ユーザがある商品を購入する際に、blog 記事を参考にして選択することを効率化するシステムである。たとえば、ユーザがある商品を購入したいとする。通常、ユーザは収集したカタログや WEB 上にあるメーカの仕様書、ネット通販のランキング情報などを参考にして商品を選択する。または WEB 検索や blog 検索から当該商品に関する記事を見つけるなど、さまざまな手段を用いて、商品に関する情報を自ら集めて商品を選択する必要がある。

これらの手間を軽減するために、blog とニュース記事を利用した、以下の機能があれば便利である。

- 1) 商品について、肯定的または否定的な評判が書かれている記事を検索する機能
- 2) 商品についての評判を時系列にグラフ表示する機能
- 3) 商品の類似品を検索する機能

1)の機能があれば、ユーザが自分で商品の評判を探す手間が従来より軽減される。また、商品を選定する場合にはその商品の長所だけでなく短所も知っておくことは重要である。そのため、blog 検索に加えて、blog 記事の中から商品に関して「良い」「悪い」などと評価している語である評価表現を抽出し、記事を分類してユーザに提示することにより、ユーザは商品についての良い評判だけでなく悪い評判も知ることができる。

2)の機能があれば、評判の移り変わりを知ることができる。たとえば、ある時期から急に否定的な評判が多くなっている商品は何か問題が発見されたと判断でき、購入するのをやめようとするかもしれない。逆に、肯定的な評判が常に多い商品は人気があるものだと判断できるかもしれない。さらに、評判の移り変わりに加えて、評判の変化の理由を知ることができれば、より効率的に商品の判断ができる。そのため、ニュースサイトの記事を利用し、検索した商品についてのニュースが

ある場合には、その時期と内容が一目でわかるような機能が必要である。この機能により、ユーザは商品の評判の変動と、その変動の原因を知ることができる。

3)の商品の類似品を検索する機能については、[3]の文献にて詳しく述べているため省略する。

2.2 システムの流れ

システム全体の流れを図 1 に示す。本システムは図 1 のように WEB を定期的に確認することで情報を収集し、データベースに保存する。また、blog 記事を収集するときに記事の HTML から本文を抽出する。本文抽出処理については 2.3 節で説明する。

ユーザが検索キーワードを入力すると、本システムは保存された blog 記事からの検索を実行する。そして、肯定否定の分類表示、時系列表示、類似品表示という 3 種類の方法でユーザに結果を提示する。2.4 節ではそれらの表示方法のうち分類表示と時系列表示について説明する。

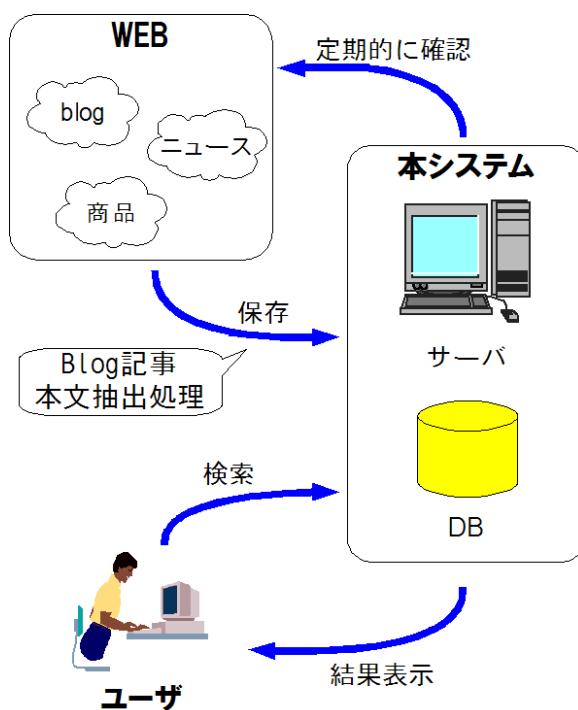


図 1 システム全体の流れ

2.3 本文抽出

本システムでは、検索のために blog 記事の HTML ファイルを用いているが、記事の HTML 中には blog の記事本文以外にも他記事や他サイトへのリンク、広告など余分な文章も含まれている。これらを除去するため、記事本文を適切に抽出する必要がある。

本文抽出に関しては、Finn らの手法[4]を参考に、リンクなどの余分な文字列に比べ、本文が長文であるという点に着目する。実際には、blog 記事の HTML 内で、タグを除いた文字列部分が一定以上の長さになっている文を本文として抽出した。なお、ここでは本文として採用する文字列は 80 文字とした。本文中で使われやすい FONT タグ、P タグ、SPAN タグ、STRONG タグは取り除いた後、本文として繋げる処理をした。

2.4 検索と結果の表示

ユーザによる商品の検索結果を、肯定的記事と否定的記事に分類して表示する方法と、評判を時系列表示しニュースとのリンクをとる方法について以下で説明する。

(1) 肯定的記事と否定的記事に分けた表示

検索結果中の評価表現の数により、記事を肯定的なものと否定的なものに分けて表示する。これにより検索した商品についての肯定的な評判と否定的な評判を両方とも知ることができる。評価表現の抽出には評価表現用の辞書を作成し利用している。辞書の作成には藤村らの研究[5]の手法を用いた。

検索キーワードを「iPod」として検索した場合の結果表示の例を図 2 に示す。この評価表現の数により記事が肯定的か否定的か判断している。ユーザはこの表示結果から見たい記事をクリックすることにより、blog 本体の記事を閲覧することができる。これらの肯定的な記事と否定的な記事の両方を見ることにより、ユーザは商品について的確に判断することができる。

good	bad
1. iPod無敵のトリセツ-ただのマニュアルじゃ満足できない、アナタのためのiPod超活用術-通販ショピング11e.jp (score:2004) Date:2005/06/30 01:55:37 cache Positive:10, Negative:0	1. 「モノ」が好き!LGのiPod shuffleクローン (score:676) Date:2005/06/29 09:27:38 cache Positive:0, Negative:3
2. Apple iPod 20GB (Click Wheel) Mac&PC [M0282J/A]-通販ショピング11e.jp (score:1233) Date:2005/06/12 04:05:33 cache Positive:4, Negative:3	2. 複写日記 iPod の不調 (score:249) Date:2005/07/03 03:34:48 cache Positive:0, Negative:2
3. iPod Style Navi - blog:iPodのライバルは登場するか?リーロンドン (score:1205) Date:2005/07/25 19:58:31 cache Positive:2, Negative:0	3. armrock: brand-new iPod (score:143) Date:2005/06/29 01:08:19 cache Positive:0, Negative:1

↑
肯定的な記事

↑
否定的な記事

図 2 肯定/否定で記事を分けた表示

(2) 時系列表示とニュースとのリンク

検索結果の記事の中にある評価表現の数を 1 日ごとに合計し、その推移をグラフとして表示する。さらに収集したニュースの情報を利用し、時系列表示とニュースの情報を並行して表示する。

検索キーワードを「iPod」として検索したときのグラフ表示の例を図 3 に示す。上部の折れ線が肯定表現の数を、下部が否定表現の数を表す。同時にニュースサイトから収集したトピックを日付順に並べてグラフと合わせて表示している。

図 3 から News:1 や News:2 に示されるように iPod nano の発表やレビューのニュースと同時期に肯定的表現の数が増えているのがわかる。このように、グラフ表示により評判の変動とその原因を知ることができ、選定支援に役立てることができる。

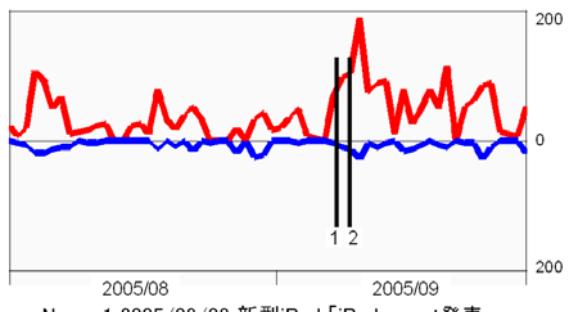


図3 blog の評価表現の数とニュースの表示

3 システムのアンケート評価

3.1 概要

2章で示した本システムの肯定否定の分類表示と時系列表示の機能の評価のため、アンケート調査を実施した。この調査で10人の理系大学生に本システムを利用してもらった。検索キーワードに入力されたのはSE/30, civic, バブ, 洗濯機, XBOX, nano, D902i, IXY DIGITAL 55, PIXUS iP8600, VAI0, ipod nano, ニンテンドーDS, マリオカートDS, 三国志大戦, SuperTangent, EOS, Dimension, iPod nano, NW-A3000, FOMA, スキー板, エスクードの22件だった。

3.2 評価

(1) 肯定否定の記事分類表示について

記事の分類表示については「検索結果を肯定的なものと否定的なものに分けているが、実際に記事を見てみてこの分類が正しいと思うか」ということをたずねた。

その結果を表1に示す。

表1 記事分類についてのアンケート結果

意見	備考	件数
正しい(だいたい正しい:5件)		9
正しくない	肯定のほうに間違った記事	2
	否定のほうに間違った記事	9
	両方に間違った記事	2
合計		22

記事分類が正しいという意見が9件、正しくないという意見が13件あった。記事の分類が正しくなかったという報告のうち、否定的に分類された記事に誤りがあったという

報告が多かった。肯定的な記事と否定的な記事を正しく分類できなかった原因を調べたところ、検索キーワードと関連性の少ない記事が20件、肯定否定の分類が逆転してしまっている記事を表示しているものが2件であった。

検索キーワードと関連性の少ない記事が表示される問題点を改善するためには、記事中の検索キーワードと評価表現との関連を見て、キーワードの商品を評価している文章を選ぶなどの検索精度の改良が必要である。

さらに、肯定否定を逆に分類してしまっている問題に関しては、評価表現の抽出手法を改良し、正確に分類できるようにする必要がある。

(2) 評判の時系列表示について

評判の時系列表示については以下の6問をたずねた。

1. 肯定的表現のグラフについて、どんな情報を読み取ったか。
2. 否定的表現のグラフについて、どんな情報を読み取ったか。
3. 時系列のグラフにニュースが何件表示されているか。
4. ニュースの表示が、キーワードに指定した商品のことを知るのに役に立ったか。
5. ニュース記事へのリンクをたどって、ニュース記事を読んだか。
6. ニュース記事を読んだとしたら、それが商品のことを知るのに役に立ったか。

まず、肯定的表現のグラフに関する質問の、設問1「肯定的表現のグラフについて、どんな情報を読み取ったか」についての結果を表2に示す。

表2 時系列表示についての設問1の結果

意見	件数
発売・発表された時期に多いのではないか	12
休みの時期に買った人が多いのではないか	1
ボーナスで買った人が多いのではないか	1
商品の季節柄多いのではないか	1
発売前に肯定表現が少ないから前評判が少ないと考えられる	1
否定よりも多いので、良い商品なのだろう	1
読み取れない	5
合計	22

この結果を見ると、およそ8割の検索において被験者は肯定的表現のグラフから何らかの情報を読み取っている。なかでも、発売・発表された時期に肯定表現が増えているのではないかという見方が多かった。他にも、「休みの時期だから買ったのではないか?」や「ボーナスで買ったのではないか?」などの意見のように、購入時期や買った人に対する推測をしている。また、前評判や否定との比較など、買うべき商品の評価に着目している。これらが、商品を購入する際の意思決定の支援につながると考えられる。

次に、否定的表現のグラフに関する質問の、設問2「否定的表現のグラフについて、どんな情報を読み取ったか」についての結果を表3に示す。

表3 時系列表示についての設問2の結果

意見	件数
発売・発表された時期だから増えている	5
肯定よりも少ないので、良い商品なのだろう	1
否定的な記事を書く人は少ないのではないか	2
否定的な意見が無い	2
少なすぎてなんとも言えない	6
読み取れない	6
合計	22

否定表現のグラフに関しては、何らかの情報を読み取ったという件数が10件、読み取れなかったという件数が12件という結果になった。よって、否定的表現のグラフは肯

定的表現のグラフに比べて情報を読み取りにくかったようである。これは本システムにおける評価表現用の辞書に登録されている否定的な語句が十分でなかったため、否定的表現の抽出が少なかったからだと考えられる。今後は辞書に登録する否定的な語句を増やすことで改善していく予定である。

最後に、ニュースのグラフに関する質問の、設問3, 4, 5, 6の結果をそれぞれ表4, 5, 6, 7に示す。

表4 時系列表示についての設問3の結果
(ニュースの件数)

ニュースの件数	件数
0件	10
1~9件	10
10件以上	2
合計	22

表5 時系列表示についての設問4の結果
(ニュースの表示が役に立ったか)

意見	件数
役に立った	6
少しは役に立った	1
役に立たない	5
合計	12

表6 時系列表示についての設問5の結果
(ニュースを読んだか)

意見	件数
読んだ	10
読まなかった	2
合計	12

表7 時系列表示についての設問6の結果
(ニュースの内容が役に立ったか)

意見	件数
役に立った	6
少しは役に立った	1
あまり役に立たない	1
役に立たない	2
合計	10

表4のように22件中12件の結果ではニュースが検索された。しかし、ニュースがまつ

たく検索されないという例も10件あった。ニュースが検索されなかっただ例はSE/30, civic, NW-A3000, D902i, PIXUS iP8600, Dimension, SuperTangent, マリオカートDS, 三国志大戦, スキー板であった。ニュースが検索されなかっただ例があったのは、収集しているニュースが少なく、ユーザが検索した商品に対応するニュース記事が見つからなかっただためである。今後は、収集するニュースのジャンルやサイト等を増やし対応していく予定である。

ニュースが検索された場合には、12件中7件がニュースの表示が役に立つという意見だった(表5)。役に立たないという意見の中では、検索した商品と関係のないニュースが検索されたというものがあった。この問題を改善するためには、検索キーワードと関連するニュースのみを適切に選択する必要がある。

また、12件中10件がニュース記事を読んだという意見だった(表6)。ニュースを読まなかっただという報告では、ニュースのタイトルから自分の検索した商品と関係のないニュースだということがわかったので読まなかっただという意見があった。この問題に関しても検索キーワードと関連性の高いニュースを検索できるようになれば改善される。

ニュースを読んだ例の中では、10件中7件が役に立ったという意見だった(表7)。役に立ったという報告では、ニュース記事を読んで商品のことがよくわかったという意見が多くあった。しかし、役に立たなかっただとの意見の中には、記事を読んだところで自分に興味のない記事だったということが後でわかったという意見もあった。

これらの結果から、検索キーワードとニュースの関連を把握し、関連性の高いニュースを表示することで、ニュースの表示がより役に立つ機能になると言える。

3.3 考察

以上の結果から、評判情報のグラフ表示、およびニュースの表示については、ユーザは他の人の購買行動を読み取ることができ、また、表示されるニュースが役に立つと多くのユーザが述べている。これらは実際の商品の

選択の支援にも役に立つと考えられる。

しかし一方で、記事の賛否分類とニュースの抽出については、あまり精度がよくないという意見が多かった。これについては、3.2節の(1), (2)で述べたように、検索キーワードと関連性の少ないblog記事やニュースが検索されてしまうという問題があることがわかる。検索キーワードと関連性の少ないblog記事やニュースの表示を減らすには、記事中の検索キーワードの商品を評価している文章を選ぶなどの検索精度の改良が必要である。また、本文以外のノイズ部分に検索キーワードがある場合も考えられるので、本文抽出の精度を改良することによっても改善が期待できる。

4章では、これらの検索精度の改善と本文抽出の改善について述べる。

4 改善策の提案

3.2節の(1)で述べたように、検索キーワードと関連性の少ない記事が表示されるという問題点があった。これを改善するための、検索精度の改善と本文抽出の改善について以下で述べる。

4.1 検索精度の改善

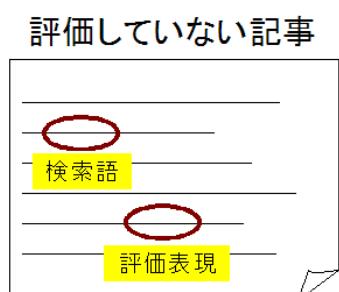
検索精度を向上させ、商品の評価に関わる記事を検索できるようにすれば、検索キーワードと関連性の少ない記事を省くことができる。

検索精度を向上させるために、blog記事を係り受け解析し、検索語と評価表現とが係っている文章を抽出するという手法をとった。これにより、検索語に関して評価している記事を抽出することができる。

記事の判定方法のイメージを図4に示す。



検索語と評価表現の間に
係り受けの関係がある



検索語と評価表現の間に
係り受けの関係がない

図4 検索語について評価している記事の判定

検索キーワードに関して評価している記事を判定する基準としては、blog記事をCaboCha[6]により係り受け解析した結果を調べ、検索キーワードが係っている文節のうち2文節以内に形容詞または形容動詞があった場合は評価している記事だとした。

例として、「iPod」というキーワードで検索した場合に、キーワードについて評価していると判定された記事には、キーワードが含まれる文として「うちの奥様の iPod 20G の調子が悪い」という文があった。この文では「iPod 20G の – 調子が – 悪い」というように「iPod」という検索キーワードに「悪い」という形容詞が2文節以内に係っている。そのため、この文が含まれる記事が、iPodについて評価している記事だと判定された。このような判定手法で従来までの検索結果について記事を判定した結果を表8に示す。ここでは、検索キーワードには「iPod」と「VAIO」の2つを設定した。表の順番は従来までの検索結果の順である。

このように、記事中の検索キーワードが含まれる文を係り受け解析し、評価表現との関

係を調べることで、キーワードについて評価が書かれている記事を探すことができた。しかし、実際にはキーワードの商品を評価している記事なのに評価していないと判定してしまう例や、逆にキーワードの商品を評価していない記事を評価していると判定してしまう例もあるため、今後は判定を間違えた記事を分析し、より正確な記事判定を目指す。これにより、検索精度が改善され、ユーザが商品の情報を集めやすくなることが期待できる。

表8 係り受け解析による記事判定

検索語	記事の判定	係り受け解析結果
iPod	○	iPodの – 調子が – 良くない。
	○	iPod 20Gの – 調子が – 悪い
	○	iPod本体だけなら – 見ると – 必須っぽいし、
	×	iPod 3G + iFMで – 聴ける – 環境に
	○	iPod miniより – 安くて
	○	ipodちゃんが – 不調。
	×	iPodな – ユーザーが – リッピングし直すかは
	×	iPod nanoの – 他、 – 大放出!!
VAIO	×	■ バイオ ■ VAIO ■ バイオ ■(以下略)
	×	「VAIO type S SZシリーズ」 – 「VAIO type F TV」を – 発表した。
	×	VAIOの – Type TXとか – LOOXでは
	○	VAIOで – 多いのが – 古いが
	×	VAIOの – 新製品を – 紹介します。
	×	「新型VAIOノート」が – 登場
	×	VAIOで – 「VAIO type T プレミアムブルー」 – 出ました
	○	VAIOは – 感じなんですが、 – 不親切ですね。

4.2 本文抽出の改善

本文抽出の精度を向上させるために、本システムによって集められた記事100件を対象として、文字数を80文字、100文字、120文字と設定した場合の再現率と適合率[7]をそれぞれ計算した。ここでは、HTMLタグによって分割された一文を単位として、再現率と適合率

の計算を行った。100件の記事でそれぞれの再現率と適合率を計算し、その平均をとった結果を表9に示す。本文として採用する文字数が増えるほど、再現率は下がってしまう。しかし、適合率は100文字とした場合が一番高かった。これらの結果をふまえて、今後は実際に本システムで本文として採用する文字数を変化させた場合に、どのような違いが現れるか確かめる。

表9 本文抽出の再現率と適合率

	再現率	適合率
80文字	0.79	0.63
100文字	0.70	0.70
120文字	0.64	0.68

5まとめ

本稿では、我々が開発しているシステムについて説明し、その評価を述べた。アンケート調査の結果から検索キーワードに指定した商品を評価していない記事が表示されてしまうという問題点があった。これについては、記事を係り受け解析し、検索キーワードと評価表現との関係を見ることと本文抽出を再検討することにより改善する方法を提案した。

今後は、提案した方法を実際にシステムに組み込み、再評価するとともに、さらに検索精度を向上させる。また、今回はアンケートという主観評価のみであるが、より客観的な評価も進め、より効率的な商品の選定支援を目指す。

参考文献

- [1] blogWatcher <http://blogwatcher.pi.titech.ac.jp/>
- [2] 山名 健悟, 滝沢 敏裕, 湯浅 将英, 大山 実, "Blog 記事を用いた選定支援システム", 情報処理学会第 67 回全国大会, 2U-4 (2005)
- [3] 山名 健悟, 西村 圭亮, 滝沢 敏裕, 湯浅 将英, 大山 実, "blog 検索と類似品情報を用いた選定支援システム", 情報処理学会研究報告, 2005-DD-52, pp.17-21 (2005)
- [4] Finn A., Kushmerick N., Smyth B., "Fact or fiction: Content classification for digital libraries" Joint DELOS-NSF Workshop on Personalisation and Recommender Systems in Digital Libraries (2001)
- [5] 藤村 滋, 豊田 正史, 喜連川 優, "電子掲示板からの評価表現および評判情報の抽出", 人工知能学会第 18 回全国大会, 3F1-03 (2004)
- [6] CaboCha ホームページ
<http://chasen.org/~taku/software/cabocha/>
- [7] 北 研二, 津田 和彦, 獅々堀 正幹, "情報検索アルゴリズム", 共立出版 (2002)