

ユーザ印象評価データの分析に基づく 印象マイニング手法の設計と評価

熊本 忠彦^{1,a)} 河合 由起子² 張 建偉³

受付日 2012年9月20日, 採録日 2012年11月7日

概要: 本論文では、「楽しい ⇔ 悲しい」、「うれしい ⇔ 怒り」、「のどか ⇔ 緊迫」という3種類の印象を対象に、新聞記事を読んだ人々が感じる印象の強さを数値的に求めるための手法を提案する。印象の強さ(すなわち印象値)を算出するためには、記事から抽出される特徴量が記事の印象に及ぼす影響力を数値化し、印象辞書に登録しておく必要がある。著者らは、先行研究において、それぞれの印象辞書を用いて算出される記事の印象値とその記事を読んだ人々が感じる印象の強さとの対応関係を高次の回帰分析により定式化することで、印象値を高精度に算出する手法を提案している。本論文では、さらに、それぞれの印象が独立ではない点に着目し、人々が感じる印象の強さと先行研究の手法を用いて算出される3つの印象値との対応関係を重回帰分析により定式化することで、それぞれの印象値をより高精度に算出し直す手法を提案する。未知データに対する提案手法の精度を5分割交差検定により調べてみたところ、それぞれの印象における平均誤差は1~7の7段階評価スケールに対して0.60, 0.49, 0.52であった。先行研究で提案した手法の平均誤差は0.69, 0.49, 0.64であったので、「うれしい ⇔ 怒り」に対しては同じ誤差を保ちつつ、「楽しい ⇔ 悲しい」と「のどか ⇔ 緊迫」に対する誤差が大幅に改善されていることが分かる。

キーワード: 評判分析, 感情, 高次回帰モデル, 重回帰モデル

Design and Evaluation of a Method for Mining Impressions of Text Based on Analysis of People's Impression Data

TADAHIKO KUMAMOTO^{1,a)} YUKIKO KAWAI² JIANWEI ZHANG³

Received: September 20, 2012, Accepted: November 7, 2012

Abstract: The authors investigate the impressions people gain from reading newspaper articles, and propose a method for quantifying the strength of these impressions. Our target impressions are limited to those represented by three bipolar scales, “Happy – Sad,” “Glad – Angry,” and “Peaceful – Strained.” In order to compute the strength of each impression as an “impression value,” that is, a real number between 1 and 7, it is generally required to quantify the power of features extracted from articles to influence on their impressions and record it in an impression lexicon. An impression lexicon is usually constructed for each kind of impression and is used only to compute an impression value for an impression. We have already proposed a method for reducing the divergence between the values that were computed using each impression lexicon and those judged by readers, and our experimental results showed that the average root-mean-square errors (RMSEs) for unlearned data were 0.69, 0.49, and 0.64 for respective impressions. In this paper, we focus on the fact that the impressions are not independent of one another and adopt a new approach that recalculates each value with the values that were computed by the previous method. That is, we apply multiple regression analysis for each impression, where the values computed from articles using the previous method are used as one of the explanatory variables, and an average of the values that respondents used to rate each article using the corresponding scale in questionnaire surveys is used as the objective variable. Consequently, we obtain a multiple regression equation for each impression, which represents a correspondence relationship between the variables. We also perform five-fold cross-validation using the data obtained in the surveys to verify the effectiveness of the proposed method. The results show that the average RMSEs for unlearned data are 0.60, 0.49, and 0.52 for respective impressions. This means that the average RMSEs were greatly reduced in the “Happy – Sad” and “Peaceful – Strained” scales, while keeping the same average RMSE in the “Glad – Angry” scale.

Keywords: sentiment analysis, emotion, higher-order regression model, multiple regression model

¹ 千葉工業大学
Chiba Institute of Technology, Narashino, Chiba 275-0016,
Japan

² 京都産業大学
Kyoto Sangyo University, Kyoto 603-8555, Japan

³ 筑波技術大学
Tsukuba University of Technology, Tsukuba, Ibaraki 305-
8520, Japan

a) kumamoto@net.it-chiba.ac.jp

1. まえがき

近年、人と機械の調和を目指した研究が数多くなされている。90年代には Affective Computing の概念 [1] が提唱され、機械が人の感情を認識したり、表現したりすることで、人が機械に合わせるのではなく、機械が人に合わせることを実現しようという研究がさかんになった。特に顔表情やジェスチャ、姿勢あるいは声といった情報からその情報を発信している人の感情を推定するための研究 [2], [3], [4] が行われている。一方、テキストを対象とする研究分野では、評判や感情、印象といった主観的な情報をテキスト（レビュー、ニュース記事、Web ページ、小説など）から抽出するための研究がさかんであり、評判分析 [5], [6] や情報可視化 [7], [8], [9], 情報推薦 [10], [11], [12], 異メディアコンテンツ生成 [13], [14], 印象タグ付与 [15], [16], 情報の信頼性評価 [17] といった様々な分野で応用されている。

本論文では、新聞記事を例に、記事を読んだ人々が感じる印象の強さを数値的に求めるための印象マイニング手法を提案する。本手法が対象とする印象は、「楽しい ⇔ 悲しい」、「うれしい ⇔ 怒り」、「のどか ⇔ 緊迫」の3種類であり、それぞれの印象に対して「(左側の印象を) 感じる (1点), わりと感じる (2点), やや感じる (3点), (どちらの印象も) 感じない (4点), (右側の印象を) やや感じる (5点), わりと感じる (6点), 感じる (7点)」という7段階の評価スケール（以下、印象尺度と呼ぶ）を割り当てる。すなわち、本手法は、それぞれの印象尺度において、そのスケールに準じた1.0~7.0の実数値を、印象の強さを表す印象値として出力する。たとえば、ある記事の「のどか ⇔ 緊迫」に対する印象値が2.30であった場合、その記事ののどかさに関しては、「わりと感じる (2点)」よりやや「やや感じる (3点)」寄りであると判断されたことが分かる。このように印象の強さを数値化することにより、印象空間（複数の印象尺度によって張られる多次元空間）へのテキストの写像が可能となり、その結果、テキストに対する印象分布の可視化やランキングといった操作が可能となる。

著者らは、先行研究 [18] において、新聞記事データベースから抽出される任意の特微量とあらかじめ定義した特定の印象語群との（記事内）共起関係に基づいて印象辞書（記事から抽出される特微量の記事印象への影響力を示すもの）を印象尺度ごとに構築し、それぞれの印象辞書を用いて算出される記事の印象値とその記事を読んだ人々が感じる印象の強さとの対応関係を高次の回帰分析により定式化することで、記事の印象値を高精度に補正する手法を提案している。しかしながら、この手法の未知データに対する誤差は、それぞれの印象尺度に対し0.69, 0.49, 0.64となっており、「楽しい ⇔ 悲しい」と「のどか ⇔ 緊迫」に対する誤差が「うれしい ⇔ 怒り」の誤差に比べ、かなり大きかった。そこで本論文では、それぞれの印象が独立では

ない点に着目し、それぞれの印象尺度において算出され、補正された印象値と人々が感じる印象の強さとの対応関係を重回帰分析により定式化することで、各印象尺度における記事の印象値を算出し直すという手法を提案する。

なお、先行研究 [18] では、記事から抽出する特微量として単語 unigram のみを採用していたが、本論文では、この単語 unigram に加え、単語 bigram を採用する。単語 unigram は、記事特微量としての網羅性が高く、使い勝手がいいことから、数多くの研究 [6], [18] で採用されている。特に Pang らの研究 [6] では他の特微量（単語 bigram のみ、単語 unigram と単語 bigram の組合せ、単語 unigram と品詞情報との組合せなど）を用いるよりも単語 unigram のみを用いた方が、精度が良かったことが示されている。一方、単語 bigram は、網羅性が低い反面、単語どうしの組合せを考慮に入れることができることから、名詞の接続や述語構造などを考慮する研究 [5], [16] で採用され、その有用性が示されている。そこで本論文では、用いる記事特微量の種類として、単語 unigram のみ、単語 bigram のみ、単語 unigram と単語 bigram の両方の3つの場合を試すことにする。

本論文の構成は以下のとおりである。まず、2章で関連研究を整理し、提案手法との違いを示す。3章で著者らが先行研究で提案した手法 [18] を説明する。4章でこの先行研究からの拡張点として単語 bigram の導入部分に関して述べ、さらに重回帰分析に基づいて記事の印象値を算出し直すための手法を提案する。5章で学習データおよび未知データに対する提案手法の精度を評価し、先行研究で提案した手法 [18] の精度と比較することで、その有効性を検証する。最後に、6章で本論文のまとめと今後の課題について述べる。

2. 関連研究

映画レビューや書評といった書き手の評価を Positive, Negative の2クラス、あるいは Neutral を加えた3クラスに分類するという研究がある。たとえば、Turney [5] は、各種レビューを「recommended」か「not recommended」に分類する手法を提案している。彼の手法は、入力テキストから特定パターン（たとえば「形容詞+名詞」や「副詞+形容詞+名詞以外」など）のフレーズを抽出し、各フレーズと参照語「excellent」および「poor」との自己相情報量 [19] をそれぞれ求め、差をとることにより、各フレーズの Semantic Orientation (SO) を決定している。そして、全フレーズの SO を平均することにより、入力テキストの SO を求め、その値により「recommended」か「not recommended」かを決定している。しかしながら、この手法は、印象の強さを数値化するのではなく、クラスへの分類問題として扱っている点や1本の印象尺度（「recommended ⇔ not recommended」）に特化し、複数の印象を対象とし

ていない点が異なっている。

一方、テキストを複数の感情クラスに分類するという研究も行われている。たとえば、Lin ら [7] は、ニュース記事を 8 つの感情クラス (Awesome, Heartwarming, Surprising, Sad, Useful, Happy, Boring, Angry) に分類する SVM (Support Vector Machine) ベースの手法を提案している。具体的には、提示された中国語のニュース記事に対して、指定された 8 つの感情のうちの 1 つを投票できる Web 上のニュースサイトを利用することで、それぞれのニュース記事本来の感情を決定し、各ニュース記事から抽出される特徴量 (単語 unigram, 文字 bigram, affix similarity など) と関連付けたものを SVM への訓練データとして用いている。つまり、この研究は、複数の感情を対象としている点で、著者らの研究と同じ方向性を持っているが、SVM によるクラス分類問題として扱っている点が印象の強さの数値化を目指している著者らの研究とは異なっている。

入力されたテキストにそのテキストの印象を表す印象語をタグとして付与するというアノテーションに関する研究がある。たとえば、宮川ら [15] は、意味の数学モデル [20] を用いてテキストが有する任意の印象を抽出するための手法を提案している。この意味の数学モデルは、文脈に応じた意味的連想を可能とする情報検索方式であり、検索に用いられるキーワード群を配置したメタデータ空間と呼ばれる正規直交空間から文脈を表す部分空間を選択し、その部分空間上での相関量に基づいて意味的に近いキーワード (印象語) の選択を可能にしている。この方式では、テキストの印象を表すキーワード (印象語) を文脈に応じて選択することが可能と考えられるが、特定の印象尺度に沿って印象の強さを数値的に求めることはできない。一方、清水ら [16] は、特定のフレーズパターンの出現頻度に基づいて形容詞どうしの意味的關係や形容詞と名詞、形容詞と動詞との意味的關係を抽出し、さらに名詞と動詞の組合せに対する印象 (特に「嬉しい」、「明るい」、「寒い」、「冷たい」、「重い」のような情景を表す形容詞) を推定する手法を提案している。この手法の特徴として、印象推定の信頼性を印象適合値という数値で表している点あげられるが、印象の強さを数値的に求めることはできない。

著者らの研究と同様、印象の強さを数値的に求めるための研究も行われている。たとえば、阿部ら [10] は、5 種類の感情 (喜, 怒, 哀, 楽, 愛) を対象に、受信したメールを読んだユーザがいだく感情の度合いを推定し、それぞれの感情の度合いに応じて楽曲を推薦する手法を提案している。この手法の感情推定部分を設計するにあたり、彼らは、訓練用のメールから抽出された特徴語 (名詞, 動詞, 形容詞) のうち、tf・idf 値が閾値以上のものを説明変数、各メールに対し、被験者らが付けた各感情の評価点 (5 段階評価尺度) を目的変数とする重回帰分析を感情の種類ごとに行い、それぞれの対応関係を重回帰式で表している。し

かしながら、メールから抽出される特徴語をそのまま説明変数としているため、汎用性 (新規受信メールへの対処能力) という点で問題が生じる。すなわち、重回帰分析では、説明変数の数より多い数の訓練事例が必要とされるが、この手法に汎用性を持たせるためには相当数の訓練事例が必要となり、実際的ではない。もし訓練事例数が十分でないと、その分、説明変数の数を絞り込む必要があり、その結果、新規の受信メールに説明変数として選ばれた特徴語があまり含まれず、正確に感情推定できないということも考えられる。これに対し、著者らの提案手法では、記事から抽出される特徴量を直接的に重回帰分析に使わないため、特徴量を増やしても、重回帰分析の説明変数が増えるわけではない。その結果、記事から抽出する特徴量の数には制限がないという利点が生じる。一方、秋山ら [21] は、「かくかく」のような XYXY 型のオノマトペ (擬音語, 擬態語, 擬声語など) から感じる印象を 4 つの因子「キレ・俊敏さ」、「柔らかさ・丸み」、「躍動感」、「大きさ・安定感」で定義し、各因子を形容詞対からなる 5 段階評価尺度 (たとえば「躍動感のない ⇔ 躍動感のある」) で表すことで、それぞれの因子における印象の強さを数値的に求める手法を提案している。具体的には、14 種類の音の要素 (子音 9 種類, 母音 5 種類) と 38 種類の XYXY 型オノマトペに対する各因子の値を被験者実験で求め、各オノマトペに対する因子の値を目的変数、そのオノマトペを構成する文字 X と Y の子音と母音に対する因子の値を説明変数 (計 4 個) とする重回帰分析を因子ごとに行うことで、音の要素とオノマトペから受ける印象の強さとの対応関係を定式化している。しかしながら、この手法は、オノマトペの音響的な特徴を利用した研究であり、かつ音の組合せ方 (文献 [21] では XYXY 型のみが対象) に制限があることから、一般的なテキストへは応用できない。

3. ベースとなる先行研究

著者らは、先行研究 [18] において、「楽しい ⇔ 悲しい」、「うれしい ⇔ 怒り」、「のどか ⇔ 緊迫」という今回と同じ 3 種類の印象を対象に、印象辞書を用いて算出される記事の印象値を説明変数、その記事に対し回答者 100 人が与えた 7 段階評価値の平均値を目的変数とする回帰分析を印象尺度ごとに行い、その結果得られた回帰式 (三次関数あるいは五次関数) を用いて記事の印象値を補正するという手法を提案している。本章では、文献 [18] において示した印象尺度の設計、印象評価データの収集、印象辞書を用いた記事印象値の算出、回帰式による記事印象値の補正について説明する。

3.1 印象尺度の設計

文献 [18] では、別の先行研究 [22] で設計した 6 本の印象尺度の中の 3 本を採用している。そこで本節では、その 6

本の印象尺度の設計手順と問題点を示し、「楽しい ⇔ 悲しい」、「うれしい ⇔ 怒り」、「のどか ⇔ 緊迫」の3本を選択した根拠を明らかにする。

文献 [22] では、新聞記事の印象特性（印象の現れ方に関する性質）を分析し、その結果に基づいて記事を読んだ人々がその記事から受ける印象を定量的にとらえるための印象尺度として「楽しい ⇔ 悲しい」、「うれしい ⇔ 怒り」、「面白い ⇔ つまらない」、「楽観的 ⇔ 悲観的」、「のどか ⇔ 緊迫」、「驚き ⇔ ありふれた」の6本を提案している。この6本の印象尺度の設計手順は以下のようになっている。

まずはじめに、新聞記事の印象特性を分析するために必要なデータをアンケート調査に基づいて収集している。この調査では、回答者900人を9つのグループ（男女50人ずつ、計100人）に分け、グループごとに異なる記事を10記事用意している。各グループの回答者には、ランダムな順序で提示される10記事を順に読んでもらい、それぞれの記事の印象を印象尺度の候補となる42個の印象語を用いて「強い（1点）、わりと強い（2点）、わりと弱い（3点）、弱い（4点）、なし（5点）」の5段階で評価してもらっている。次に、このようにして収集されたデータ（新聞記事10記事×印象語42語×回答者100人×9グループ）に対し、基本統計量（平均値と標準偏差）の分析や回帰分析、因子分析、クラスタ分析を行い、各印象語の特性や印象語間の関係を明らかにしている。その結果に基づいて、上述した6本の印象尺度が設計されている。なお、印象尺度の候補となった印象語42語は、記事の印象を表しうるものとして類語辞典 [23] から選ばれている。

しかしながら、文献 [22] では、次のような問題点も示されている。

- 「驚き」に関する印象は、人によって大きく異なっており、かつ、その異なり具合はいずれの記事においても同程度である。したがって、「驚き」に関する印象を扱うためには、何らかの個人適応が必要と考えられる。
- 印象尺度の使い勝手に関するアンケート調査の結果から、「面白い ⇔ つまらない」と「楽観的 ⇔ 悲観的」という2つの印象尺度は、ある種の記事（たとえば殺人事件や自殺、事故死などに関する記事）に対しては不適切であり、評価しにくい。

そこで本研究でも、文献 [18] と同様、この3本の印象尺度を取り扱わないことにした。すなわち、本論文において対象となる印象は、「楽しい ⇔ 悲しい」、「うれしい ⇔ 怒り」、「のどか ⇔ 緊迫」の3種類であり、それぞれの印象に対し「（左側の印象を）感じる（1点）、わりと感じる（2点）、やや感じる（3点）、（どちらの印象も）感じない（4点）、（右側の印象を）やや感じる（5点）、わりと感じる（6点）、感じる（7点）」という7段階の評価スケールを設定する。

3.2 印象評価データの収集

人々が新聞記事からどのような印象を受けるのかを示す印象評価データを得るために、900人（男女450人ずつ）が参加するアンケート調査を行った。具体的には、回答者900人を年齢や性別が均等になるよう9つのグループ（男女50人ずつ、計100人からなるグループ）に分け、各グループに毎日新聞の2002年版社会面 [24] に掲載された10記事を提示した。この10記事はグループによって異なっており、全部で90記事が重複しないように選ばれている。各回答者は、ランダムに提示される10記事の印象をランダムな順番で提示される3種類の印象尺度を用いて7段階評価した。すなわち、「楽しい ⇔ 悲しい」、「うれしい ⇔ 怒り」、「のどか ⇔ 緊迫」のそれぞれに対し、対応する印象をどの程度感じるかを「（左側の印象を）感じる（1点）、わりと感じる（2点）、やや感じる（3点）、（どちらの印象も）感じない（4点）、（右側の印象を）やや感じる（5点）、わりと感じる（6点）、感じる（7点）」の7段階で評価した。なお、今回のアンケート調査に参加した回答者は、印象尺度の設計（3.1節参照）に参加した回答者とは異なっており、重複していない。

以上の結果得られたデータから各記事の各印象尺度における平均値を求めた。本論文では、この平均値を記事本来の印象値と見なし、印象評価データとして扱う。

なお、各回答者に提示した記事は、元の記事の第1段落のみであり、第2段落以降は提示していない。これは、記事の構成上、第1段落を読めば記事の概要が分かるように書かれている点や段落ごとに記事の印象が変わる可能性がある点、記事が長いと回答者にかかる負担が増大する点を考慮した結果である。ただし、将来的には1つの記事の中での印象の推移を追跡できるような印象マイニングを実現したいと考えている。

3.3 印象辞書を用いた記事印象値の算出

本節では、著者らの先行研究 [18] に基づいて、新聞記事から抽出する特徴量として単語 unigram を定義し、3つの印象辞書（3種類の印象尺度に対応）を構築するとともに、それぞれの印象尺度において、印象辞書を用いて算出される記事の印象値を説明変数、3.2節のアンケート調査の結果に基づいて算出された回答者の平均値（印象評価データ）を目的変数とする回帰分析を行い、両者の対応関係を表す最適な回帰式を得る。

3.3.1 単語 unigram の生成

はじめに、新聞記事から記事特徴量として単語 unigram を生成する手法について説明する。

まず、日本語汎用形態素解析システムである Juman [25] を用いて、入力された記事を形態素の列に分解する。しかしながら、これらの形態素は、記事の印象を決定づける基本要素としては細かすぎる。たとえば、接尾辞や接頭辞は、

他の形態素と結合することで、形態素の印象に影響を与えることがあると考えられることから、結合したものを1つの記事特微量として扱った方がよい。また、動詞の基本連用形は名詞化する場合があり、そのような場合はサ変名詞として扱った方がよいし、サ変名詞と動詞「する」の組合せは「～する」という動詞1語として扱った方がよい。以上のような点を考慮するために、本研究では、表1に示すような、接尾辞や接頭辞を他の形態素と結合するためのルールや品詞を変換するためのルールを設計し、後処理ルールとして導入している。

表1 Juman の出力結果を変換するための後処理ルール
Table 1 Rules for transforming Juman's output.

1.	形容詞/動詞+名詞性述語接尾辞のとき、この2語を普通名詞1語に変換する
2.	名詞/未定義語/形容詞(語幹)/動詞(基本連用形)+名詞性名詞接尾辞(「化」を除く)のとき、この2語を普通名詞1語に変換する
3.	名詞/未定義語/形容詞(語幹)/動詞(基本連用形)+名詞性名詞接尾辞「化」のとき、この2語をサ変名詞1語に変換する
4.	接頭辞「御/ご/お」+動詞(基本連用形)のとき、この2語をサ変名詞1語に変換する
5.	動詞(基本連用形)+格助詞のとき、動詞(基本連用形)をサ変名詞に変換する
6.	名詞/未定義語+名詞性特殊接尾辞(「都、道、府、県、郡、市、町、村、区、州、省」を除く)のとき、この2語を未定義語1語に変換する
7.	形容詞/動詞+動詞性接尾辞のとき、この2語を動詞1語に変換する
8.	サ変名詞/カタカナ/アルファベット/副詞/形容詞(基本連用形/タ列基本連用形)+動詞「する/できる」のとき、この2語を動詞1語に変換する
9.	動詞+助動詞「ぬ」/形容詞性述語接尾辞「ない」のとき、この2語を動詞1語に変換する
10.	名詞(形式名詞と副詞的名詞を除く)/未定義語/動詞(基本連用形)/副詞+判定詞のとき、この2語を形容詞1語に変換する
11.	形容詞/動詞/判定詞+形容詞性述語接尾辞(「ない」を除く)のとき、この2語を形容詞1語に変換する
12.	名詞/未定義語/動詞/形容詞+形容詞性名詞接尾辞のとき、この2語を形容詞1語に変換する
13.	形容詞+形容詞性述語接尾辞「ない」のとき、この2語を形容詞1語に変換する
14.	形式名詞/副詞的名詞/助詞+判定詞のとき、この2語を判定詞1語に変換する
15.	判定詞+形容詞性述語接尾辞「ない」のとき、この2語を判定詞1語に変換する
16.	形容詞(タ列タ系連用テ形/基本連用形)/動詞(タ系連用テ形)/判定詞(タ列タ系連用テ形)+副助詞「は/も」のとき、副助詞を削除する
17.	接頭辞(「御、ご、お」を除く)+任意の形態素のとき、この2語を1語にする

本手法は、Juman の出力結果に対し、表1に示したルールを再帰的に適用することで、後処理を行う。その結果、たとえば、Juman によりサ変名詞「削除」、動詞「する」、形容詞性述語接尾辞「ない」の3語に分けられるフレーズ「削除しない」は、ルール8とルール9を順に適用することにより、「削除しない」という動詞1語として扱われる。同様に、普通名詞「ホームラン」と判定詞「だ」の2語に分けられるフレーズ「ホームランだ」は、ルール10を適用することにより、「ホームランだ」という形容詞1語として扱われ、名詞接頭辞「再」とサ変名詞「チャレンジ」の2語に分けられるフレーズ「再チャレンジ」は、ルール17を適用することにより、サ変名詞1語として扱われる。以上のような後処理の結果から助詞、連体詞、指示詞を取り除いたものが単語 unigram として利用される。

3.3.2 単語 unigram をエントリとする印象辞書の構築

次に、前項の方法で生成された単語 unigram を用いて印象辞書を自動構築する手法について述べる。

まず、「ある印象を有する単語 unigram は、その印象を表現する印象語群と共起しやすく、逆の印象を表現する印象語群とは共起しにくい」という仮定を置き、この仮定のもと、5年分の読売新聞記事データ(2002年版~2006年版)から生成される任意の単語 unigram U と印象尺度ごとに用意される対比的な印象の2つの印象語群との(記事内)共起の仕方を調べ、どちらの印象語群とより共起しやすいかを数値化したものを、 U の当該印象尺度における印象値として印象辞書に登録する。具体的な手順を以下に示す。

まず、各印象尺度の左側の印象(楽しい、うれしい、のどか)を表す印象語群 I_L と右側の印象(悲しい、怒り、緊迫)を表す印象語群 I_R を表2のように定義し、解析対象となる新聞記事データから印象語群 I_L あるいは I_R に含まれる印象語を1語以上含む記事を抽出するとともに、各記事に含まれる印象語の数を印象語群ごとに数える。

以上の結果、印象語群 I_L に属する印象語の数が印象語群 I_R に属する印象語の数よりも多かった記事の集合を S_L (記事数を N_L) とし、逆に少なかった記事の集合を S_R (記事数を N_R) とする。

次に、それぞれの記事集合 (S_L もしくは S_R) からすべての形態素を抽出し、前節で述べた手法を用いて単語

表2 各印象尺度を構成する印象語群

Table 2 Sets of impression words constituting each impression scale.

印象尺度	印象語群(上段: I_L , 下段: I_R)
楽しい ⇔ 悲しい	楽しい, 楽しむ, 楽しみだ, 楽しげだ 悲しい, 悲しむ, 悲しみだ, 悲しげだ
うれしい ⇔ 怒り	うれしい, 喜ばしい, 喜ぶ 怒る, 憤る, 激怒する
のどか ⇔ 緊迫	のどかだ, 和やかだ, 素朴だ, 安心だ 緊迫する, 不気味だ, 不安だ, 恐れる

unigram を生成するとともに、その出現記事数を数える。このとき、ある単語 unigram U の記事集合 S_L における出現記事数を $N_L(U)$ 、記事集合 S_R における出現記事数を $N_R(U)$ とすると、それぞれの条件付き出現確率 $P_L(U)$ と $P_R(U)$ は次のように表される。

$$P_L(U) = \frac{N_L(U)}{N_L}$$

$$P_R(U) = \frac{N_R(U)}{N_R}$$

この $P_L(U)$ と $P_R(U)$ を用いて、単語 unigram U の印象値 $v(U)$ を以下の式で計算する。

$$v(U) = \frac{P_L(U) \cdot W_L}{P_L(U) \cdot W_L + P_R(U) \cdot W_R}$$

ただし、 W_L と W_R は、条件を満たす記事数 (N_L あるいは N_R) が多いほど大きくなるように設計された重みであり、以下の式で計算する。

$$W_L = \log_{10} N_L$$

$$W_R = \log_{10} N_R$$

以上の計算により得られる、単語 unigram U の印象語群 I_L に対する条件付き出現確率 $P_L(U)$ と印象語群 I_R に対する条件付き出現確率 $P_R(U)$ の重み付き内分比 $v(U)$ を、単語 unigram U の印象尺度「 $I_L \Leftrightarrow I_R$ 」における印象値として印象辞書に登録する。

なお、表 2 に示した印象語群 I_L と I_R は、i) それぞれの印象尺度の印象を表す単語（動詞もしくは形容詞）であること、ii) 語義の多様性により他の印象を（なるべく）持たない単語であること、という基準に基づいて決められている。また、表 3 は、それぞれの印象尺度において条件を満たした記事数 (N_L と N_R) を示している。

3.3.3 記事印象値の算出と 7 段階評価スケールへの換算

印象辞書を用いて新聞記事の印象値を算出する手法について述べる。

まず、3.3.1 項に示した方法で、入力された記事から単語 unigram を生成する。次に、生成された各単語 unigram の印象値を 3.3.2 項で構築した印象辞書から取り出し、印象尺度ごとに平均値を算出する。この平均値をその記事の当該印象尺度における印象値として扱う。なお、この印象値（以下、算出値と呼ぶ）は、印象尺度の左側の印象（楽

表 3 各印象尺度において条件を満たす記事の数

Table 3 Number of articles satisfying a specific condition in each impression scale.

印象尺度	N_L	N_R
楽しい \Leftrightarrow 悲しい	79,596	6,272
うれしい \Leftrightarrow 怒り	57,252	6,561
のどか \Leftrightarrow 緊迫	8,109	46,803

しい、うれしい、のどか) が強いと 1 に近づき、右側の印象（悲しい、怒り、のどか) が強いと 0 に近づくように設計されているが、3.2 節で行ったアンケート調査では印象尺度の左側の印象が強いときは 1 に近づき、右側の印象が強いときは 7 に近づくという設計になっていたので、

$$\text{換算値} = (1 - \text{算出値}) \times 6 + 1$$

という式を用いて同じスケールになるよう算出値を換算した。

3.4 回帰式による記事印象値の補正

それぞれの印象尺度において、3.2 節で用意した全 90 記事（の第 1 段落）から求められる換算値を説明変数、この 90 記事（の第 1 段落）に対し回答者が付けた 7 段階評価値の平均値（印象評価データ）を目的変数とする回帰分析を行い、両者の対応関係を示す最適な回帰式（三次関数もしくは五次関数）を得た。結果を表 4 に示す。この回帰式に換算値を代入することにより、換算値を補正することができる（以下、補正された換算値を補正值と呼ぶ）。なお、この回帰分析では、様々な回帰モデル（直線、ロジスティック曲線、二次関数、三次関数、四次関数、五次関数など）が試され、その中から最も高い自由度修正済み決定係数 [26] を得たものが最適な関数として選ばれている。

ここで、各回帰式の自由度修正済み決定係数を表 5 に示し、各印象尺度における回帰分析の結果を図 1 にまとめる。表 5 によれば、自由度修正済み決定係数は、いずれの印象尺度においても 0.5 より高く、回帰式のあてはまり具合が良いことを示している。また、図 1 は換算値（説明変数）と回答者の平均値（目的変数）の散布図と回帰式を示しており、各回帰式が換算値と平均値の間のギャップを狭

表 4 90 記事分のデータから生成された回帰式（単語 unigram のみ）
Table 4 Regression equations designed for impression data of ninety articles (word unigram features).

印象尺度	回帰式 (x : 換算値)
楽しい \Leftrightarrow 悲しい	$-1.6355586x^3 + 18.971570x^2 - 70.68575x + 88.5147$
うれしい \Leftrightarrow 怒り	$2.384741939x^5 - 46.87159982x^4 + 363.6602058x^3 - 1391.589442x^2 + 2627.06261x - 1955.3058$
のどか \Leftrightarrow 緊迫	$-1.7138394x^3 + 21.942197x^2 - 90.79203x + 124.8218$

表 5 回帰式の分析精度（単語 unigram のみ）

Table 5 Accuracy of regression equations (word unigram features).

印象尺度	自由度修正済み決定係数
楽しい \Leftrightarrow 悲しい	0.62
うれしい \Leftrightarrow 怒り	0.79
のどか \Leftrightarrow 緊迫	0.63

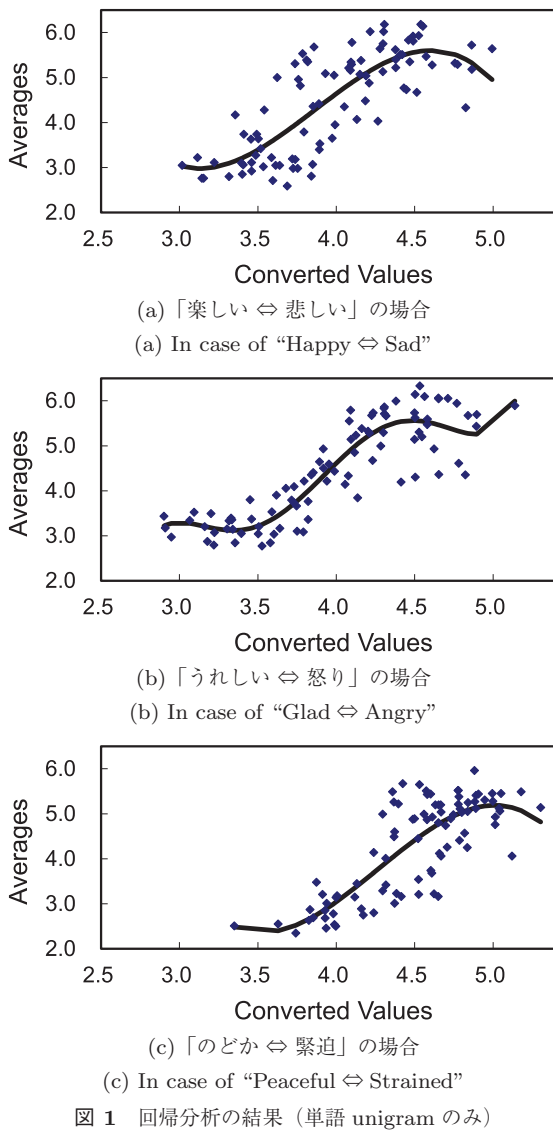


Fig. 1 Results of regression analysis (word unigram features).

めていることが分かる。

4. 重回帰式による記事印象値の再計算

本章では、まず前章で説明した手法 [18] からの拡張点として単語 bigram の導入部分に関して述べ、次に重回帰分析に基づいて記事の印象値 (補正值) を算出し直すための手法を提案する。この重回帰分析では、3つの印象尺度において特定の記事特徴量 (単語 unigram のみ, 単語 bigram のみ, あるいは単語 unigram と単語 bigram の両方) を用いて求められる補正值を説明変数, 3.2 節のアンケート調査の結果に基づいて算出された回答者の平均値 (印象評価データ) を目的変数とする重回帰分析を印象尺度ごとに行い、それぞれの対応関係を重回帰式という形で定式化する。

4.1 単語 bigram の生成

本節では、新聞記事から記事特徴量として単語 bigram を生成する手法について説明する。

表 6 単語 bigram 生成ルール

Table 6 Rules for generating word bigram features from results of post-processing.

核となる形態素が普通名詞/カタカナのとき
<ul style="list-style-type: none"> 直前にある動詞/形容詞/判定詞。ただし、その活用形が基本形/タ形/文語基本形/テアル列基本形/基本連体形/文語連体形/ダ列基本連体形/ダ列文語連体形/ダ列特殊連体形/その他の基本形/その他の連体形の場合のみ 直前にある名詞 (形式名詞と副詞的名詞を除く)/未定義語/形容詞 (語幹)。ただし、核となる形態素との間に 1 個以上の格助詞/接続助詞があってもよい
核となる形態素がサ変名詞のとき
<ul style="list-style-type: none"> 直前にある動詞/形容詞/判定詞。ただし、その活用形が基本形/タ形/文語基本形/テアル列基本形/基本連体形/文語連体形/ダ列基本連体形/ダ列文語連体形/ダ列特殊連体形/その他の基本形/その他の連体形の場合のみ 前出する動詞/形容詞/判定詞。ただし、その活用形が基本連用形/文語連用形/ダ列基本連用形/ダ列特殊連用形/ダ列文語連用形/その他の連用形の場合のみ 前出する名詞 (形式名詞と副詞的名詞を除く)/未定義語/形容詞 (語幹)/副詞
核となる形態素が動詞/形容詞のとき
<ul style="list-style-type: none"> 前出する動詞/形容詞/判定詞。ただし、その活用形が基本連用形/文語連用形/ダ列基本連用形/ダ列特殊連用形/ダ列文語連用形/その他の連用形の場合のみ 前出する名詞 (形式名詞と副詞的名詞を除く)/未定義語/形容詞 (語幹)/副詞
核となる形態素が判定詞のとき
<ul style="list-style-type: none"> 直前にある動詞/形容詞。ただし、その活用形が基本形/タ形/文語基本形/テアル列基本形/基本連体形/文語連体形/ダ列基本連体形/ダ列文語連体形/ダ列特殊連体形/その他の基本形/その他の連体形の場合のみ

単語 bigram は、3.3.1 項に示した形態素解析と後処理を行った結果に、表 6 に示したルールを適用することにより、生成される。単語 bigram の核となる形態素は、表 6 に示したように、普通名詞, カタカナ, サ変名詞, 動詞, 形容詞, 判定詞であり、それぞれの形態素に対してルールに整合する形態素が同一文内にあるかどうかをチェックし、あれば、ペアとして単語 bigram を生成する。このチェックは、核となる形態素を基準に文頭方向に対して行われるが、動詞/形容詞/判定詞/サ変名詞が現れた時点で打ち切られる。ただし、他の品詞 (主に普通名詞や未定義語) が現れても打ち切られないので、その結果、1つの核となる形態素から複数の単語 bigram が生成されることもある。

4.2 単語 bigram をエントリとする印象辞書の構築

単語 bigram を記事特徴量とする場合の印象辞書の自動構築は、3.3.2 項で述べた、単語 unigram を記事特徴量とする場合の手法と同じアルゴリズムで行われる。すなわち、

表 7 90 記事分のデータから生成された回帰式 (単語 bigram のみ)

Table 7 Regression equations designed for impression data of ninety articles (word bigram features).

印象尺度	回帰式 (x : 換算値)
楽しい ⇔ 悲しい	$0.00697781x^5 - 0.087062931x^4 + 0.236357677x^3 + 0.674432364x^2 - 2.743114097x + 5.343448159$
うれしい ⇔ 怒り	$0.013647721x^5 - 0.190165208x^4 + 0.777479789x^3 - 0.273660346x^2 - 3.131896274x + 6.857487555$
のどか ⇔ 緊迫	$0.163772013x^5 - 4.019323402x^4 + 38.52678817x^3 - 180.0471523x^2 + 410.6745046x - 363.673368$

3.3.2 項のそれぞれの式において単語 unigram U の代わりに、単語 bigram B を用いればよい。

4.3 単語 bigram による記事印象値の算出と 7 段階評価スケールへの換算

単語 bigram を記事特徴量とする場合の記事印象値の算出も、3.3.3 項で述べた、単語 unigram を記事特徴量とする場合の手法と同じアルゴリズムで行われる。すなわち、入力された記事を Juman を用いて形態素に分解し、表 1 に示したルールを用いて後処理を行った後、4.1 節に示した方法で単語 bigram を生成する。次に、生成された単語 bigram の印象値をあらかじめ構築されている印象辞書から取り出し、印象尺度ごとに平均値を計算する。以上の結果得られた平均値を 1~7 の 7 段階評価スケールに換算したものを、その記事の当該印象尺度における印象値 (換算値) として出力する。

なお、単語 unigram の処理と単語 bigram の処理は独立に行われるので、1 つの記事から共通部分を有する単語 unigram と単語 bigram が生成されても、それぞれ別個に計算される。


4.4 換算値の回帰式による補正

単語 bigram を記事特徴量とする場合の回帰式の生成も、3.4 節で述べた、単語 unigram を記事特徴量とする場合の手法と同じアルゴリズムで行われる。すなわち、それぞれの印象尺度において、前節に示した方法で全 90 記事から算出される換算値を説明変数、3.2 節のアンケート調査の結果に基づいて算出された回答者の平均値 (印象評価データ) を目的変数とする回帰分析を行い、両者の対応関係を表す回帰式 (五次関数) を生成した。結果を表 7 に示す。以下では、この回帰式を用いて補正された換算値も補正值と呼ぶ。なお、今回の回帰分析でも、様々な回帰モデル (直線、ロジスティック曲線、二次関数、三次関数、四次関数、五次関数など) を試しており、その中から最も高い自由度修正済み決定係数を得たものを最適な関数として選んでいる。


表 8 回帰式の分析精度 (単語 bigram のみ)

Table 8 Accuracy of regression equations (word bigram features).


印象尺度	自由度修正済み決定係数
楽しい ⇔ 悲しい	0.53
うれしい ⇔ 怒り	0.69
のどか ⇔ 緊迫	0.56



(a) 「楽しい ⇔ 悲しい」の場合
(a) In case of "Happy ⇔ Sad"



(b) 「うれしい ⇔ 怒り」の場合
(b) In case of "Glad ⇔ Angry"



(c) 「のどか ⇔ 緊迫」の場合

(c) In case of "Peaceful ⇔ Strained"

図 2 回帰分析の結果 (単語 bigram のみ)

Fig. 2 Results of regression analysis (word bigram features).

ここで、各回帰式の自由度修正済み決定係数を表 8 に示し、各印象尺度における回帰分析の結果を図 2 にまとめる。表 8 によれば、表 5 と同様、自由度修正済み決定係数は、いずれの印象尺度においても 0.5 より高く、回帰式のあてはまり具合が良いことを示しているが、表 5 の値に比べれば、少し値が低いことも分かる。また、図 2 は換算値 (説明変数) と回答者の平均値 (目的変数) の散布図と回帰式を示しており、各回帰式が換算値と平均値の間のギャップを狭めていることが分かる。

4.5 重回帰分析に資するデータの準備

本節では、重回帰分析に資するデータを3種類準備する。すなわち、単語 unigram のみを記事特微量とする場合、単語 bigram のみを記事特微量とする場合、単語 unigram と単語 bigram の両方を記事特微量とする場合の3種類である。

まず、重回帰分析における目的変数は、3.2節のアンケート調査の結果に基づいて算出された回答者の平均値（印象評価データ）であり、いずれの場合においても同じデータが用いられる。一方、説明変数は、3.2節のアンケート調査で回答者に提示した記事（第1段落のみ）から求められる補正值となるが、用いる記事特微量の種類に応じて求め方が異なっている。すなわち、単語 unigram を用いるときは3.3節と3.4節に示した手法を用い、単語 bigram を用いるときは4.3節と4.4節に示した手法を用いる。いずれの場合も印象尺度に対応した3種類の補正值が説明変数として得られる。単語 unigram と単語 bigram の両方を用いるときは、それぞれの場合の補正值をすべて用い、6種類の補正值が説明変数として得られる。

ここで、全90記事から求めた6種類の補正值（6個の説明変数）と各印象尺度における回答者の平均値（目的変数）との対応関係を印象尺度ごとに整理し、散布図という形で図3(a)（「楽しい ⇔ 悲しい」の場合）、図3(b)（「うれしい ⇔ 怒り」の場合）、図3(c)（「のどか ⇔ 緊迫」の場合）に示す。図中の点は、記事特微量の種類によって区分されており、各区分ごとに90個の点がプロットされている。ただし、プロットが重なる場合は「楽しい ⇔ 悲しい」が上、「のどか ⇔ 緊迫」が下となり、印象尺度が同じ場合は単語 bigram が上、単語 unigram が下になる。

4.6 重回帰分析に基づく重回帰式の生成

前節で準備した3種類のデータを用いて、印象尺度ごとに重回帰分析を行った。このとき、変数選択法として変数増加法 [26] を採用することで、変数間の独立性が乏しいときに発生する多重共線性の問題を回避し、記事の印象値を求めるのに適した説明変数を取捨選択した。その結果、表9（単語 unigram のみを用いた場合）、表10（単語 bigram のみを用いた場合）、表11（単語 unigram と単語 bigram の両方を用いた場合）に示す重回帰式が生成された。

ここで、各重回帰式の自由度修正済み決定係数を表12に示す。表12によれば、表5や表8と同様、自由度修正済み決定係数は、いずれの印象尺度においても0.5より高く、重回帰式のあてはまり具合が良いことを示している。さらに、表12に示された値は、表5や表8に示された値より高く、あてはまり具合が向上していることも分かる。また、表12から、単語 bigram より単語 unigram の方が、単語 unigram より単語 unigram と単語 bigram の両方を用

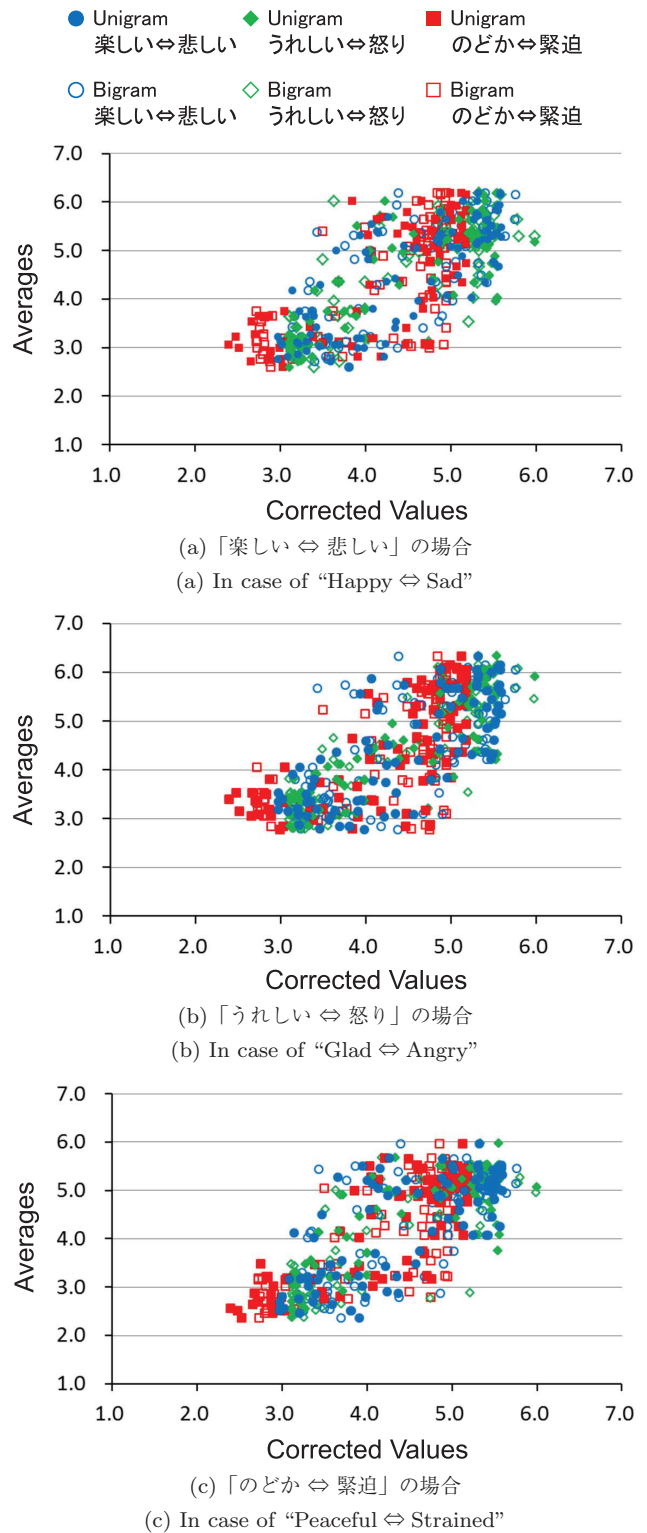


図3 重回帰分析に資するデータの散布図
 Fig. 3 Scatter diagrams for the data to which multiple regression analysis is applied.

いた方があてはまり具合が良いことも分かる。

4.7 重回帰式の利用方法

本節では、前節で生成された重回帰式の利用方法を示す。具体的には、印象尺度が「のどか ⇔ 緊迫」、用いる記事特微量が単語 unigram と単語 bigram の両方の場合を例

表 9 90 記事分のデータから生成された重回帰式 (単語 unigram のみ)

Table 9 Multiple regression equations designed for impression data of ninety articles (word unigram features).

印象尺度	説明変数	偏回帰係数
楽しい ⇔ 悲しい	Unigram 楽しい ⇔ 悲しい	0.313
	Unigram うれしい ⇔ 怒り (定数項)	0.723 (-0.152)
うれしい ⇔ 怒り	Unigram うれしい ⇔ 怒り (定数項)	1.000 (0.000)
のどか ⇔ 緊迫	Unigram うれしい ⇔ 怒り	0.655
	Unigram のどか ⇔ 緊迫 (定数項)	0.383 (-0.269)

表 10 90 記事分のデータから生成された重回帰式 (単語 bigram のみ)

Table 10 Multiple regression equations designed for impression data of ninety articles (word bigram features).

印象尺度	説明変数	偏回帰係数
楽しい ⇔ 悲しい	Bigram 楽しい ⇔ 悲しい	0.327
	Bigram うれしい ⇔ 怒り	0.568
	Bigram のどか ⇔ 緊迫 (定数項)	0.328 (-0.922)
うれしい ⇔ 怒り	Bigram うれしい ⇔ 怒り	0.874
	Bigram のどか ⇔ 緊迫 (定数項)	0.221 (-0.386)
のどか ⇔ 緊迫	Bigram うれしい ⇔ 怒り	0.616
	Bigram のどか ⇔ 緊迫 (定数項)	0.563 (-0.868)

表 11 90 記事分のデータから生成された重回帰式 (単語 unigram と単語 bigram の両方)

Table 11 Multiple regression equations designed for impression data of ninety articles (word unigram and bigram features).

印象尺度	説明変数	偏回帰係数
楽しい ⇔ 悲しい	Bigram 楽しい ⇔ 悲しい	0.216
	Unigram うれしい ⇔ 怒り	0.515
	Bigram うれしい ⇔ 怒り	0.248
	Bigram のどか ⇔ 緊迫	0.175
	(定数項)	(-0.642)
うれしい ⇔ 怒り	Bigram 楽しい ⇔ 悲しい	-0.149
	Unigram うれしい ⇔ 怒り	0.847
	Bigram うれしい ⇔ 怒り	0.309
	(定数項)	(-0.026)
のどか ⇔ 緊迫	Unigram うれしい ⇔ 怒り	0.465
	Bigram うれしい ⇔ 怒り	0.277
	Bigram のどか ⇔ 緊迫	0.394
	(定数項)	(-0.705)

に、重回帰式を用いて記事の印象値を求める方法を示す。すなわち、ある記事の印象尺度「のどか ⇔ 緊迫」における印象値 y は、その記事から算出される説明変数「Unigram

表 12 重回帰式の分析精度

Table 12 Accuracy of multiple regression equations.

印象尺度	自由度修正済み決定係数		
	unigram	bigram	unigram+bigram
楽しい ⇔ 悲しい	0.73	0.71	0.74
うれしい ⇔ 怒り	0.80	0.71	0.82
のどか ⇔ 緊迫	0.75	0.74	0.77

うれしい ⇔ 怒り」, 「Bigram うれしい ⇔ 怒り」, 「Bigram のどか ⇔ 緊迫」の値 (補正值) をそれぞれ x_1, x_2, x_3 とすると、表 11 に示したとおり、

$$y = 0.465x_1 + 0.277x_2 + 0.394x_3 - 0.705$$

という式で求められる。

5. 性能評価

本章では、提案手法の学習データと未知データに対する精度を評価し、その有効性を検証するとともに、学習データに対する誤差解析を行い、今後の課題について考察する。

5.1 学習データに対する精度評価

まず、回帰分析と重回帰分析を行った際に用いた全 90 記事 (の第 1 段落) を対象に、提案手法が出力する印象値と回答者が付けた 7 段階評価値の平均値 (印象評価データ) との誤差が回帰式や重回帰式の導入によりどう変化するかを調べた。結果を表 13 にまとめる。ただし、表 13 において、「ベースライン 1」は印象辞書を用いて算出された換算値との誤差を、「ベースライン 2」は回帰式で補正された補正值との誤差を、「提案手法」は回帰式と重回帰式を併用して求めた印象値との誤差を示している。また、参考のために、3 つの印象尺度における換算値を説明変数、回答者の平均値 (印象評価データ) を目的変数とする重回帰分析を行い、回帰式を用いない、重回帰式のみ的手法 [27] も準備した。「ベースライン 3」はこの重回帰式のみ的手法で計算された印象値との誤差を示している。なお、誤差には、Root-Mean-Square Error (RMSE) を用いており、全 90 記事に対する印象値と回答者の平均値の差分平方和を記事数 (= 90) で割り、平方根をとることにより求められる。

表 13 によれば、RMSE は、用いる記事特徴量の種類に関係なく、ベースライン 1 よりベースライン 2 や 3 の方が小さい。一方、ベースライン 2 と 3 を比べてみると、「楽しい ⇔ 悲しい」と「のどか ⇔ 緊迫」ではベースライン 3 の方が小さいが、「うれしい ⇔ 怒り」ではベースライン 2 の方が小さい。そこで、ベースライン 2 または 3 の RMSE が小さい方と提案手法の RMSE を比べてみた。その結果、単語 unigram のみの場合の「うれしい ⇔ 怒り」に対しては同じ RMSE (= 0.47) であったが、それ以外の組合せに対しては提案手法の RMSE の方が小さかった。

次に、用いる記事特徴量の種類により提案手法の RMSE

表 13 回帰式と重回帰式の導入による誤差 (RMSE) の減少
 Table 13 Change of errors or RMSEs by using simple and/or multiple regression equations.

(a) 単語 unigram のみ			
	楽しい ⇔ 悲しい	うれしい ⇔ 怒り	のどか ⇔ 緊迫
印象辞書のみ (ベースライン 1)	0.94	0.83	0.82
回帰式のみ (ベースライン 2)	0.67	0.47	0.63
重回帰式のみ (ベースライン 3)	0.66	0.58	0.61
回帰式+重回帰式 (提案手法)	0.57	0.47	0.52
(b) 単語 bigram のみ			
	楽しい ⇔ 悲しい	うれしい ⇔ 怒り	のどか ⇔ 緊迫
印象辞書のみ (ベースライン 1)	1.34	1.05	1.22
回帰式のみ (ベースライン 2)	0.74	0.59	0.68
重回帰式のみ (ベースライン 3)	0.65	0.61	0.60
回帰式+重回帰式 (提案手法)	0.59	0.57	0.53
(c) 単語 unigram と単語 bigram の両方			
	楽しい ⇔ 悲しい	うれしい ⇔ 怒り	のどか ⇔ 緊迫
重回帰式のみ (ベースライン 3)	0.64	0.56	0.57
回帰式+重回帰式 (提案手法)	0.55	0.45	0.50

がどう変わるかを表 13 により調べた。その結果、いずれの印象尺度においても、単語 unigram と単語 bigram の両方を用いた場合の RMSE が最も小さく、単語 unigram のみの場合の RMSE が 2 番目に小さかった。

以上のことから、学習データに対しては、単語 unigram と単語 bigram の両方を用いた場合の提案手法が最も精度が高く (RMSE が小さく)、有効であることが分かった。

ここで、参考のために、単語 unigram と単語 bigram の両方を用いた場合の提案手法が出力する印象値と 100 人の回答者が付与した 7 段階評価値の平均値との対応関係を図 4 に示す。図 4 が示す対応関係と、図 1, 図 2, 図 3 に示された換算値あるいは補正值と回答者の平均値との対応関係とを見比べてみると、データの分布が対角線上により近づいており、誤差が改善されていることを視覚的にも把握できる。

一方、重回帰分析に用いた目的変数と各説明変数の相関係数を調べ、表 14 にまとめてみると、いずれの目的変数に対しても「Unigram うれしい⇔怒り」が最も高い値であ

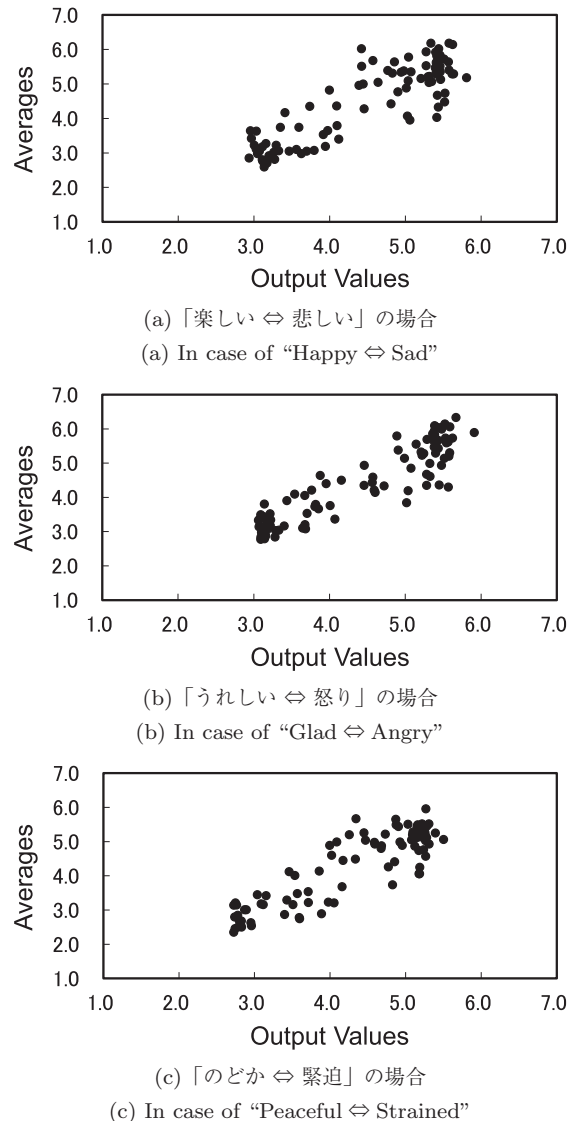


図 4 提案手法の出力値と 100 人の回答者が付けた 7 段階評価値の平均値との対応関係 (単語 unigram と単語 bigram の両方)

Fig. 4 Scatter plots between output values computed by our proposed method and averages of values rated by 100 respondents (both word unigram features and word bigram features).

表 14 補正值と回答者の平均値の相関係数

Table 14 Coefficients of correlation between corrected values and averages.

説明変数 (補正值)	目的変数 (回答者の平均値)		
	楽しい ⇔ 悲しい	うれしい ⇔ 怒り	のどか ⇔ 緊迫
Unigram 楽しい⇔悲しい	0.79	0.76	0.75
Bigram 楽しい⇔悲しい	0.75	0.67	0.71
Unigram うれしい⇔怒り	0.85	0.90	0.85
Bigram うれしい⇔怒り	0.80	0.84	0.80
Unigram のどか⇔緊迫	0.73	0.73	0.80
Bigram のどか⇔緊迫	0.69	0.63	0.76

ることが分かる。複数の印象尺度を設計するとき、それぞれの印象尺度の違いを印象語群にどう反映させるかは、1本の評価尺度を対象とする評判分析研究にはない、難しい問題であり、現段階では印象尺度を構成する印象語（楽しい、悲しい、うれしい、怒り、のどか、緊迫）の同義語・類義語をベースに試すということを行っている。重回帰分析の結果、いずれの目的変数に対しても「Unigram うれしい⇔怒り」が最も高い相関係数を持つ説明変数となったわけだが、この説明変数だけでは十分でなく、それぞれの印象尺度に対応した説明変数と組み合わせることで、より高い精度が実現されていることが分かる。一方、重回帰分析（変数増加法）を採用した今回の提案手法では、精度の向上に貢献する印象語群を自由に設計し、追加することができる。すなわち、それぞれの印象尺度を表現する印象語群を一意に決定するのが困難な中、いろいろな印象語群を試してみることができるというのも本手法の利点の1つといえる。

5.2 未知データに対する精度評価

まず、学習データを用いて5分割交差検定を行い、未知データに対する精度評価を行った。具体的には、(1) 90記事分の学習データを5分割し、18記事に対する換算値と回答者の平均値のデータセットを5つ作成する、(2) この5つのデータセットのうちの4つ（72記事分の換算値と回答者の平均値）を用いて回帰分析と重回帰分析を行い、それぞれの印象尺度に対して最適な回帰式と重回帰式を生成する、(3) 残りのデータセット（18記事分の換算値と回答者の平均値）を未知データとし、その換算値を回帰式に代入する、(4) その結果得られる補正値を重回帰式に代入し、提案手法による記事の印象値を得る、(5) 以上の処理の結果得られる18記事分の補正値/印象値と回答者の平均値との誤差（RMSE）を求め、という手順をすべての組合せ（5通り）に対して行った。その結果得られたRMSE（5回分）の平均値（平均誤差）を表15に示す。表15において、「ベースライン2」は補正値と回答者の平均値との平均誤差を示しており、「提案手法」は印象値と回答者の平均値との平均誤差を示している。

表15より、ベースライン2と提案手法の平均誤差を比べてみると、「うれしい⇔怒り」に対しては同じ精度を保ちつつ、「楽しい⇔悲しい」と「のどか⇔緊迫」に対する精度が大きく改善していることが分かる。なお、先行研究で提案した手法[18]は、単語 unigram のみを記事特徴量とする場合のベースライン2手法と同一なので、この手法に対しても同じことがいえる。

以上のことから、未知データに対しても、回帰式と重回帰式を組み合わせることで、より高精度な印象マイニングを実現できることが確認された。なお、表16は、各データセットにおける回答者の平均値の基本統計量（平均値と

表 15 5分割交差検定による精度評価
Table 15 Estimation of overall accuracy based on 5-fold cross-validation.

(a) 単語 unigram のみ			
	楽しい ⇔ 悲しい	うれしい ⇔ 怒り	のどか ⇔ 緊迫
回帰式のみ (ベースライン2)	0.69	0.49	0.64
回帰式+重回帰式 (提案手法)	0.60	0.49	0.52
(b) 単語 bigram のみ			
	楽しい ⇔ 悲しい	うれしい ⇔ 怒り	のどか ⇔ 緊迫
回帰式のみ (ベースライン2)	0.75	0.61	0.70
回帰式+重回帰式 (提案手法)	0.65	0.61	0.58
(c) 単語 unigram と単語 bigram の両方			
	楽しい ⇔ 悲しい	うれしい ⇔ 怒り	のどか ⇔ 緊迫
回帰式+重回帰式 (提案手法)	0.62	0.50	0.55

表 16 各データセットにおける回答者の平均値の基本統計量（平均値と標準偏差）

Table 16 Means and standard deviations of respondents' averages in each dataset.

データ セット ID	楽しい ⇔ 悲しい	うれしい ⇔ 怒り	のどか ⇔ 緊迫
全体 (1~5)	4.46 1.10	4.44 1.08	4.28 1.06
1	4.51 1.09	4.37 1.07	4.22 1.02
2	4.47 1.09	4.40 1.07	4.27 0.93
3	4.39 1.06	4.43 1.07	4.16 1.16
4	4.51 1.13	4.49 1.07	4.44 1.01
5	4.42 1.14	4.53 1.09	4.30 1.14

(上段は平均値を、下段は標準偏差を示す)

標準偏差)を示しており、学習データの分割に際し、各データセットに極端な偏りがなかったことを表している。

次に、用いる記事特徴量の種類により提案手法の精度（RMSE）がどう変わるかという観点から表15を見てみると、いずれの印象尺度においても、単語 unigram のみを用いた場合のRMSEが最も小さく、単語 unigram と単語 bigram の両方を用いた場合のRMSEが2番目に小さいことが分かる。単語 bigram は、網羅性が低い反面、単語どうしの組合せを考慮に入れることができることから、名詞の

接続や述語構造などを考慮する研究 [5], [16] では, その有用性が示されていた. 実際, 学習データに対しては, 単語 unigram と組み合わせることで, 精度の向上 (表 13 参照) に貢献しているが, 未知データに対しては, わずかではあるが精度が悪化している. その原因としては, 学習データに対する回帰分析あるいは重回帰分析で過学習が生じた可能性や, 回帰分析・重回帰分析に資するデータのサイズが 5 分割交差検定では 5 分の 4 になることにともない, データスパース性が増した可能性が考えられる. 具体的な原因の分析と対応策については, 今後の課題としたい.

5.3 学習データに対する誤差解析

ここで, 学習データ (全 90 記事分) を対象に, 誤差 (回答者による 7 段階評価値の平均値と提案手法 (表 9 に示した単語 unigram のみを用いる手法) により算出された印象値との差の絶対値) が大きかった記事の内容を調べてみた.

まず, 学習データから回答者の平均値と印象値の差が +1 以上であった記事を印象尺度ごとに抽出した結果, 「楽しい ⇔ 悲しい」で 4 記事, 「うれしい ⇔ 怒り」で 0 記事, 「のどか ⇔ 緊迫」で 5 記事あり, 全部で 9 記事を得た. この 9 記事の各々の平均値は, 4.89~6.02 の範囲に分布しており, 総じて負の印象 (悲しい, 緊迫) が強めであることが分かる. つまり, 提案手法は, この 9 記事の印象を実際よりも弱く評価していたことになる. 各記事の内容を調べてみると, その主な原因として, 以下の 2 点に気付く. 1 つは, 負の印象の強い単語があっても, そうでない単語が多いと, 記事の印象が弱められてしまうという点であり, これは, 記事から抽出される特徴量の印象値を単純に平均している点に問題があるといえる. もう 1 つは, 個々の単語にはあまり負の印象の強いものはないが, 記事全体としては強い印象を感じる場合があるという点であり, これは, 提案手法が個々の単語の印象値のみを処理対象とし, 話題などの大局的な情報を取り入れていない点に問題があるといえる. なお, 「うれしい ⇔ 怒り」に関しては該当する記事がなかったため, 回答者の平均値と印象値の差が大きかった上位 5 記事 (差は 0.64~0.88 の範囲) を調べてみた結果, 同じような傾向が観測された.

次に, 逆の場合, すなわち回答者の平均値と印象値の差が -1 以下であった記事を印象尺度ごとに抽出した結果, 「楽しい ⇔ 悲しい」で 3 記事, 「うれしい ⇔ 怒り」で 4 記事, 「のどか ⇔ 緊迫」で 4 記事の計 11 記事を得た. この 11 記事の各々の平均値は, 3.74~4.36 に分布しており, 中間値である「(どちらの印象も) 感じない (4 点)」に近い値となっている. これは, 提案手法がこの 11 記事の印象を負の印象 (実際には 5.04~5.56 の範囲に分布) と判断したことを意味しており, 回答者の平均値と印象値の差が +1 以上の場合は逆のパターンになっている. そこで, 各記事の内容を調べてみると, その主な原因として, 1 つのこ

とに気付く. すなわち, 負の印象の単語が比較的多く用いられている割に, 記事の内容がさほど深刻ではないということである. たとえば, 某国の難民への支援物資を輸送した海上自衛隊の掃海母艦が母港に帰港したという話や, ダイヤモンドの原石をお腹の中のみ込んでいた男が不法所持と密輸の疑いで逮捕されたという話, 名誉毀損や安眠妨害に対して損害賠償を求める訴訟があったという話などが相当しており, いずれの印象尺度においても同じような傾向であった.

以上, 本節で述べたような問題の解決に際し, いくつかの側面からのアプローチを考える. まず, 新たな説明変数の導入を検討する. たとえば, 記事から抽出される特徴量の印象値がどのように分布しているかを表す指標として, 現在用いている平均値に加え, 最大値や最小値, あるいは第 1 四分位数や第 3 四分位数といった統計量を用いることで, 記事内における特徴量の印象分布を重回帰式に取り込むことが可能となり, 高精度化に貢献することが期待される. 次に, 重要文抽出技術との組合せを考える. 悲惨な状況下で起きた明るい出来事を伝える記事やその逆など正の印象の単語と負の印象の単語が混在する記事も見受けられることから, 記事の印象を決定づけるような文 (あるいは事象) を抽出した後, その文 (あるいは事象) を対象に印象マイニングを行うという方法も有効かもしれない. また, 話題のタイプによって人々の感じる印象が強くなったり, 逆に弱くなったりすることもあるので, 記事の話題タイプを決定する技術と組み合わせることで, 印象値を算出するための重回帰式を話題タイプごとに設計するという方法も考えられる. 以上のようなことを今後の課題として取り組んでいきたい.

6. むすび

本論文では, 新聞記事を読んだ人々が感じる印象の強さ (印象値) を数値的に求めるための印象マイニング手法を提案した. 本手法が対象とする印象は, 「楽しい ⇔ 悲しい」, 「うれしい ⇔ 怒り」, 「のどか ⇔ 緊迫」の 3 種類であり, それぞれの印象に対して「(左側の印象を) 感じる (1 点), わりと感じる (2 点), やや感じる (3 点), (どちらの印象も) 感じない (4 点), (右側の印象を) やや感じる (5 点), わりと感じる (6 点), 感じる (7 点)」という 7 段階の評価スケール (印象尺度) を設定している. 提案手法は, それぞれの印象尺度において, このスケールに準じた 1.0~7.0 の実数値を印象値として出力する.

具体的には, まず, 著者らの先行研究 [18] で示した考え方に基づいて, 記事から抽出する特徴量として単語 unigram と単語 bigram を定義し, 新聞記事データベースから 6 つの印象辞書 (3 種類の印象尺度と 2 種類の記事特徴量に対応) を構築した. そして, それぞれの印象尺度において, 印象辞書を用いて算出される記事の印象値を説明変数, ア

ンケート調査に基づいて数値化される記事本来の印象値を目的変数とする回帰分析を行い、それぞれの対応関係を示す回帰式を生成した。この回帰式を用いることで、印象辞書を用いて算出される印象値が補正され、高精度な出力を得ることができるようになった。本論文ではさらに、3つの印象尺度において補正された印象値を説明変数、記事本来の印象値を目的変数とする重回帰分析を印象尺度ごとに行い、それぞれの対応関係を示す重回帰式を生成した。この重回帰式を用いることで、回帰式使用時に精度の良かった説明変数「Unigram うれしい ⇔ 怒り」を取り込むことが可能となり、その結果、より高精度な出力を得ることができるようになった。

提案手法の精度を、学習データ（全 90 記事分）を用いて評価してみたところ、重回帰式を導入することにより、より高精度になることが確認された。また、5分割交差検定により未知データに対する精度を調べてみたところ、それぞれの印象尺度における平均誤差は、「楽しい ⇔ 悲しい」で 0.60, 「うれしい ⇔ 怒り」で 0.49, 「のどか ⇔ 緊迫」で 0.52 という結果であり、未知データに対する精度も先行研究で提案した手法 [18] より高精度であることが確認された。

今後の課題としては、1つの記事の中での印象の推移を追跡できる印象マイニング手法の開発や、精度の向上に貢献する印象尺度（印象辞書）の設計（構築）、印象の感じ方の違いを吸収する個人適応手法の開発、新たな説明変数の導入や他の技術（重要文抽出技術、話題タイプ決定技術）との統合などがあげられる。一方、抽出された印象値を有効利用するアプリケーションの開発も必要不可欠であり、これまで応用してきた情報可視化や情報推薦、異メディアコンテンツ生成などの分野に加え、新たな分野（たとえば、身体障害者向けの情報保障に関する分野）にも応用していきたいと考えている。

謝辞 本研究は、JSPS 科研費 24500134, 千葉工業大学附属総合研究所科学研究助成金, SCOPE 若手 ICT 研究者育成型研究開発 (102107001), 筑波技術大学平成 24 年度競争的教育研究プロジェクト事業, JSPS 科研費 24800007, 福田将治奨学寄付金 (52303) による助成の成果であり、ここに記して謝意を表すものとする。

参考文献

[1] Picard, R.W.: *Affective Computing*, MIT Press (1997).
 [2] Busso, C., Deng, Z., Yildirim, S., Bulut, M., Lee, C.M., Kazemzadeh, A., Lee, S., Neumann, U. and Narayanan, S.: Analysis of emotion recognition using facial expressions, speech and multimodal information, *Proc. 6th International Conference on Multimodal Interfaces*, State College, PA, USA, pp.205-211 (2004).
 [3] Kipp, M. and Martin, J.-C.: Gesture and Emotion: Can basic gestural form features discriminate emotions?, *Proc. 3rd International Conference on Affective Com-*

puting and Intelligent Interaction, pp.1-8 (2009).
 [4] De Silva, P.R. and Bianchi-Berthouze, N.: Modeling human affective postures: An information theoretic characterization of posture features: Research Articles, *Computer Animation and Virtual Worlds*, Vol.15, No.3-4, pp.269-276 (2004).
 [5] Turney, P.D.: Thumbs up or thumbs down? Semantic orientation applied to unsupervised classification of reviews, *Proc. 40th Annual Meeting on Association for Computational Linguistics*, Philadelphia, USA, pp.417-424 (2002).
 [6] Pang, B. and Lee, L.: Seeing stars: Exploiting class relationships for sentiment categorization with respect to rating scales, *Proc. Annual Meeting on Association for Computational Linguistics*, Morristown, NJ, USA, pp.115-124 (2005).
 [7] Lin, K.H.-Y., Yang, C. and Chen, H.-H.: Emotion classification of online news articles from the reader's perspective, *Proc. 2008 IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology*, Vol.1, pp.220-226 (2008).
 [8] Kumamoto, T. and Tanaka, K.: Web OpinionPoll: Extensive Collection and Impression-based Visualization of People's Opinions, *Advances in Communication Systems and Electrical Engineering*, Vol.4, Chapter 17, pp.229-243, Springer, USA (2008).
 [9] 張 建偉, 河合由起子, 熊本忠彦, 田中克己: 地域性に基づく発信者の観差異を可視化するセンチメントマップシステムの提案, *情報処理学会論文誌データベース*, Vol.3, No.1 (TOD 45), pp.38-48 (2010).
 [10] 阿部健一, 藤本 悠, 大原剛三: ユーザーが受信メールから抱く感情に合わせた音楽推薦システム, 第 4 回データ工学と情報マネジメントに関するフォーラム, No.A9-1 (2012).
 [11] 河合由起子, 熊本忠彦, 田中克己: 印象と興味に基づくユーザ選好のモデル化手法の提案とニュースサイトへの応用, *知能と情報*, Vol.18, No.2, pp.173-183 (2006).
 [12] 矢野絵美, 北野有亮, 末吉恵美, 篠原 勲, ピンヤボン シーナット, 加藤俊一: 消費者の感性モデルを利用したレコメンデーションシステムの構築, *情報処理学会論文誌: データベース*, Vol.44, No.SIG 8 (TOD 18), pp.46-54 (2003).
 [13] 熊本忠彦, 灘本明代, 田中克己: 記事の印象を伝達するニュース番組生成システム wEE の設計と評価, *電子情報通信学会論文誌*, Vol.J90-D, No.2, pp.185-195 (2007).
 [14] 石塚賢吉, 鬼沢武久, 加藤 茂: 物語のシーンの印象に基づいた声楽曲の生成, *日本感性工学会論文誌*, Vol.10, No.4, pp.523-534 (2011).
 [15] 宮川祥子, 清木 康: 特定分野ドキュメントを対象とした意味的連想検索のためのメタデータ空間生成方式, *情報処理学会論文誌: データベース*, Vol.40, No.SIG 5 (TOD 2), pp.15-28 (1999).
 [16] 清水浩平, 萩原将文: 名詞と動詞の組み合わせに対する印象推定法, *日本感性工学会論文誌*, Vol.10, No.4, pp.505-514 (2011).
 [17] 山本祐輔, 手塚太郎, アダムヤトフト, 田中克己, WebAlert: Web 情報の印象集約を利用した閲覧ページ内容に対する反対意見提示, *日本データベース学会論文誌*, Vol.7, No.1, pp.251-256 (2008).
 [18] 熊本忠彦, 河合由起子, 田中克己: 新聞記事を対象とするテキスト印象マイニング手法の設計と評価, *電子情報通信学会論文誌*, Vol.J94-D, No.3, pp.540-548 (2011).
 [19] Church, K.W. and Hanks, P.: Word association norms, mutual information, and lexicography, *Computational Linguistics*, Vol.16, Issue 1, pp.22-29 (1990).

- [20] 清木 康, 金子昌史, 北川高嗣: 意味の数学モデルによる画像データベース探索方式とその学習機構, 電子情報通信学会論文誌, Vol.J79-D-II, No.4, pp.509-519 (1996).
- [21] 秋山広美, 小松孝徳, 清河幸子: オノマトペから感じる印象の客観的数値化方法の提案, 情報処理学会研究報告 (ヒューマンコンピュータインタラクション研究会), 2011-HCI-142, pp.1-7 (2011).
- [22] Kumamoto, T.: Design of Impression Scales for Assessing Impressions of News Articles, *International Workshop on Social Networks and Social Media Mining on the Web*, Tsukuba, Japan, Lecture Notes in Computer Science, Vol.6193, pp.285-295, Springer-Verlag (2010).
- [23] 大野 晋, 浜西正人 (編): 類語国語辞典, 角川書店, 東京 (1986).
- [24] CD-毎日新聞データ集 2002 年版, 日外アソシエーツ.
- [25] Kurohashi, S., Nakamura, T., Matsumoto, Y. and Nagao, M.: Improvements of Japanese morphological analyzer JUMAN, *Proc. International Workshop on Sharable Natural Language Resources*, Nara, Japan, pp.22-28 (1994).
- [26] 菅 民郎: 多変量統計分析, 現代数学社, 京都 (2000).
- [27] 熊本忠彦, 河合由起子, 張 建偉, 田中克己: 複数の印象辞書を用いるテキスト印象マイニング手法の設計と評価, Web とデータベースに関するフォーラム WebDB Forum 2011, 3G-2 (2011).



張 建偉 (正会員)


筑波技術大学産業技術学部助教。2005年筑波大学大学院システム情報工学研究科博士前期課程修了。2008年筑波大学大学院システム情報工学研究科博士後期課程修了。博士(工学)。埼玉大学情報メディア基盤センター産学官連携研究員, 京都産業大学コンピュータ理工学部特定研究員を経て, 2012年より現職。Webマイニング, Web情報システム, 情報保障の研究に従事。日本データベース学会会員。

(担当編集委員 井上 創造)



熊本 忠彦 (正会員)

千葉工業大学情報科学部教授。1988年筑波大学第三学群情報学類卒業。1990年同大学大学院理工学研究科修士課程修了。同年郵政省通信総合研究所(現, 独立行政法人情報通信研究機構)。2007年千葉工業大学情報科学部情報ネットワーク学科准教授を経て, 2010年より現職。テキスト印象マイニングとその応用(検索, 推薦, 可視化, ほか)に関する研究に従事。1996年筑波大学博士(工学)取得。FIT2004論文賞。電子情報通信学会, 人工知能学会, 言語処理学会, 日本データベース学会, 日本知能情報ファジィ学会, 日本感性工学会各会員。



河合 由起子 (正会員)

京都産業大学コンピュータ理工学部准教授。1997年九州工業大学情報工学部電子情報工学科卒業。2001年奈良先端科学技術大学院大学情報科学研究科情報システム学博士後期課程修了。同年独立行政法人情報通信研究機構。2006年京都産業大学理学部コンピュータ科学科講師を経て, 2008年より現職。博士(工学)。情報推薦, Webマイニング, 信憑性分析の研究に従事。電子情報通信学会, 日本データベース学会各会員。