

スピンモデルによる単語の感情極性判定

高村 大也 乾 孝司 奥村 学

東京工業大学 精密工学研究所

〒 226-8503 横浜市緑区長津田町 4259

{takamura,oku}@pi.titech.ac.jp, tinui@lr.pi.titech.ac.jp

単語の感情極性（望ましいか否か）を判定する方法を提案する。提案手法では、単語の感情極性をスピンの方向とみなし、語釈文によって構築された語彙ネットワークをスピン系でモデル化する。平均場近似を利用してスピン系の状態を近似的に求めることにより、単語の感情極性を判定する。また、系の状態に影響を与えるハイパーパラメータの予測方法も同時に提案する。英語と日本語で実験を行い、数語から十数語という少数の単語を種として、高い正解率で単語の感情極性判定が実現できることを示した。

キーワード：感情極性, 単語分類, スピン

Extracting Semantic Orientation of Words using Spin Model

Hiroya Takamura Takashi Inui Manabu Okumura

Tokyo Institute of Technology, Precision and Intelligence Laboratory

4259 Nagatsuta Midori-ku Yokohama, JAPAN, 226-8503

We propose a method for extracting semantic orientations of words: desirable or undesirable. Regarding semantic orientations as spins of electrons, we use the mean field approximation to compute the approximate probability function of the system instead of the intractable actual probability function. We also propose a criterion for parameter selection on the basis of magnetization. Given only a small number of seed words, the proposed method extracts semantic orientations with high accuracy in the experiments on English lexicon and Japanese lexicon. The result is comparable to the best value ever reported.

Keywords : semantic orientation, word classification, spin

1 序論

文書データにおける感情（意見や態度を含む）の判別は、様々な応用において重要になってきている。例を挙げると、インターネット上の電子掲示板に書き込まれたある製品に関する消費者の意見が特定・判別できると、その製品に関する広範囲なサーベイが可能になる。また、すべての回答に人間が目を通すことなくアンケートの概要を把握することも可能になる。そのような自動特定・判別を実現するための重要なリソースとして、各単語の感情極性（ポジティブ「望ましい」、もしくはネガティブ「望ましくない」）を挙げることができる。最も単純には、ある文書においてポジティブな単語が多く出現している場合、その文書全体もポジティブであると推測ができる。

本研究の目的は、そのような単語の感情極性を自動的に獲得する方法を提案することである。そのため、ここではスピン系のモデルを用いる。電子のスピンが方向（上向きあるいは下向き）を

持っているように、各単語は感情極性（ポジティブあるいはネガティブ）を持っている。電子のスピン系において隣り合ったスピンは同じ方向を持ちやすいという傾向がある。我々は、辞書の見出し語とその語釈文にある単語とは、同じ感情極性を持ちやすいと仮定し、語釈文で構築された語彙ネットワークをスピン系でモデル化する。スピン系で使用されている平均場近似を用いて系の状態を算出し、各単語の感情極性を判定する。さらに、系の状態に影響を与えるハイパーパラメータの予測方法も同時に提案する。ここでは、統計物理の基本的概念である平均磁化を用いる。

非常に小規模の初期単語集合（種となる単語とその感情極性）を与えるだけで、多くの単語の感情極性が高い正解率で判定できることを、実験的に示す。我々の実験では、英語語彙については81.9%、日本語語彙については79.8%の正解率を得た。手法の汎用性を示すために、別のタスクでの実験も行った。

2 関連研究

Turney ら (2003) は 2 種類の感情極性判定アルゴリズムを提案している。彼らは、ウェブの検索エンジンを用いて種となる単語との関連性の強さを測っている。具体的には、“word NEAR good”, “word NEAR bad” などのクエリを検索エンジンに投げ、そのヒット数から種となる単語との関連性を算出し、関連性の数値の差を感情極性の指標としている。また、潜在意味解析 (Latent Semantic Analysis) を用いた手法も提案している。実験結果は、General Inquirer の語彙 (Stone et al., 1966) で評価している。

Hatzivassiloglou (1997) は、“simple and well-received” あるいは “simplistic but well-received” などといった接続表現に注目して単語の感情極性を判定している。前者は and で接続されており、両単語の極性は等しく、後者では異なると予想される。彼らの手法では、まず接続表現を大量に収集し、それらを同極性が異極性に判定する。その判定結果を用いて単語を 2 つのグループにクラスタリングして、片方をポジティブと判定している。評価は彼らが作成したタグ付データで行われた。

小林ら (2001) は、ブートストラッピングを用いた。彼らは単語の語釈文に対するルールを入手で 52 個作成した。そのルールをブートストラッピング的に繰り返し適用することにより、単語の感情極性を決定していく。彼らはこのタスクに対して詳細な調査をしており、その手法は我々の提案手法のもととなっているが、彼らの手法は再現率の低さと言語依存性という二つの欠点を持つ。実験では 113 単語のみの極性が決定されている (初期単語集合が大きいことも一因となっているので、単純にこの数字では評価できないことに注意しなくてはならない)。また、使用したルールは日本語にのみ適用可能である。

Kamps ら (2004) は、WordNet (Fellbaum, 1998) の同義語を連結することにより語彙ネットワークを構築し、ある単語から初期単語 (“good” と “bad”) へのネットワーク上での最短距離を用いて感情極性を判定した。彼らの手法の欠点は、語釈文よりも入手しにくいシソーラスを必要としていること、評価対象が形容詞のみなのでその応用性が未知なことなどが挙げられる。

その他の研究で関連しているものに、単語の主観性判定がある。主観的な単語はしばしば強い感情極性を持つ。Wiebe (2000) はコーパスから主観的な形容詞を収集する方法を提案している。また、Riloff ら (2003) は、主観的な名詞を収集する方法を提案している。

実験について述べた 5 節で、Turney らの手法及び Kamps らの手法と、我々の提案手法とを比

較する。実験設定の違いがあることや、詳細な設定が明らかにされていない部分があることから、小林らの手法との直接的な比較はできなかった。

3 スピンモデルと平均場近似¹

ここでは、スピンモデルと平均場近似 (Mackay, 2003) を簡単に紹介する。これらは、統計物理や機械学習などの分野で盛んに研究されてきた。

スピン系とは、 N 個の電子の成す系であり、各電子には “+1 (上向き)” もしくは “-1 (下向き)” のどちらかの値をとるスピンの付随している。隣接した電子は、エネルギーの観点から考えると、お互いに同じ向きを取り易いことが知られている。このモデルをスピンモデルと呼ぶことにする²。スピン系のエネルギー関数は次のように表される：

$$E(\mathbf{x}, W) = -\frac{1}{2} \sum_{ij} w_{ij} x_i x_j. \quad (1)$$

ここで、 x_i と x_j はそれぞれ電子 i と j のスピンの方向を表し、行列 $W = \{w_{ij}\}$ は二つの電子の間の重みを表す。

スピン系においては、変数ベクトル \mathbf{x} はボルツマン分布に従う：

$$P(\mathbf{x}|W) = \frac{\exp(-\beta E(\mathbf{x}, W))}{Z(W)}. \quad (2)$$

ここで、 $Z(W) = \sum_{\mathbf{x}} \exp(-\beta E(\mathbf{x}, W))$ は正規化項であり、 $\beta (= 1/T)$ は逆温度定数と呼ばれる定数である。なお、 T は物理の世界では温度に対応する定数である。この分布関数が示すように、エネルギーが小さな状態ほど確率が大きくなる。

確率分布が具体的に与えられているものの、この系の状態は実は依然としてわからない。その理由は、 2^N 個の異なる状態が存在するので、確率値の計算量が非常に大きいからである。それゆえ、スピン系においては、しばしば平均場近似と呼ばれる近似計算が用いられる。以下、スピン系における平均場近似を説明する。 $P(\mathbf{x}|W)$ を $Q(\mathbf{x}; \theta)$ で近似することを考える。 θ は Q を決定するパラメータの集合であり、 $P(\mathbf{x}|W)$ にできるだけ近くなるように決定される。 P と Q の近さの指標としては、変分自由エネルギー F を用いる。 F は、 Q に関する平均エネルギーと Q のエントロピーの差として定義される：

$$F(\theta) = \beta \sum_{\mathbf{x}} Q(\mathbf{x}; \theta) E(\mathbf{x}; W) - \left(- \sum_{\mathbf{x}} Q(\mathbf{x}; \theta) \log Q(\mathbf{x}; \theta) \right). \quad (3)$$

¹数式変形の詳細は付録 A を参照して頂きたい。

²より正確には、イジングスピンモデルなどと呼ばれる。

この F を最小にするパラメータ θ が選ばれる。実は、 F を最小にすることは、 P と Q の間のカルバック・ライブラー情報量を最小にすることと等価であることが知られている (Mackay, 2003)。

平均場近似では、 $Q(\mathbf{x}; \theta)$ の形を、次のような計算量的に扱いやすいものに制限する：

$$Q(\mathbf{x}; \theta) = \prod_i Q(x_i; \theta_i). \quad (4)$$

簡単な代入と変形により、式 (3) の変分自由エネルギーは次のように表される：

$$F(\theta) = -\frac{\beta}{2} \sum_{ij} w_{ij} \bar{x}_i \bar{x}_j - \sum_i \left(-\sum_{x_i} Q(x_i; \theta_i) \log Q(x_i; \theta_i) \right). \quad (5)$$

ここで、 \bar{x}_i, \bar{x}_j はそれぞれ単語 i, j のスピン方向の平均である。

微分して 0 になるという静止条件より、次のような平均場方程式が得られる：

$$\bar{x}_i = \frac{\sum_{x_i} x_i \exp\left(\beta x_i \sum_j w_{ij} \bar{x}_j\right)}{\sum_{x_i} \exp\left(\beta x_i \sum_j w_{ij} \bar{x}_j\right)}. \quad (6)$$

この方程式は次のような繰り返し更新計算により解くことができる：

$$\bar{x}_i^{new} = \frac{\sum_{x_i} x_i \exp\left(\beta x_i \sum_j w_{ij} \bar{x}_j^{old}\right)}{\sum_{x_i} \exp\left(\beta x_i \sum_j w_{ij} \bar{x}_j^{old}\right)}. \quad (7)$$

4 スピンモデルによる感情極性の判定

ここで、単語の感情極性判定にスピンモデルを用いるという我々の提案手法の説明をする。

各電子のスピンは、上向きと下向きのうちどちらかの値をとり、隣り合ったスピンは同じ値を取りやすい。我々は、各単語を電子とみなし、単語の感情極性をスピンの向きとみなす。もしある単語が別の単語の語釈文に出現した場合にその二単語を連結することにより、語彙ネットワークを構築する。このようなモデル化の背後には、ある単語とその語釈文に出現する単語は同じ感情極性を持ちやすいであろうという直観が存在する。

以下、どのように語彙ネットワークを構築し、近似確率を計算し、感情極性を判定するかを説明していく。

4.1 語彙ネットワークの構築

ある単語とその単語の語釈文内の各単語を連結することにより語彙ネットワークを構築する。各リ

ンクは、 SL (同極性リンク集合)、 DL (逆極性リンク集合) という二つのグループに分けられる。これらはもちろん、必ず同極性、あるいは必ず逆極性という意味ではなく、そうなりやすいと予測されるという意味である。もし、少なくとも片方の単語がもう片方の単語の語釈文で否定語 (英語ならば not など) の後に出現しているならば、両単語をつなぐリンクは DL に分類される。そうでなければ SL に分類される。

次にリンクに対する重み $W = (w_{ij})$ を次のように決める：

$$w_{ij} = \begin{cases} \frac{1}{\sqrt{d(i)d(j)}} & (l_{ij} \in SL) \\ -\frac{1}{\sqrt{d(i)d(j)}} & (l_{ij} \in DL) \\ 0 & otherwise \end{cases}. \quad (8)$$

ここで、 l_{ij} は単語 i と j の間のリンクを表し、 $d(i)$ は単語 i の次数、すなわち単語 i が連結している単語数を表す。連結されていない単語同士は、重み 0 のリンクで連結されているとみなすことができる。このネットワークを *gloss network* (G) と呼ぶことにする。

我々は、ネットワーク G に加えて、シソーラスで与えられた同義語、反義語、上位語をリンクで連結することにより別のネットワーク *gloss-synonymy network* (GS) を構築する。反義語のリンクは DL に属するとする。それ以外のリンクは SL に属するとする。

さらにコーパスから得られた情報を加える。2 節で述べたように、Hatzivassiloglou (1997) はコーパスに出現する接続表現を利用した。同様に我々も二つの単語が and による接続表現で出現したらそのリンクを SL として、また、but による接続表現で出現したら DL として加える。このようにしてできたネットワークを *gloss-synonymy-corpus network* (GSC) と呼ぶことにする。

上記のシソーラスによる語彙ネットワーク拡張はリンク数を増加させるので、正解率の向上が期待される。またコーパスによる拡張は、リンク数を増加させるだけでなく、将来的に未知語 (辞書に載っていない語) に対する本手法の適用も可能にする³。

4.2 感情極性判定

小規模な初期単語集合が与えられているとする。この少量のラベル付きデータを以下のようにスピン系に取り入れる。

式 (2) において、 $\beta E(\mathbf{x}, W)$ の代わりに次の関数 $H(\beta, \mathbf{x}, W)$ を用いる：

³本稿では未知語に対する評価は行っていない。

$$H(\beta, \mathbf{x}, W) = -\frac{\beta}{2} \sum_{ij} w_{ij} x_i x_j + \alpha \sum_{i \in L} (x_i - a_i)^2, \quad (9)$$

ここで、 L は初期単語集合、 a_i は初期単語 i の感情極性（1 または -1 ）、 α はラベル付きデータに対する重み（正の定数）を表す。つまり、 x_i ($i \in L$) が a_i と異なる場合、ペナルティが与えられる。

この関数 H を用いると、次の更新式が得られる：

$$\bar{x}_i^{new} = \frac{\sum_{x_i} x_i \exp(\beta x_i s_i^{old} - \alpha (x_i - a_i)^2)}{\sum_{x_i} \exp(\beta x_i s_i^{old} - \alpha (x_i - a_i)^2)}. \quad (10)$$

ここで、 $s_i^{old} = \sum_j w_{ij} \bar{x}_j^{old}$ である。また、 \bar{x}_i^{old} と \bar{x}_i^{new} は、それぞれ更新前と後の x_i の平均である。ここでの新しい更新式は、Inoue (2001) の画像修復方法に従っている。

初期値としては、初期単語の \bar{x}_i については、そのラベルに従う。それ以外は 0 と設定しておく。

更新の前後で変分自由エネルギーの変化が十分に小さくなったら、収束したものとみなして計算を終了する。最終的に平均値が正だった単語については、感情極性がポジティブと判定する。逆に負だった単語は、感情極性がネガティブであると判定する。

4.3 ハイパーパラメータの推定

提案手法の性能は、ハイパーパラメータ β の値に大きく依存する。本手法を実際に使用可能なものにするためには、 β の値を適切に決定しなくてはならない。ここでは、そのための基準として平均磁化 m を用いることを提案する：

$$m = \frac{1}{N} \sum_i \bar{x}_i. \quad (11)$$

高温度においては、スピンの方向には秩序がない（常磁性相、 $m \approx 0$ ）。低温度においては、スピン系は秩序を持っており同方向を向こうとする（強磁性相、 $m \neq 0$ ）。統計物理学の世界では、ある温度において突然、常磁性相と強磁性相が入れ替わることが知られている。これを相転位といい、その時の温度を臨界点という。臨界点より僅かに高温であるとき、スピン系は局所的に秩序を持つが、全体的には秩序的でない状態になる。

語彙ネットワークにおいては、good の周辺の単語の多くはポジティブであり、bad の周辺の単語の多くはネガティブであると考えられる。よって、我々が望む語彙ネットワークの状態は、局所的に秩序立っていると予想される。それゆえ、我々は臨界点より僅かに高い値を用いる。具体的には、

一定間隔で β を大きくしていき、 m がある閾値より大きくなる直前の β を最良の値であると予測する。

5 実験

提案手法の性能を、実験により示す。

英語の語彙ネットワークの構築には、WordNet (Fellbaum, 1998) の語釈文、同義語、反義語、上位語を用いた。語釈文に対する品詞タグ付けと原形化には、TreeTagger (Schmid, 1994) を用いた。動詞、名詞、形容詞、副詞などの内容語のみを用い、さらに“be”や“have”などのストップワードは削除した。否定語としては、“not”や“never”などだけでなく、“free from”や“lack of”などの表現も加え、すべて合わせると 33 個になった。また、コーパスからの接続表現としては、Wall Street Journal と Brown corpus から 804 個の表現を抽出した。孤立した単語を削除すると、約 88,000 単語から成るネットワークが得られた。平均次数は GSC では 17.94、GS では 17.93 G では 12.73 となった。

Turney らによる実験 (2003) に従い、General Inquirer (Stone et al., 1966) の語彙を正解データとして使用した。“Positiv”もしくは“Negativ”のラベルがついている単語を General Inquirer の単語リストから抽出し、多義性により複数のエントリがある単語は、一つにまとめた⁴。その結果、1616 のポジティブな語、1980 のネガティブな語からなる 3596 語のラベル付き単語集合が得られた。

実験は、0.1 間隔で 0.1 から 2.0 までの異なる β の値を用いて行い、4.3 節で述べた方法を用いて最も良い β の値を予測した。 α は、充分大きな値 (1.0×10^3) に固定した。

初期単語集合としては Turney らが使用したのと同じものを用いる：ポジティブ初期単語集合 = {good, nice, excellent, positive, fortunate, correct, superior}、ネガティブ初期単語集合 = {bad, nasty, poor, negative, unfortunate, wrong, inferior}。評価の段階では、初期単語は取り除いた。

岩波国語辞典 (西尾ら, 1994) を用いて、日本語の語彙に対する実験も行った。形態素解析には ChaSen (松本ら, 2000) を用いた。英語の場合と同様に内容語のみを用いた。また、ここでの否定語は「ない」と「ぬ」である。日本語に対しては、ネットワーク G (約 58,000 単語) のみを試した。

正解として人手で 5632 語にタグ付けした。このうち、2491 語がポジティブであり、3141 語が

⁴一つの単語に異なる極性が与えられている場合は、正解データに含めなかった。

ネガティブである。日本語の初期単語集合は「良い」と「悪い」の二語のみとして試してみた。

5.1 実験結果

まず、英語の実験結果について述べたあと、日本語の実験結果について簡単に付け加える。結果は予測された β を用いた場合のものである。

表 1 は、三種類の初期単語集合に対する、それぞれのネットワークによる単語の感情極性分類の実験結果を示す。2 個の初期単語は “good” と “bad” に対応し、4 個の初期単語は “good”, “bad”, “superior”, そして “inferior” に対応する。

表 1: 予測された β を用いた場合の分類正解率 (%). 括弧内にはそのときの β の値が付与されている。

# seeds	GSC	GS	G
14	81.9 (1.0)	80.2 (1.0)	76.2 (1.0)
4	73.8 (0.9)	73.7 (1.0)	65.2 (0.9)
2	74.6 (1.0)	61.8 (1.0)	65.7 (1.0)

多くの場合、シソーラス及びコーパスの情報を取り入れることで正解率が上昇していることがわかる。例外は、サイズ 2 の初期単語集合において GS が G を下回っているケースである。この理由は調査中であるが、初期単語が少数である場合は解空間の自由度が大きく、最適化の過程で計算が期待される解と異なる局所解に陥りやすくなっている可能性がある。

提案手法の結果を Turney らの結果と比較してみる。サイズ 14 の初期単語で彼らは、小さなコーパス (約 1×10^7 単語) を用いて 61.26%, 中程度のサイズのコーパス (約 2×10^9 単語) を用いて 76.06%, 大きなコーパス (約 1×10^{11} 単語) を用いて 82.84% の正解率を得ている。ただし、サイズの大小は相対的なものである。我々は、コーパスもシソーラスも使用することなく、中程度のサイズのコーパスでの Turney らの結果と同等の結果を得た。さらに、コーパスやシソーラスで語彙ネットワークを拡充した場合、我々は大きなコーパスでの Turney らの結果と同等な結果を得た。

GSC で 14 初期単語の場合について、品詞ごとの正解率を調べてみると、動詞は 77.8%, 名詞は 81.2%, 形容詞は 85.4%, 副詞は 83.3% であった。品詞に関係なく高い正解率が出ていることがわかるが、その中では動詞の正解率が最も低い。動詞はその主体の視点をとるか客体の視点をとるかに依存して感情極性が全く逆になるため、その判定が難しいことが原因であると予想される。

提案手法が言語依存でないことを示すために、同様の条件で日本語での補足実験も行った。その結果、79.8% の正解率を得ることに成功した。




図 1: β と平均磁化および分類正解率 (%) の関係 (GSC, 14 初期単語の場合)。

5.2 ハイパーパラメータ β の予測

ハイパーパラメータの予測手法の性能を調べるために、表 1 と表 2 を比較する。表 2 では最適な値を用いた結果が示されている。特に 14 初期単語

表 2: 最も良い β を用いた場合の分類正解率 (%). 括弧内にはそのときの β の値が付与されている。

# seeds	GSC	GS	G
14	81.9 (1.0)	80.2 (1.0)	76.2 (1.0)
4	74.4 (0.6)	74.4 (0.6)	65.3 (0.8)
2	75.2 (0.8)	61.9 (0.8)	67.5 (0.5)

の場合において、我々の予測手法は良い性能を示している。その他の場合も、いくらか大きな値を予測する傾向があるものの、正解率としては遜色ない値が出ているといえる。

β の値を変化させたときの、平均磁化と正解率の変化を表した図 1 も、参考のために付け加える。今回の場合、 $\beta = 1.0$ 付近で相転位が起こっており、その直前に正解率がピークを迎えている。我々の提案した β の予想方法が期待通りに機能していることがわかる。

5.3 確信度が高い分類結果に対する精度

次に、高い確信度をもって分類された単語に対する分類精度を算出する。確信度としては、スピンの平均値の絶対値 $|\bar{x}|$ を用いた。この絶対値の降順に単語を並べ、上位の単語のみで分類精度を測った。

結果を図 2 に示す。横軸は選ばれた上位単語数、縦軸は分類精度である。上位 1000 語で 92% を越える精度が得られた。平均値の絶対値が分類の確信度として機能することも確認できた。




図 2: 14 初期単語のときの分類精度 (%)。

Kamps ら (2004) は、彼らの手法で “good” と “bad” を初期単語として用い、667 語の形容詞について 67.32% という精度を報告している。比較のために我々も上記確信度を用いて (Kamps らの 667 語と異なる) 667 語の形容詞を選び、精度を測った (表 3)。提案手法が Kamps らの手法を上回っていることが示されている。

表 3: 上位 667 語の形容詞に対する分類精度 (%)。

# seeds	GSC	GS	G
2	94.5 (1.0)	76.3 (1.0)	86.7 (1.0)

5.4 エラー解析

提案手法を用いた場合の分類誤りを調査し、主に三種類の原因があることがわかった。

一つは語義の曖昧性の問題である。例えば、“costly” の語釈文は “entailing great loss or sacrifice” である。しかし、ここでの “great” は程度が大きいことを示しているにも関わらず、ポジティブな極性を持つ「偉大」という意味の用法の影響を受けて、結果として “costly” が誤ってポジティブに分類されている。

また、構文構造が取り入れられていないことによる分類誤りも存在する。例えば、“arrogance” の語釈文は “overbearing pride evidenced by a superior manner toward the weak” であり、正しくはネガティブな単語であるが、“superior” という単語の影響でポジティブに分類されてしまっている。“superior” であるのは “manner” であることが構文構造から推測できるようになると、このような分類誤りは避けることができる。

さらに別のタイプの誤りとしては、熟語的表現がある。例えば、“brag” は、“show off” の意味でネガティブなのだが、“show” と “off” のどちらもネガティブな意味を持っていないので、正しく分類ができていなかった。

現在のモデルにおいては、これらの分類誤りをうまく扱うことはできない。このような問題の解決は、今後の課題として取り組んでいく。

5.5 他のタスクへの応用

本稿においてこれまで “感情極性” と呼んでいたものは、Osgood (1957) の三因子のうちの evaluation 因子に対応する。残りの二つは potency 因子と activity 因子であり、これら三因子は対象に対する印象を表すうえで非常に重要な役割を果たしているとされている。Potency 因子とは、「強さ」のような概念を表す軸であり、その極は strong と weak である。また、activity 因子は、「能動性」といった概念を表す軸であり、その極は active と passive である。

ここでは、我々の提案手法が残り二つの因子についても応用可能であることを実験的に示す。General Inquirer から “Strng” もしくは “Weak” とラベル付けされた単語を抽出し、前と同様の前処理を施すことにより 2434 単語から成る potency 因子のラベル付き単語集合 (1738 単語が “Strng”, 696 単語が “Weak”) を作成した。同様に、“Actv” もしくは “Psv” とラベル付けされた単語を抽出し、2610 単語から成る activity 因子のラベル付き単語集合 (1807 単語が “Actv”, 803 単語が “Psv”) を作成した。

初期単語集合は、ラベル付き単語集合から次数が高い 100 語及び 50 語をそれぞれ選んだ。

結果は、表 4 と表 5 に示す。多い方のラベルを常に選んだ場合をベースラインとすると、どの条件においてもベースラインを上回っている。

シソーラスによりネットワークを拡充した効果については、感情極性 (evaluation 因子) の場合ほど明確ではないが、結果に現れている。しかし、コーパスによる正解率上昇はほとんど見られない。少なくとも現在のコーパスの大きさでは、potency 因子や activity 因子に関する分類に、接続表現は有用でないことを示している。今後、より大きなコーパスを試すとともに、それぞれのタスクに応じた言語表現を発見する必要がある。

表 4: 推測された β を用いた場合の potency 因子の分類正解率 (%)。

# seeds	GSC	GS	G
100	75.9 (.04)	75.8 (.04)	73.2 (.07)
50	73.5 (0.2)	73.5 (0.2)	71.1 (0.3)

表 5: 推測された β を用いた場合の activity 因子の分類正解率 (%).

# seeds	GSC	GS	G
100	71.8 (.04)	71.8 (.04)	71.5 (.05)
50	69.9 (0.1)	69.9 (0.2)	69.0 (0.2)

6 結論と今後の課題

単語の感情極性を判定する手法を提案した。提案手法では、感情極性を電子のスピンとみなし、語釈文を用いて語彙ネットワークを構築した。さらに平均場近似を用いて近似確率分布関数を計算し、各単語の極性を調べた。実験により、提案手法は少数の初期単語を用いて高い精度で感情極性分類を判定できることが示した。また、提案手法が言語に依存しない一般的な手法であることや、他のタスクへも応用可能であることも示した。

今後の課題としては以下のものが考えられる：

- 語釈文内の各単語の重要性は、その出現位置や文法的機能にも依存すると思われる。構文構造を通じてこのような重要性の違いを取り入れる。
- ポジティブでもネガティブでもない単語が存在することを考えると、多値のスピン系の方がより現実の語彙ネットワークに近い可能性がある。そのような異なるモデルでの性能を確かめる。
- 人手での初期単語集合作成のコストを減らすために、能動学習を導入する。
- 今回使用したコーパスは、それほど大きくはない。さらに大きなコーパスを用いることにより、性能が改善する可能性がある。また、Turney らの手法との融合は興味深い。
- 提案手法は、コーパスに現れた接続表現を用いることにより、辞書に載っていない新しい単語の感情極性も判定可能なので、それを実験的に確かめる。
- ここでは Osgood (1957) の三因子について実験をしたが、それ以外にもスピン系に類似した構造を背後に持つ概念は多く存在する。そのような応用可能性を探る。

References

Christiane Fellbaum. 1998. *WordNet: An Electronic Lexical Database, Language, Speech, and Communication Series*. MIT Press.

Vasileios Hatzivassiloglou and Kathleen R. McKeown. 1997. Predicting the semantic orientation of adjectives. *Proceedings of the 35th Annual Meeting of the Association for Computational Linguistics*, pp. 174–181.

Jun ichi Inoue and Domenico M. Carlucci. 2001. Image restoration using the q-ising spin glass. *Physical Review E*, 64:036121–1 – 036121–18.

Jaap Kamps, Maarten Marx, Robert J. Mokken, and Maarten de Rijke. 2004. Using wordnet to measure semantic orientation of adjectives. *Proceedings of the 4th International Conference on Language Resources and Evaluation (LREC 2004), volume IV*, pp. 1115–1118.

David J. C. Mackay. 2003. *Information Theory, Inference and Learning Algorithms*. Cambridge University Press.

Charles Osgood, George Suci, and Percy Tannenbaum. 1957. *The Measurement of Meaning*. University of Illinois Press.

Ellen Riloff, Janyce Wiebe, and Theresa Wilson. 2003. Learning subjective nouns using extraction pattern bootstrapping. *Proceedings of the Seventh Conference on Natural Language Learning (CoNLL-03)*, pp. 25–32.

Helmut Schmid. 1994. Probabilistic part-of-speech tagging using decision trees. *Proceedings of International Conference on New Methods in Language Processing*, pp. 44–49.

Philip J. Stone, Dexter C. Dunphy, Marshall S. Smith, and Daniel M. Ogilvie. 1966. *The General Inquirer: A Computer Approach to Content Analysis*. The MIT Press.

Peter D. Turney and Michael L. Littman. 2003. Measuring praise and criticism: Inference of semantic orientation from association. *ACM Transactions on Information Systems*, 21(4):315–346.

Janyce M. Wiebe. 2000. Learning subjective adjectives from corpora. *Proceedings of the 17th National Conference on Artificial Intelligence (AAAI-2000)*, pp. 735–740.

小林のぞみ, 乾孝司, 乾健太郎. 2001. 語釈文を利用した「p/n 辞書」の作成. 人工知能学会言語・音声理解と対話研究会 SLUD-33, pages pp.45–50.

松本裕治, 北内啓, 山下達雄, 平野善隆, 松田寛, 高岡一馬, 浅原 正幸, 2000. 日本語形態素解析システム『茶釜』version 2.2.1 使用説明書.

西尾実, 岩淵悦太郎, 水谷 静夫. 1994. 岩波国語辞典. 岩波書店.

A 平均場方程式の導出

$Q(\mathbf{x})$ について、式 (4) の形を仮定すると以下のようになる :

$$\sum_{\mathbf{x}} Q(\mathbf{x}; \theta) E(\mathbf{x}; W) = \sum_{\mathbf{x}} Q(\mathbf{x}; \theta) \left(-\frac{1}{2} \sum_{ij} w_{ij} x_i x_j \right) \quad (12)$$

$$= -\frac{1}{2} \sum_{ij} w_{ij} \left(\sum_{x_i} x_i Q(x_i; \theta_i) \right) \left(\sum_{x_j} x_j Q(x_j; \theta_j) \right). \quad (13)$$

$$-\sum_{\mathbf{x}} Q(\mathbf{x}; \theta) \log Q(\mathbf{x}; \theta) = \sum_i \left(-\sum_{x_i} Q(x_i; \theta_i) \log Q(x_i; \theta_i) \right) \quad (14)$$

$$F(\theta) = -\frac{\beta}{2} \sum_{ij} w_{ij} \left(\sum_{x_i} x_i Q(x_i; \theta_i) \right) \left(\sum_{x_j} x_j Q(x_j; \theta_j) \right) - \sum_i \left(-\sum_{x_i} Q(x_i; \theta_i) \log Q(x_i; \theta_i) \right) \quad (15)$$

$\forall i, \sum_{x_i} Q(x_i; \theta_i) = 1$ なる条件の下で、変分自由エネルギーを最小化する $Q(\mathbf{x}; \theta)$ を求めたい。ラグランジュ関数 F' は次のように表される :

$$F'(\theta) = F(\theta) + \sum_i \lambda_i \left(\sum_{x_i} Q(x_i; \theta_i) - 1 \right). \quad (16)$$

$$\frac{\partial F'(\theta)}{\partial Q(x_i; \theta_i)} = -\beta \sum_j w_{ij} x_i \left(\sum_{x_j} x_j Q(x_j; \theta_j) \right) + \frac{Q(x_i; \theta_i)}{Q(x_i; \theta_i)} + \log Q(x_i; \theta_i) + \lambda_i \quad (17)$$

式 (17) を 0 と置くことにより、次を得る :

$$\begin{aligned} \log Q(x_i; \theta_i) &= -\lambda - 1 + \beta \sum_j w_{ij} x_i \left(\sum_{x_j} x_j Q(x_j; \theta_j) \right) \\ Q(x_i; \theta_i) &= \frac{\exp\left(\beta \sum_j w_{ij} x_i \left(\sum_{x_j} x_j Q(x_j; \theta_j) \right)\right)}{Z_i} \\ &= \frac{\exp\left(\beta x_i \sum_j w_{ij} \bar{x}_j\right)}{Z_i}. \end{aligned} \quad (18)$$

ここで

$$Z_i = \sum_{x_i} \exp\left(\beta x_i \sum_j w_{ij} \bar{x}_j\right). \quad (19)$$

このようにして、平均場方程式を得る :

$$\begin{aligned} \bar{x}_i &= \sum_{x_i} x_i Q(x_i; \theta_i) \\ &= \frac{\sum_{x_i} x_i \exp\left(\beta x_i \sum_j w_{ij} \bar{x}_j\right)}{\sum_{x_i} \exp\left(\beta x_i \sum_j w_{ij} \bar{x}_j\right)}. \end{aligned} \quad (20)$$