

自己組織化マップ SOM による心情を表すオノマトペ分類の再検討

黒澤 義明

目良 和也

竹澤 寿幸

広島市立大学 情報科学研究科

[kurosawa, mera, takezawa]@ls.info.hiroshima-cu.ac.jp

1. はじめに

オノマトペとは擬音語・擬態語の総称であり、物事を的確に表現することを可能とする言語表現である。しかし、オノマトペは感覚的表現であるため、語義が曖昧であり、コンピュータに的確な意味を理解させることは困難である。

加えて、オノマトペは種類や表現が非常に多い。見出し語として収録されている語だけでも約 4500 語とも言われ(小野 2007)、さらに、新語が絶えず作られるため、辞書に載っていない語も多いと考えられる。こうした点も機械処理を難しくしている。

このような理解困難さを解消し、新語への対応を容易にするため、我々は自己組織化マップを用いた、オノマトペの自動分類・視覚化システムを提案した(中村ら 2009)。しかしながら、浅賀ら(浅賀ら 2007)が行った k-means 法による分類等、他の手法との比較を中心に議論を行ったため、視覚化に必要なベクトル要素について検討が不十分であった。そこで、本研究では詳細な検討を行う。

2. 自己組織化マップによるオノマトペの可視化

本研究では、自己組織化マップ(Self-Organizing Map, SOM)を採用する(Kohonen 2001)。

SOM は、多次元ベクトルにより表されたデータを、その特徴を残し、他のデータとの相互関係を保ったまま、2次元マップに写像することが出来る。すなわち、多次元のデータの関係を2次元平面上の距離として表し、視覚的に理解し易いという特徴を持つ。

2.1. 自己組織化マップのアルゴリズム

SOM は二層からなる神経回路網モデルであり、教師なし学習～入力層への入力により、競合層の特定の領域が反応するような～を行う。入力層への入力ベクトル x は n 次元のベクトルであり、 $x = \{x_1, x_2, \dots, x_n\}$ と表現する。また、競合層にはノ

ードと呼ばれるユニットがあり、全ノードから、入力層との間に参照ベクトルと呼ばれるリンクが行われる。ここで、次式を満たす勝者ノード c の発見を試みる。次式は入力ベクトルに最も類似した参照ベクトルを持つノードを見つける操作と考えられる。

$$\forall i, \|x - m_c\| \leq \|x - m_i\|$$

上記の勝者ノードの発見に続いて、参照ベクトルを入力ベクトルに近づける操作を行う。つまり、時間が経つにつれ、近隣のノードの類似性が増す。以下に、時間軸 t を用いて表現した式を示す。

$\forall i \in N_c(t)$ を満たすとき、

$$m_i(t+1) = m_i(t) + h_{ci}(t)(x(t) - m_i(t))$$

それ以外するとき、 $m_i(t+1) = m_i(t)$

なお、 $h_{ci}(t)$ は作用範囲を示す近傍と呼ばれる領域であり、本研究では単調減少関数を用いた。

ここで紹介した SOM は自然言語処理に適用され、オノマトペ以外の分類についても、有効性が確認されている(cf. 黒澤ら 2008; 神崎ら 2007; 金 2003; 馬ら 2001)。

3. 実験と考察

3.1. 実験の流れ

基本的な手続きは、中村ら(中村ら 2009)と同じであるため、簡潔に記すこととする。

本研究では SOM による分類を行うための用例として Web 日本語 N グラム(工藤ら 2007)を使用する。まず、オノマトペ、及びその後方一語に出現する動詞を取得する。学習のための動詞種が多くなることを防ぐため、動詞項構造シソーラス(竹内 2008)を用いて動詞を概念ごとに分類し、概念ごとに出現頻度を求める。そして、以下の手続きにより、動詞フレーム v_i の出現回数を出現率にデータ変換した上で自己組織化を行う。

$$v_i \text{ の出現率} = v_i / \sum_{i=1}^n v_i$$

3.2. 実験手続き

2章で説明した手続きにより, som_pak を使用した分類を行った. オノマトペ 119 語, フレーム数 165 であった. なお, 学習は2段階で行った. 使用したパラメータを以下に示す. このパラメータは予備実験により決定した. 結果を図 1 に示す.

マップサイズ: 64×48

1st: 学習回数 100,000, 初期学習率係数 0.05

2nd: 学習回数 1,000,000, 初期学習率係数 0.01

3.3. 実験結果

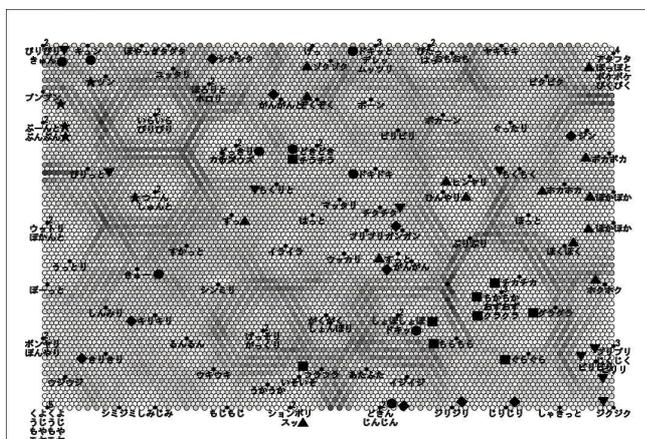


図 1 SOM による分類結果

黒っぽい点 (ノード) によって囲まれた領域がグループを示す. ここで, さらに考察を行うため, 以下に示す Akita の意味記述(Akita 2006)に基づいた手作業によるオノマトペ分類 (表 1) との比較を行う. Akita の記述はシンプルであるため, 単語に着目することで, 分類が容易となり, また主観性が入りづらいという利点がある.

dokidoki 'feeling one's heart *throbbing*,'

hinyari 'feeling pleasantly *cool*,'

4. 考察

4.1. 精度と再現率

表 1 のそれぞれのグループに対し, 3 フレームを選び, RGB により表現する (方法は後述). 選択された例 (温度) を示す. なお, 30 以上のオノマトペ, 及び 2 個以下のオノマトペと共起するフレームは分析から省いた. ただ 1 個と共起するフレームを使って精度 100% と言っても意味がないからである.

表 1 考察用対象語の正解分類

特徴	記号	個数	着目した単語
目眩	■	9	eye, dizzy
鼓動	●	9	throb, heart, jump
痛み	◆	9	sore, pain, ...
臭い	★	5	smell
温度	▲	14	cool, cold, hot, warm, ...
刺激	▼	9	pungent, skin
他		64	

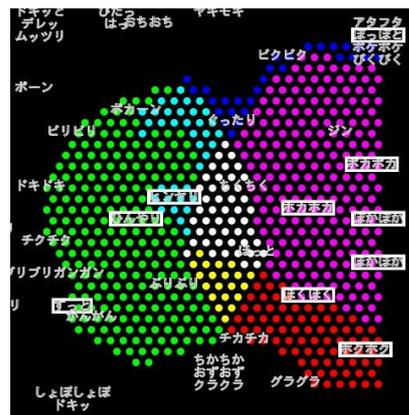


図 2 3 フレーム選択表現

ここで, 長方形で囲まれたオノマトペが当該グループに属する, 正しいオノマトペである. フレーム選択表現により領域が明確となり, さらに色の重ねあわせが生じているため, 赤 (「ほくほく」) とピンク (「ぼかぼか」) とに意味の違いがあることがわかる.

上記の領域を用いて, 次式に基づき精度・再現率を求めた. 次式中, 「適切」とは適切に分類されたオノマトペを, 「領域」とは 3 フレームにより選択された領域内のオノマトペを, 「グループ」とは, 表 1 のグループを示す.

$$\text{精度} = N_{\text{適切}} / N_{\text{領域}}$$

$$\text{再現率} = N_{\text{適切}} / N_{\text{グループ}}$$

なお, フレームの選び方はさまざまに考えられる. 今回は, F 値及び精度が最大になるように 3 個のフレームを選ぶこととする. 結果を表 2 に示す.

全体として, 精度が低く, 再現率が高くなっている. 精度を最大にするようにした場合でも, 精度は 57.1% に過ぎない (刺激). 一方で, 再現率は 7 割程度を示しており, 抽出漏れが少ないと考えられる.

表 2 F 及び精度最大時の精度と再現率

項目	最大化	オノマトペグループ					
		目眩	鼓動	痛み	臭い	温度	刺激
精度 (%)	F	46.2	22.2	33.3	25.0	45.8	45.5
		6/13	6/27	7/21	4/16	11/24	5/11
	精度	46.2	22.7	40.0	25.0	50.0	57.1
		6/13	5/22	4/10	4/16	9/18	4/7
再現率 (%)	F	66.7	66.7	77.8	80.0	78.6	55.6
		6/9	6/9	7/9	4/5	11/14	5/9
	精度	66.7	55.6	44.4	80.0	64.3	44.4
		6/9	5/9	4/9	4/5	9/14	4/9

4.2. 表現フレーム数の検討

次に本提案手法における必要フレーム数の検討を行う。

4.1 に示したように、3 フレームを用いて RGB 表現を行うことにより、視覚的に理解しやすくなると考えられる。しかし、3 フレームが必要十分かどうかについては検討が必要である。そこで、表現フレーム数を 1, 3, 5 と変更することで、再度、精度等の計算を行った。結果を表 3 に示す。なお、ここでの計算は、精度が最大になるような計算を行っている。

表 3 表現フレーム数変更時の精度と再現率

項目	フレーム数	オノマトペグループ					
		目眩	鼓動	痛み	臭い	温度	刺激
精度 (%)	1	21.1	20.0	50.0	28.6	50.0	36.4
		4/19	3/15	4/8	4/14	7/14	4/11
	3	46.2	22.7	40.0	25.0	50.0	57.1
		6/13	5/22	4/10	4/16	9/18	4/7
	5	46.2	22.7	40.0	23.5	50.0	57.1
		6/13	5/22	4/10	4/17	9/18	4/7
再現率 (%)	1	44.4	33.3	44.4	80.0	50.0	44.4
		6/9	3/9	4/9	4/5	7/14	4/9
	3	66.7	55.6	44.4	80.0	64.3	44.4
		6/9	5/9	4/9	4/5	9/14	4/9
	5	66.7	55.6	44.4	80.0	64.3	44.4
		6/9	5/9	4/9	4/5	9/14	4/9

フレームが 1 個の場合と 3 個の場合を比べてみると、再現率では 3 グループ (目眩, 鼓動, 温度) の結果がわずかによくなっていることがわかる。

一方、精度ではよくなっているグループ (目眩, 鼓動, 刺激) もあり、わずかながら悪くなっているグループ (痛み, 臭い) もある。このため、精度を比べるだけでは、本研究が提案する 3 フレーム必要という根拠とはならない。しかしながら注目したい

のは、目眩グループと刺激グループに見られる分母の数の減少である (目眩: 19→13, 刺激: 11→7)。あるフレームでの表現に別のフレームが加わると、領域が拡大するため、分母の数 (領域内のオノマトペの数) は増えるはずである。しかし、減少しているということは、フレーム 1 個のときと 3 個のときでは表現に必要なフレームそのものが交代し、別のフレームが選ばれたことを意味している。つまり、フレーム 1 個で表現した結果は、最適ではない、局所的な正解に過ぎない可能性があるわけである。この点、3 個のフレームで表現したほうがよいと考えられる。

次に、フレームが 3 個の場合と 5 個の場合を比べてみると、再現率ではまったく同じ値であり、違いは存在しない。その一方精度では、1 個のグループ (臭い) を除けば同一の結果であり、両者に違いは少ないと考えられる。この意味では、フレームが 3 個であっても 5 個であってもどちらでもかまわない。しかし、多くのフレームから 5 個を選び出す組み合わせは膨大であるので、計算量を考えると 3 個のフレームを用いるほうがよいと考えられる。

以上の点から、本研究が提案する 3 個のフレームを用いた表現は、分類結果を視覚的にわかりやすく表しているだけでなく、SOM による学習結果にうまく適合していると言える。

4.3. 領域の絞込み

図 2 で定義した領域は周辺部に多くの (不正解の) オノマトペを含んでおり、領域選択としては広すぎると言えよう。特に本研究においては、形態素解析誤り等もそのまま含まれており、こうした誤ったオノマトペが周辺領域に配置されている可能性がある。

そこで、この周辺領域を選択領域から除くために、各グループ中のノードが持つピークレベルを基準とし、その値の半分 (閾値 50%) 以下を 0 とするような変換処理を行った。得られた結果の例を図に示す (図 3)。

図から明らかなように、周辺部分が選択領域から除かれた。これにより、一部のオノマトペを除いて、正しいグループ化が行われるようになったと考えられる。

