

自己組織型神経回路網モデルを用いた日本語意味マップの構築

馬 青 神崎 享子 村田 真樹 内元 清貴 井佐原 均

郵政省通信総合研究所

{qma, kanzaki, murata, uchimoto, isahara}@crl.go.jp

1 はじめに

単語間の意味的な類似性を自動的に判断する技術は、用例に基づく機械翻訳、文書分類、情報検索といった多くの自然言語処理のタスクだけでなく、言語学の分野にも応用できる。これまでコーパスに基づく単語のクラスタリングの手法が多数提案されてきた（英語においては、例えば、Hindle, 1990 と Brown et al., 1992；日本語においては、例えば、森ら, 1997）。しかしながら、単語のクラスタリングは基本的には単語をいくつかのグループに分類する技術である。このような手法では、グループ間の意味的な関係、または単語間の意味的距離を直観的に知ることが困難である。もっとも、単語を単純に特定のグループに分類すること自体でさえ困難な問題であるかもしれない。なぜならば、単語が意味的にいくつかのグループにまたがる可能性も十分ありうるからである。これらの問題を解決するためには、クラスタリングの代わりに単語を、意味的類似性を距離とする連続した意味空間¹⁾にマッピングする技術が必要である。このような意味空間を意味マップと呼ぶ。可視性を考えると2次元のものが望ましい。

これまで英語においてこのようなマップを自己組織化によって自動構築する研究がいくつかなされてきた[（Kohonen, 1997）を参照]。しかし、これらの研究においては、自己組織化に用いるデータを単に目標単語と前後の2単語で構成される三つ組で構成され、言語構造を全く考慮してこなかった。また、日本語においては、英語と違う言語構造を考慮に入れて意味マップを構築しなければならないにもかかわらず、このような研究は系統的に行われていない²⁾。

本研究の目的は共起する連体修飾要素の観点から名詞の意味マップを自己組織型神経回路網モデルを用いて自動構築することである。名詞の意味マップは一般的な意味マップの一部をなすだけでなく、日本語の語用論の研究に重要とされる名詞と修飾語の関係の分析にも役立つ。まだ、小規模ではあるが、計算機実験の結果、2年分の

¹⁾つまり、意味的に近い単語同士は近いところに、意味的に遠い単語同士は離れたところに配置されるような空間である。

²⁾日本語への自己組織化技術を利用したものとしては例えば清田らの電子ニュース記事の分類に関する研究（清田ら, 1998）があるが、意味マップの研究ではない。

毎日新聞から得られた特定種類の名詞句（計4,800個）を自己組織化に用いることによって我々の直観に会うような名詞（計60個）の意味マップを得ることができた。本稿では、まず自己組織型神経回路網モデル、次にこのモデルを用いた意味マップの自己組織化、最後に実際に得られた意味マップについて順に述べていく。

2 自己組織型神経回路モデル

自己組織型神経回路網モデルとしてコホーネンのSOM（Self-organization Map）（詳細については Kohonen, 1997 を参照）を用いる。SOMは図1に示しているように高次元入力を持つ2次元配列のノード（ニューロン）で構成され、以下に述べる自己組織化によって高次元データを2次元空間にその特徴を反映するようにマッピングすることができる。

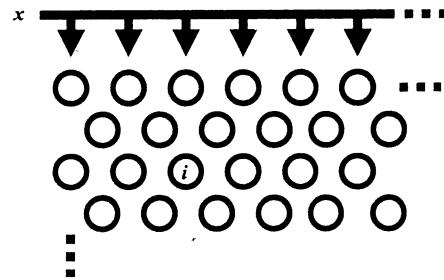


図1: コホーネンの2次元SOM

入力 $x = [\xi_1, \xi_2, \dots, \xi_n]^T \in \mathbb{R}^n$ ならば、個々のノード i はそれぞれ参照ベクトル $m_i = [\mu_{i1}, \mu_{i2}, \dots, \mu_{in}]^T \in \mathbb{R}^n$ を持つものとする。但し、参照ベクトルの要素 μ_{ij} はノード i と入力要素 ξ_j の間の重みであり、自己組織過程において少しずつ修正される。具体的に、入力ベクトル x が与えられたとき、まず、その入力をすべてのノードの参照ベクトルと比較し、ユークリッド距離の一番短いノードを活性化する。このノードをベストマッチノード、あるいは勝者ノードと呼ぶ。即ち、勝者ノード c は以下のように選ばれる。

$$c = \operatorname{argmin}_i \{ \|x - m_i\| \} \quad (1)$$

そして、グローバルに自己組織化が行われるように、勝者ノードの近傍³⁾のノードも活性化させ、リラックス（スマージング）処理を行う。即ち、活性化されたすべてのノードに対し、それらの参照ベクトルを入力ベクトルにくつぐ（距離が短くなる）ように修正を行う。

$$m_i(t+1) = m_i(t) + h_{ci}(t)[x(t) - m_i(t)] \quad (2)$$

ここで、 t は学習回数で、 $h_{ci}(t)$ は例えば以下のように定義された近傍関数である。

$$h_{ci}(t) = \alpha(t) \cdot \exp\left(-\frac{\|r_c - r_i\|^2}{2\sigma^2(t)}\right) \quad (3)$$

但し、 $r_c \in \mathbb{R}^2$ と $r_i \in \mathbb{R}^2$ はそれぞれ勝者ノード c と近傍ノード i の位置ベクトルである。従って、項 $\|r_c - r_i\|$ は近傍ノード i が勝者ノード c から離れて行くにつれ、 h_{ci} が小さくなり $m_i(t)$ の修正量が小さくなることを意味する。また、 $\alpha(t)$ は学習率で、 $\sigma(t)$ は近傍の大きさ（半径）である。これらは時間と共に単調に減少していく関数であり、例えば以下のようなものである。

$$\alpha(t) = \alpha(0) \frac{T-t}{T}, \quad (4)$$

$$\sigma(t+1) = 1 + (\sigma(t) - 1) \frac{T-t}{T} \quad (5)$$

但し、 $\alpha(0)$ は初期値で、 T は総学習回数である。

自己組織化が終った後のマッピング処理は、單に入力 x に対する勝者ノードを選び出す[式(1)]ことである。従って、上に述べた自己組織化（即ち、入力データに応じた参照ベクトルの修正）は入力にマッチするノードの整列過程と見なすことができる。即ち、マッチするノードを入力に近付ける過程である。但し、この処理はグローバルに行われるため、結果的には、似た入力への勝者ノードが近いところに配置され、そうでないノードは離れたところに配置されるようになる。

通常、学習過程は「整列」フェーズと「微調整」フェーズからなる。「整列」フェーズにおいては $\alpha(t)$ と $\sigma(t)$ の初期値を共に大きく取り、時間と共に(4)(5)に従って減少して行く。ノードの配置の基本形はこのフェーズで形成される。一方、残りのフェーズでは $\alpha(t)$ と $\sigma(t)$ は小さい値のまま長時間をかけて初期フェーズで形成された基本形を微調整する。

3 意味マップの自己組織化

3.1 目的

本研究は、連体修飾要素に基づいた被修飾語（名詞）の意味マップを扱うものである。連体修飾関係は、連体修飾要素+名詞で名詞句をなすが、この二者間には種々の関係が存在する。たとえば、「うれしい思い」の例では、

連体修飾要素「うれしい」は名詞「思い」の具体的な内容を表す。一方、「太郎の思い」の例では、「太郎の」は「思い」の所有者を表す。連体修飾要素は名詞の属性として働く場合もある。例えば、「赤いリンゴ」の例では、「赤い」は「リンゴ」の属性である。このように、名詞と連体修飾要素間の関係はさまざまである。このような関係は自然言語処理と言語学の分野で広く研究されている（例えば、Kanzaki and Isahara, 1999）。しかしながら、これらの関係を調べるために、まず連体修飾要素と名詞からなる名詞句を大量に収集・整理しなければならない。本研究は、このような大量のデータを自動的に処理することで、分析作業の効率化を図るとともに、名詞意味マップの構築によって、名詞相互の意味の類似性や相違性を可視的に捉えることを目的とする。また、本研究で扱う連体修飾関係は、連体修飾要素が主名詞の具体的な内容を表す関係であるが、これは同時に連体修飾要素が主名詞と共に通する意味要素をもつ関係でもある（詳細は神崎ら、2000 を参照）。このタイプの連体修飾要素によって主名詞を定義すれば、連体修飾要素の類似性を計算することによって、類似した意味をもつ主名詞を分類することが可能である。そういう点で、このタイプの連体修飾関係のデータは、自己組織化にとって有効であると考えられる。

3.2 データ

2年分の毎日新聞から人手で連体修飾要素が名詞の具体的な内容を表すような4,800個の名詞句を集めた。これらの名詞句には60種類の被修飾名詞が存在した。表1は集めたデータの例を示す。この表の1列目は被修飾名詞であり、2列目は共起する連体修飾要素である。

表1: 収集されたデータの例

名詞	連体修飾要素
思い	うれしい、 誇らしい、 悲しい、 気の毒な …
状態	曖昧な、 安静の、 危ない、 …
観点	アカデミックな、 教育的な、 歴史的、 …
:	:

3.3 符号化

名詞の意味マップの構築に当たって、まず個々の名詞を共起する連体修飾要素のセットで定義する。例えば、表1から「思い」を

$$\text{思い} = \{ \text{うれしい}, \text{誇らしい}, \text{悲しい}, \text{気の毒な}, \dots \}$$

のように定義する。ここで、一般に ω 種類の名詞 $w_i (i = 1, \dots, \omega)$ が存在し、それらの意味マップを構築すると仮定する。このような場合、名詞 w_i は以下のように連体修飾要素のセットで定義される。

$$w_i = \{a_1^{(i)}, a_2^{(i)}, \dots, a_{\alpha_i}^{(i)}\} \quad (6)$$

³⁾近傍の形状は六角形、正方形など色々考えられる。

但し, $a_j^{(i)}$ は w_i と共に起する j 番目の連体修飾要素で, α_i は w_i と共に起する連体修飾要素の数である. このように定義された名詞を SOM が取り扱えるように符号化するために, 英語の場合には「ランダムコーディング」法(詳細は Kohonen, 1997 を参照)を用いた. しかし, この方法は本研究においてはあまり有効ではなかったため, 以下に述べる新しい手法を導入した.

まず, 表 2 に示す名詞間の相関行列を (6) の定義式を用いて求める. ここで, 行列の要素 d_{ij} は名詞 w_i と w_j 間の意味的相関(あるいは意味的距離)を反映するものとする. 次に, この行列を用いて名詞 w_i を以下のように

表 2: 名詞の相関行列

	w_1	w_2	\cdots	w_ω
w_1	d_{11}	d_{12}	\cdots	$d_{1\omega}$
w_2	d_{21}	d_{22}	\cdots	$d_{2\omega}$
\vdots		\ddots		
w_ω	$d_{\omega 1}$	$d_{\omega 2}$	\cdots	$d_{\omega \omega}$

に符号化する.

$$V(w_i) = [d_{i1}, d_{i2}, \dots, d_{i\omega}]^T \quad (7)$$

ここで, $V(w_i) \in \mathbb{R}^\omega$ は SOM の入力である(即ち, $x = V(w_i)$, $n = \omega$). 本研究では, 要素 d_{ij} を以下のようない算式を用いて求めることにした.

$$d_{ij} = \begin{cases} \frac{(\alpha_i - c_{ij}) + (\alpha_j - c_{ij})}{\alpha_i + \alpha_j - c_{ij}} & \text{もし } i \neq j \\ 0 & \text{その他} \end{cases} \quad (8)$$

但し, α_i と α_j はそれぞれ w_i と w_j が共起する連体修飾要素の数で, c_{ij} は w_i と w_j に共通する連体修飾要素の数である. 従って, 要素 d_{ij} は名詞 w_i と w_j の間にどれだけ共通の連体修飾要素を持つかという意味での両名詞間の正規化された距離である. 即ち, d_{ij} が小さければ, 両名詞は意味的に近く, d_{ij} が大きければ, 両名詞は意味的に遠い.

4 実験結果

データ: 実験には 3.2 節に述べたデータを用いた. 従って, 名詞の種類 ω は 60 で, 連体修飾要素の総数 $\sum_{i=1}^{\omega} \alpha_i$ は 4,800 であった. このうち, 名詞「状態」の連体修飾要素の数($\alpha_{\text{状態}} = 391$)がもっとも多く, 名詞「中2」⁴⁾の連体修飾要素の数($\alpha_{\text{中2}} = 4$)がもっとも少なかった. また, 名詞「思い」と「気持」がもっと多く共通の連体修飾要素を持ち($c_{\text{思い, 気持}} = 79$), 多数の名詞が互いに共通する連体修飾要素を持たなかった.

⁴⁾添字は同じ単語の異なる意味を区別するために用いられている.

SOM: 実験には 13×13 の 2 次元配列の SOM を用い, 近傍の形状は六角形にした. 入力の次元 ω は 60 である. 整列フェーズにおいては, 学習総回数 T を 10,000 に, 学習率の初期値 $\alpha(0)$ を 0.1 に, そして, 近傍の初期半径 $\sigma(0)$ を 13(即ち, SOM の直径に等しい)に設定した. 微調整フェーズにおいては, 学習総回数 T を 100,000 に, 学習率の初期値 $\alpha(0)$ を 0.02 に, そして, 近傍の初期半径 $\sigma(0)$ を 13 に設定した.

結果: 図 2(a) に自己組織化された名詞の意味マップを示し, 図 2(b) にこれを意味的に七つのグループに分けた図を示す. 例えば, 左上から左下までの領域にマッピングされた名詞(気持, 気分, くらい, …, どん底)は基本的に「感情 感覚」を表すものと考えてよい. このグループはより詳細には直接感情を表すもの(気持, 気分, …, ため息)と感情の程度を表すもの(くらい, ほど, どん底)に分けられる. 「感情 感覚」の領域には, 左端中央に名詞「空気」が出現しているが, これは「気まとい空気」などのように「霧囲気」を表す名詞である. 連体修飾要素からみると, 「空気」は「感情 感覚」の名詞と共に連体修飾要素を多く持つが, それだけではなく「様子」の領域の名詞(様子, 空気, 気配, 様相)とも共通する連体修飾要素が多い(例えば「不穏な空気」). 従って, 図 2(b) の意味グループの図では「様子」の領域の一部を「感情 感覚」の領域に重ねて図示している. また, 同様の例として, 名詞「様子」は「様子」の領域だけでなく, 「感情 感覚」の領域(例えば「感激の様子」)や, 「状態, 状況」の領域(例えば「悪戦苦闘の様子」)とも連体修飾要素を共有している. 実際, 図 2(a) をみると, 名詞「様子」の位置は、「感情 感覚」や「状態 状況」の領域に寄っていることが分かる. 従って, 「様子」の領域を「感情 感覚」の領域とだけでなく「状態 状況」の領域とも一部分重ねて図示した.

右下の領域にマッピングされた名詞({面2, 見地, …, 意味合い}と{枠組, 枠})は観点や見地などを表すものである. このグループにおいては, 前者のセットと後者のセットの間の意味上の微妙な違いは異なる領域にマッピングされることによって表現されている. もちろん, 分け方によってはこの二つの領域にマッピングされる名詞を二つのグループに分けることも可能である. しかし, この二つの領域が近接しているため, これらの中の名詞が意味的に近いという結果には変わりがない. 似たようなことは「観点 見地」グループと「範囲」グループの間にも言える. この二つのグループの名詞は意味的に相似しているため, それぞれ隣同士の領域に位置するグループにマッピングされている. 実際, 「範囲」グループの名詞「分野」や「領域」は「観点 見地」グループに分類されてもおかしくない. 今回は, これらを二つのグループに分けたが, いずれにせよこの二つのグループの中の名詞が意味的に近いという結果に変わりがない. このように, 意味マップは意味の相似性を連続的に表現

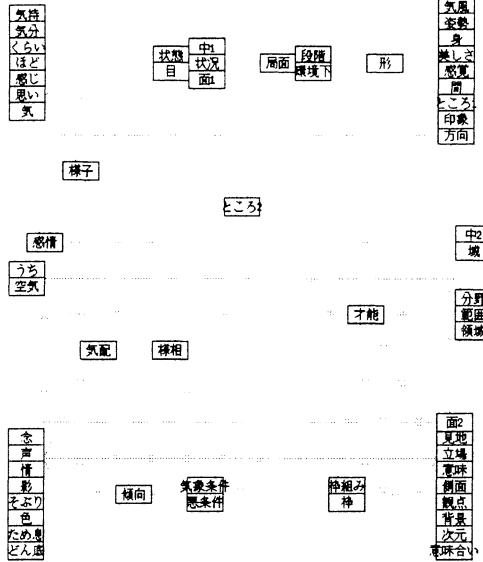


図 2(a): 自己組織化された意味マップ

しているため、意味マップを用いれば、どの名詞がどのグループに分類できるかを知ることだけでなく、名詞同士が互いにどれくらい意味的に近いかを知ることもできる。そして、名詞間の意味的相似を見る際にはそれらの名詞が同じグループに属するかどうかを考える必要はなく、また、その名詞がどのグループに分類すべきかが決まらない場合でも意味的な近さの比較が可能である。

以上に述べたように、自己組織化されたマップは全般的に我々の直観に合っていると言ってよい。うまく行かなかった例もあるが、本実験に限って言えばそれは基本的に訓練データのスパースネス問題に起因するものであった。その例として「その他」にマッピングされた名詞（気象条件、悪条件、傾向）がある。訓練データを調べた結果、これらの名詞は他の名詞との間に共通する連体修飾要素が極端に少ないことが分かった。例えば、名詞「気象条件」は他の名詞との間に多くとも三つの共通の連体修飾要素しか持っていない。

5 結び

本稿は、共起する連体修飾要素の観点から自己組織型神経回路網モデルを用いた名詞の意味マップの自動構築について述べた。小規模計算機実験の結果、我々の直観に合う意味マップの構築が可能であることが分かった。今後は、「被修飾名詞の内容を具体的に表す」という制約を外して、より広範な連体修飾要素を用いたより大規模な名詞の意味マップの構築を行う予定である。このような名詞の意味マップは、一般的な意味マップの一部をなすだけでなく、語用論研究の重要な課題とされる名詞

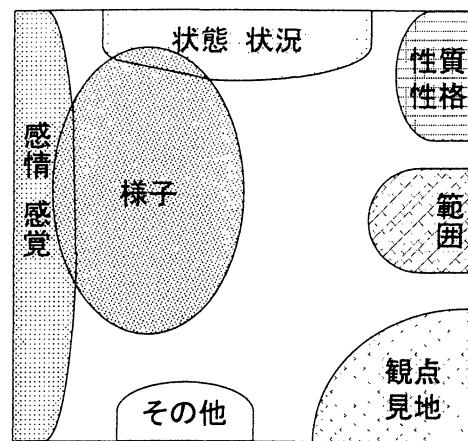


図 2(b): 意味マップに対応する意味グループ

と連体修飾要素間の関係を分析する上で強力なサポートツールにもなりうる。

謝辞

本研究に用いるデータの抽出を手伝ってくださった郵政省通信総合研究所知的機能研究室の内山将夫研究員に感謝する。

参考文献

- [1] Brown, P. F., et al.: Class-based n-gram models of natural language, *Computational Linguistics*, 18(4), pp. 467-479, 1992.
- [2] Hindle, D.: Noun classification from predicate-argument structures, *COLING-92*, Vol. 2, pp. 658-664, 1990.
- [3] Kanzaki, K. and Isahara, H.: Extracting semantic similarities of Japanese adnominal constituents from large corpora, *Papers in Computational Lexicography, COMPLEX'99*, pp. 83-92, 1999.
- [4] 神崎 享子, 馬 青, 井佐原 均: 形容詞的ふるまいをする「名詞+の」について, 言語処理学会第6回年次大会発表論文集, 2000.
- [5] 清田 陽司, 黒橋 順夫, 中村 順一, 長尾 真: 構文情報を用いた電子ニュース記事のクラスタリングシステムの作成と評価, 信学技報, NLC98-17, pp. 15-22, 1998-07.
- [6] Kohonen, T.: *Self-organizing maps*, Springer, 2nd Edition, 1997.
- [7] 森 信介, 西村 雅史, 伊東 伸泰: クラスに基づく言語モデルのための単語クラスタリング, 情報処理学会論文誌, 38(11), pp. 2200-2208, 1997.
- [8] Press, W. H., Teukolsky, S. A., Vetterling W. T., and Flannery, B. P.: *Numerical recipes in C*, Cambridge University Press, 2nd Edition, 1994.