領域表現に基づいた四項類推を行なうニューラルネットワーク

非会員 溝 口 健 二 (慶應義塾大学)

正 員 萩 原 将 文 (慶應義塾大学)

A Novel Neural Network for Four-Term Analogy based on Area Representation

Kenji MIZOGUCHI, Non-member, Masafumi HAGIWARA, Member (Keio university)

Knowledge representation is important in the information processing. The local representation and the distributed representation are well known. Recently, area representation has attracted much attention because it can preserve advantages of each method. In this paper, we propose a novel neural network for four-term analogy based on area representation. It can deal with four-term analogy such as “teacher : student = doctor : ?”. The proposed network is composed of three map layers and an input layer. The area representation method based on Kohonen Feature Map (KFM) is employed in order to represent knowledge, so that similar concepts are mapped in the nearer area in the map layer. The proposed mechanism in the map layer can realize the movement of the excited area to the near area. We carried out some computer simulations and confirmed the followings: (1) similar concepts are mapped in the nearer area in the map layer; (2) the excited area moves among similar concepts; (3) the proposed network realizes four-term analogy; (4) the network is robust for the lack of connections.

キーワード：領域表現, 四項類推, Kohonen 自己組織化マップ

1. ま え が き

人類は今までにさまざまな分野を科学技術をもって開拓してきた。しかし「脳」についてはいまだ解明されておらず、最後に残された未開の地とも言われる。近年、多分野の研究者が「脳」を解き開かすべく脳研究に注目している。その脳研究の関心事のひとつに脳内での情報表現の問題がある。脳内で情報がいかに表現されているかが解明されれば、脳研究は加速されることは間違いない。その情報表現形式として従来よりおぼあさん細胞説(局所表現)、分散表現、ダイナミカルセルアセンブリ仮説等が提案されている⁽¹⁾⁻⁽⁴⁾。

それらの説の中に、池田らの領域表現⁽⁵⁾がある。これは、分散表現の特殊な場合で、局所表現と分散表現の両者の長所を兼ね合わせたような表現形式である。この領域表現の可能性については、池田ら⁽⁵⁾やFujinagaら⁽⁶⁾の研究によって論じられている。池田らは領域表現という概念を提唱し、上位概念下位概念の関係を領域表現を用いて表すことに成功した⁽⁵⁾。またFujinagaらはdo-whileやif-thenなどの手続き的知識処理を領域表現に基づいて実現させた⁽⁶⁾。

本論文では、領域表現のさらなる可能性として、新たに類推を行うニューラルネットワークを提案する。さらにその生体での記憶システムとの対応について考察を行なう。

領域表現は原理的にKohonenのFeature Map(KFM)ア

ルゴリズム⁽⁷⁾を基にしている。すなわち概念がKFMアルゴリズムによってマッピングされるので、マップ上での概念の位相的關係は概念間の類似度を反映したものとなっている。そこで本論文では、領域表現のさらなる可能性を試す課題として類似度がキーとなる類推に着目している⁽⁸⁾⁻⁽¹⁰⁾。類推にも様々な形式があるが、我々はその中で比較的扱いやすい四項類推⁽¹⁵⁾、⁽¹⁶⁾を例題として取り挙げ、計算機シミュレーションを行った。

以下に、2.で領域表現について簡単に触れ、3.で四項類推について説明する。4.では領域表現を用いた四項類推を行うニューラルネットワークを提案し、その詳細を述べる。5.で計算機シミュレーションの結果を示し、6.では領域表現と実際の生体との対応について考察する。そして最後に7.で結論を述べる。

2. 領域表現⁽⁵⁾と四項類推

〈2・1〉 領域表現⁽⁵⁾ 領域表現は、概念をマップ内のある領域の興奮であらわすという知識表現法であり、局所表現と分散表現の両者の特長を持ち合わせている⁽⁵⁾。またマップ内で各領域を決定する際には、Kohonen Feature Map(KFM)アルゴリズムが用いられる⁽⁵⁾、⁽⁷⁾ので、概念の類似度を比較的容易に扱う事が出来る。さらに本研究では入力ベクトルは文脈付きの概念を表すようになっており⁽⁵⁾、

図 1 知識の一例: A と B の間には (A, R_{AB}, B) という知識が存在する。
 Fig. 1. An example of knowledge: There is knowledge (A, R_{AB}, B) between A and B .

図 2 類似度。
 Fig. 2. similarity.

概念と文脈を同時に扱う事が可能となっている。すなわち、概念の類似度を文脈という観点から測り、それをマップ内での領域の配置として表現している。

〈2・2〉四項類推 類推とは、類似度に基づいたたとえを用いた推測のことである。類推の例としては様々なものがあるが、本研究では次のような四項類推⁽¹⁵⁾⁽¹⁶⁾を扱う。

“教師：生徒＝医者：？”

ここで四項類推の目的は、上式の“？”に当てはまる妥当なものを選ぶことである。この場合では、“？＝患者”が最も妥当な解だと思われる。

この問題を解く際、左辺の教師と生徒の関係性を右辺に当てはめ、その類似性から解を求めることとなる。

3. 領域表現を用いた四項類推を行なうニューラルネットワーク

〈3・1〉用語説明 “ $A : B = C : D$ ” という式において、項 A と C は *Subject* と呼ばれる。項 B と D は *Object* と呼ばれる。項 R_{AB} と R_{CD} は *Relation* と呼ばれる。ここで R_{AB} と R_{CD} はそれぞれ A と B 、 C と D の関係である。また、例えば各項 $A, B, C, D, R_{AB}, R_{CD}$ は概念と呼ばれ、 (A, R_{AB}, B) のようにまとまった形式を知識と呼ぶこととする。つまり本研究で扱われる知識は、図 1 のような (*Subject*, *Relation*, *Object*) という構造をしている。

本研究での類似度は文脈に基づいたものである⁽⁵⁾。例えば、知識 (A, R_{AB}, B) については、概念 R_{AB} の文脈は A と B である。ある二つの概念を比べた際、それらの用いられる文脈により、その概念間の類似度は大きくなる。三つの

図 3 提案ネットワーク
 Fig. 3. Proposed network.

図 4 近傍結合
 Fig. 4. Neighborhood connections.

知識、 (A, R_1, B) 、 (C, R_2, D) 、 (A, R_3, B) を考えた場合、同じ文脈を有しているので R_1 と R_3 の間の類似度が一番大きくなる。図 2 にその概念図を示す。

〈3・2〉提案ネットワークの構成 提案ネットワークは、図 3 に示すように三つのマップ層と一つの入力層とから成る。三つのマップ層とは、Subject 層、Relation 層そして Object 層である。三つのマップ層は互いに全結合しており (層間結合)、また Relation 層内のニューロンは同じ層内の他のニューロンとも全結合している (層内結合)。入力層は三つの部分、Subject 部、Relation 部、Object 部からできており、各部分は各概念に対応するニューロンから構成されている。入力層と各マップ層とは全結合でつながれている (入力層－マップ層結合)。

Relation 層の層内結合はさらに近傍結合と相互結合とから成る。近傍結合は図 4 に示すようにあるニューロンとその周囲 8 近傍のニューロンとの間に存在する。ここで v は重みを表すパラメータである。重みは二つのニューロン間の距離に反比例している。また、Relation 層のニューロンは相互結合 $u_{j \rightarrow i}$ も有している。ここで $u_{j \rightarrow i}$ は Relation 層のニューロン j からニューロン i への相互結合を表す。

図5 四項類推“A : B = C : ?”の流れ

Fig. 5. Flow of association of “A : B = C : ?”

〈3・3〉類推の概要 ここでは、図5を用いて類推の概要について説明する。例として“A : B = C : ?”という四項類推を考えることにする。この解は“? = D”であるとする。始めに、入力層においてSubject部のAに対応するニューロンとObject部のBに対応するニューロンとが刺激される（一方学習時には入力文脈を持つ）(①, ②)。この入力は入力層-マップ層結合を通りそれぞれのマップ層へ届き、Subject層、Object層上でそれぞれ領域AとBを賦活させる(③, ④)。このとき入力層-マップ層結合は各概念領域を決定するのに用いられている。次に、領域AとBの興奮は層間結合によってRelation層へと運ばれる。これらの興奮がRelation層で概念 R_{AB} を想起させる。ここで R_{AB} は概念AとBの間のRelationである(⑤)。ここに層間結合はマップ層間での連想記憶に用いられる。

Relation層での興奮領域は、領域 R_{AB} から領域 R_{CD} のような近くの領域へと移動する(⑥)。この移動は層内結合によって引き起こされる。

ターゲット段階においてSubject層の概念Cが賦活される（ターゲット段階についてはあとで説明する）(⑦, ⑧)。この領域Cの興奮と先の領域 R_{CD} の興奮がマップ間結合を通り、Object層へ移動し概念Dを想起させる(⑨)。その結果として四項類推の妥当な解が得られる。

〈3・4〉学習段階

〈3・4・1〉入力層-マップ層結合の学習 この過程ではKFMアルゴリズムを用いて、各概念領域がマップ層に形成される。 (A, R_{AB}, B) のようにある知識は、三つの概念ベクトルの結合したベクトル形式で表される。また、文脈を反映させるため各マップ層はそれに対応した概念ベクトルだけではなく他の概念ベクトルも同時に影響を受ける。ただし、対応した概念ベクトルのみが重みづけられ、マップに反映される。

この論文では類推を扱っている。特に類似度に注目している。しかし図1に示されるような知識群には共通する文脈を有するRelation概念はほとんどない。そこで、Sub-

ject概念とObject概念のすべての意味の通る組合せが文脈としてRelation概念に付加される。そしてそれらのすべてが学習時の入力ベクトルとして使用される。例えば、 (A, R_{AB}, B) , (C, R_{AB}, B) , (C, R_{AB}, D) , ..., (A, R_{CD}, B) , ...などが学習時の知識として用いられる。

〈3・4・2〉層間結合の学習 マップ間結合は、三つのマップ層の間での連想記憶に用いられる。学習には、勝ちニューロンの近傍にだけ効果を持つ近傍ヘブ学習⁽⁵⁾が用いられる。この学習は入力層-マップ層結合のあとで行なわれる。

マップ n のニューロン j からマップ m のニューロン i への結合 $v_{nj \rightarrow mi}$ は次のように更新される。

$$\Delta v_{nj \rightarrow mi} = \gamma h_{mi} \cdot h_{nj} \cdot y_{nj} (\delta y_{mi} - v_{nj \rightarrow mi}) \quad (1)$$

ここで γ は層内結合に対する層間結合の学習のスケールングファクタであり、 δ はニューロンの出力値を適当な値の範囲に調整するスケールングファクタである。 h_{mi} 、 h_{nj} は近傍関数、 y_{nj} はマップ n のニューロン j の出力を表す。

〈3・4・3〉層内結合の学習 マップ内結合はRelation層において興奮領域の移動を引き起こす。またこの結合はさらに近傍結合と相互結合から構成されている。近傍結合の結合荷重は経験的に値が決定される。一方、相互結合の学習のために、我々は改良近傍ヘブ学習を提案し、これが用いられる。この学習もまた入力層-マップ層結合の学習後に行なわれる。この学習では、ほぼ概念領域内の相互結合のみが値を持つようになる。それ以外のほとんどの相互結合の値は0となる。

改良近傍ヘブ学習は近傍ヘブ学習と次の二点で異なる。一つ目は、改良近傍ヘブ学習では一つのマップ内で学習が行なわれるのに対し、近傍ヘブ学習は二つのマップ間での学習に用いられる点である。もう一つは、改良近傍ヘブ学習では近傍関数が(3)式のような点である。一方、近傍ヘブ学習では近傍関数としてガウス関数が用いられている点である。(3)式は概念領域内ではほぼ一定の値なので自己想起するためには適している。ガウス関数では徐々に値が小さくなっていくので、概念領域の境界付近をはっきり想起できないからである。

ニューロン j からニューロン i への相互結合 $u_{j \rightarrow i}$ は次のように更新される。

$$\Delta u_{j \rightarrow i} = \eta h'_{ii} \cdot h'_{ji} \cdot y_j (\zeta y_i - u_{j \rightarrow i}) \quad (2)$$

ここで y_i 、 y_j はそれぞれRelation層のニューロン i 、 j の出力である。また η は層間結合に対する層内結合の学習のスケールングファクタであり、 ζ はニューロンの出力値を適当な値の範囲に調整するスケールングファクタである。 h'_{ii} 、 h'_{ji} は次のような近傍関数である。

$$h'_{ii} = \frac{1}{1 + \exp\left(\frac{d(i, i^*) - \theta_{h'}}{T_{h'}}\right)} \quad (3)$$

ここで $\theta_{h'}$ 、 $T_{h'}$ はシグモイド関数のパラメータであり、 $d(i, i^*)$ はニューロン i 、 i^* 間の距離である。

図 6 近傍結合による興奮の伝播
Fig. 6. Activity propagation by neighborhood connections.

図 7 Relation 層での自己想起
Fig. 7. Auto-association in Relation layer.

〈3・5〉 類推段階

〈3・5・1〉 Relation 層でのメカニズム Relation 層でのメカニズムには、層間の働きと層内の働きの二つがある。それぞれは次のようなものである。

(1) 層間結合は連想記憶を実現するため用いられる。つまりある Subject 概念、ある Object 概念からそれと関連のある Relation 概念が層間結合の働きによって想起されるのである。例えば、Subject 層の概念 A と Object 層の概念 B から Relation 層では概念 R_{AB} が想起される。

(2) Relation 層での層内結合は興奮領域をその近傍へと移動させるために用いられる。この層内結合の働きはさらに二つの働きからなる。興奮伝播と概念の自己想起である。興奮伝播は近傍結合によってもたらされ、概念の自己想起は相互結合によって実現される。

興奮伝播とは図 6 のようなものである。図 6(a) では、中央の領域が想起されている。その数ステップ後、その興奮は図 6(b) に示すようにその近傍へと伝播する。このとき中央の領域が興奮していないのは不応期⁽¹⁷⁾のためである。ここで不応期とは、ニューロンの出力値の時間加算が閾値 θ を越えた後、出力値が 0 になる期間のことである。詳細は、後述のアルゴリズムのとおりである。

一方、概念の自己想起は図 7 に示すようなものである。図 7(a) では、左下の興奮領域が広がりはじめている。図 7(b) では、興奮領域がさらに広がりその一部が想起されるべき領域へ差しかかっている。その結果として図 7(c) のように

興奮は想起されるべき領域へと引き込まれる。このような引き込みが起こるのは、相互結合がほぼ各概念領域内のみ値を持つよう学習されるためである。仮に相互結合がまったくないとすれば、興奮伝播は無秩序に行なわれてしまう。詳細なアルゴリズムは次の通りである。

- (1) Relation 層 r のニューロン i は Subject 層 s と Object 層 o からの影響を時刻 t で受ける。

$$net_{ri,t,inter} = \sum_{j \in s} v_{sj \rightarrow ri} \cdot y_{sj,t} \sum_{j \in o} v_{oj \rightarrow ri} \cdot y_{oj,t} \quad (4)$$

ここで $net_{ri,t,inter}$ は層間の働きを表す。

- (2) 時刻 $t-1$ における Relation 層のニューロン j の出力 $y_{rj,t-1}$ は時刻 t で層内結合を通り、マップ r のニューロン i へと伝わる。

$$net_{ri,t,intra} = \sum_{j \in r} \left(\kappa \cdot u_{j \rightarrow i} + \frac{\nu}{d^*(i,j)} \right) y_{rj,t-1} \quad (5)$$

ここで $net_{ri,t,intra}$ は層内の働きを表す。

$$d^*(i,j) = \begin{cases} d(i,j), & \text{if } j \in 8\text{-neighbor} \\ \infty, & \text{else} \end{cases} \quad (6)$$

$d(i,j)$ はニューロン i, j 間の距離を表し、 κ は相互結合 $u_{j \rightarrow i}$ の影響をあらわすパラメータである。

- (3) 時刻 t におけるマップ r のニューロン i の内部状態 $net_{ri,t}$ は次のように決定される。

$$net_{ri,t} = \iota \cdot net_{ri,t,inter} + net_{ri,t,intra} \quad (7)$$

ここで ι はそれぞれの要素の強さの比を決めるパラメータである。そして $net_{ri,t}$ は正規化され、これを $net'_{ri,t}$ とする。

- (4) 出力 $y_{ri,t}$ は次のように決定される。

$$y_{ri,t} = \begin{cases} net'_{ri,t}, & \begin{cases} net'_{ri,t} \geq \theta_{fire} \text{ かつ} \\ \text{不応期でない} \end{cases} \\ 0, & \begin{cases} net'_{ri,t} < \theta_{fire} \text{ または} \\ \text{不応期} \end{cases} \end{cases} \quad (8)$$

ここで θ_{fire} は閾値であり、出力がこれを上回るとそのニューロンは賦活される。

- (5) 出力 $y_{ri,t}$ は sum_{ri} に加算される。

$$\Delta sum_{ri} = y_{ri,t} \quad (9)$$

sum_{ri} が θ より大きくなった場合、ニューロンは T_{ref} ステップ続く不応期に入り sum_{ri} は 0 に初期化される。

〈3・5・2〉 ベース段階・ターゲット段階 類推過程はさらにベース段階とターゲット段階とに分かれ、この二つの段階が繰り返される事で構成されている。

ベース段階は T_{base} ステップ続く。この段階では、例えば概念 A, B が入力層に与えられ、Subject 層、Object 層それぞれに概念 A, B が想起される。その後 Relation 層は Subject

図 8 Subject 層の概念 C からの Relation 層での影響

Fig. 8. Reflection in Relation layer from a concept C in Subject layer.

層, Object 層からの影響を受けつつ動作する。
ターゲット段階はベース段階の後、 T_{target} ステップ続く。この段階では概念 C が入力層に与えられることによって、Relation 層では興奮領域が、例えば領域 R_{AB} のような、適当な領域へと移動しやすくなる。図 8(a) では、想起された領域が近傍結合の働きによって周囲に伝播している。このままこの伝播が続けば、その先には想起される領域が三つも存在する。しかしここで Relation 層は、Subject 層から次のような影響を受けるので想起されるべき適当な領域だけが賦活させられる。Subject 層では、ターゲット段階において入力が概念 C であるので領域 C が想起されている。その領域の興奮はマップ間結合を通り Relation 層へ伝わり、Relation 層で概念 C と関係のある領域を想起させる。図 8(a) では、図の中央の領域にその興奮が見える。図 8(b) では、その興奮と近傍結合によって伝播してきた興奮の両者が、想起されるべき領域を最も強く想起している様子が分かる。そして Subject 層の領域 C と Relation 層で新しく想起された領域が Object 層に概念を想起させる。

またターゲット段階では Object 層に対する入力がないので、式 (4) の $\sum_{j \in o} v_{oj \rightarrow ri} \cdot y_{oj,t}$ の部分は、次のように決められる。

$$\sum_{j \in o} v_{oj \rightarrow ri} \cdot y_{oj,t} = \mu \cdots \cdots \cdots (10)$$

ここで μ は、ベース段階とターゲット段階で Subject 層と Object 層からの影響をほぼ等しくするためのパラメータである。

4. 計算機シミュレーション

提案ネットワークの動作を確認するため計算機シミュレーションを行なった。シミュレーションで用いた知識を図 9 に示す。その中の関係からいくつかの四項類推をシミュレーションした。また表 1 にシミュレーションで用いたパラメータを示し、図 10 にその結果得られた Relation 層上の概念の配置を示した。

図 9 シミュレーションで用いた知識

Fig. 9. Knowledge used in simulations.

表 1 シミュレーションのパラメータ

マップサイズ		20 × 20
ν	近傍結合	0.1
γ	層間結合学習のスケールリングファクタ	1.0
δ	出力値調整のスケールリングファクタ	0.02
η	層内結合学習のスケールリングファクタ	1.5
ζ	出力値調整のスケールリングファクタ	0.02
$\theta_{h'}$	シグモイド関数の中心	2.5
$T_{h'}$	シグモイド関数の温度	0.0625
κ	相互結合の影響	1.7
ι	連想時の層間の連想の影響	3.0
$\theta_{f,rec}$	発火の閾値	0.15
θ	不応期導入の閾値	5.0
T_{ref}	不応期の期間	6
T_{base}	ベース段階の期間	3
T_{target}	ターゲット段階の期間	2
μ	ターゲット段階の Object 層からの影響	0.1

図 10 配置

Fig. 10. Allocation.

〈4・1〉 類推結果 1 “教師：生徒＝医者：？”という四項類推を行なった。この四項類推に対する期待される解は、“？＝患者”である。

類推時の各マップ層の動作を図 11 に示す。時刻 $t = 0$ はベース段階なので“教師”と“生徒”が Subject 層と Object 層にそれぞれ想起された。このとき Relation 層では“教師”と“生徒”の間の関係である“教える”が想起された。時刻 $t = 8$ はターゲット段階なので“医者”が Subject 層に想起された。また、Relation 層では興奮領域の伝播が始まった。時刻 $t = 13$ では Relation 層の興奮領域はさらに移動し、概念“治療する”が想起された。そのとき Subject 層では“医者”が想起されていたので、Subject 層の“医者”と Relation 層の“治療する”がマップ間結合を通り Object

図 11 四項類推“教師：生徒＝医者：？”時のネットワークの動作

Fig. 11. Behavior at “teacher : student = doctor : ?”

図 12 四項類推“教師：生徒＝看護婦：？”時のネットワークの動作

Fig. 12. Behavior at “teacher : student = nurse : ?”

層に“患者”を想起させ、この四項類推における妥当な解が得られた。

〈4・2〉類推結果2 〈4・1〉とは別の“教師：生徒＝看護婦：？”という四項類推を行なった。この四項類推での望まれる結果は“＝医者”である。なぜならば教師と生徒の関係は人と人の関係であるので看護婦に対する人は医者だからである。その時のマップ層の動作を図 12 に示す。〈4・1〉のときのように最終的には、Relation 層で概念“手伝う”が想起され、それにより Object 層では概念“医者”が想起された。

〈4・3〉ロバスト性 結合のいくつかが欠損した際のネットワークの動作を確認するために、ランダムにネットワーク中の結合数の 30% を選び、その結合荷重を 0 とした。

図 13 30%の結合荷重が欠損している際のネットワークの動作

Fig. 13. Behavior of network (30% of weights were randomly removed).

図 13 はそのときの結果を示している。このシミュレーションで用いた四項類推は〈4・1〉と同じ“教師：生徒＝医者：？”である。このように多数の結合が欠損した際でもネットワークの動作は欠損がない場合（図 11）に比べ、ほぼ同様な振舞いを示した。このことから提案ネットワークは結合の欠損に対しロバストであると言える。

5. 考 察

4. において 3 つの例を示したが、それらはどれももっともらしいひとつの解だけを示している。したがって、それはわかりやすさのためでありそれだけが唯一の解ではない。実際、入力層-マップ層結合の初期乱数によって得られる解が異なる場合があり、また同一試行中でも、始めに予期していなかった概念が想起される場合がある。これらは、類推において誰もが必ずしも同じ解を導き出さないことや、その時の状況に応じて異なった解を導く事に対応するとも考えられる。

さて、領域表現と生体内での情報表現との対応づけについて考察する。

本論文も含めて、領域表現についていくつかの論文が出されている^{(5),(6)}。それらはいずれもがマップ層と入力層の 2 層構造を有している。入力層はある概念に対して文脈を付加するために用いられ、マップ層にはその文脈付きの記憶が書き込まれる。

一方、生体での記憶のモデルとして皮質と海馬の関係が注目されている⁽¹⁸⁾⁽¹⁹⁾。長期記憶は皮質に蓄えられると言われ、海馬は長期記憶の定着に関与していると言われている。また海馬は記憶の文脈形成に関与しているとも言われている。

これらのことを照らし合わせてみると、領域表現およびそれを実現するためのネットワークは、生体での記憶モデ

ルとしての皮質と海馬の関係に対応づけるのではないかと考えられる。すなわちマップ層は皮質に対応し、入力層は海馬に対応すると考える。

また、Penfieldの実験で有名な感覚性小人は体の部位の位相的關係が体性感覚皮質においてもほぼ保持されている⁽²⁰⁾。また手や口唇などの知覚が敏感である部位は感覚性小人のなかでも大きな領域で表現されている。この性質は領域表現での領域の形成過程との対応が良くつく。すなわち提案ネットワークではKFMアルゴリズムを基にしているので文脈的類似度が高ければマップ上での位置関係が近くなり、かつ入力頻度の多い概念領域は大きく形成される。このことは領域表現と生体での一部での情報表現との整合性を示すとも考えられる。

6. む す び

領域表現を用いた四項類推を行なうニューラルネットワークを提案した。このネットワークでは知識表現法としてKFMアルゴリズムに基づいた領域表現が用いられている。また、Relation層内でのメカニズムの一部に改良近傍ヘブ学習も提案した。これらのメカニズムが一体となりマップ上で近くに配置された領域間での興奮の移動を可能となっている。ゆえに提案ネットワークは類似度を扱う問題に適していると言える。

本論文ではそのような問題として四項類推を行うネットワークを提案し、その計算機シミュレーションを行なった。そして(1)類似度の高い概念がマップ上で近くに配置されること(2)類似度の高い概念間で興奮領域の移動が実現されること(3)提案ネットワークで四項類推ができること(4)提案ネットワークが結合の欠損に対してロバストであることを確認した。

今後の課題としては、領域表現を裏付ける更なる生理実験データが要求される。また、皮質上での領域間の相互作用を示す生理実験データとの対応について考慮していきたい。

なお本研究の一部は、文部省の分子・超分子 超構造体理工学プロジェクトによっている。

(平成12年9月5日受付, 同13年2月22日再受付)

文 献

- (1) H. B. Barlow: "Single units and sensatioperceptual psychology?," Perception, vol. 1, pp.371-394, 1972.
- (2) 伊藤浩之: "脳におけるダイナミカルな情報コード," 数理科学, no. 394, pp. 27-37, Apr. 1996
- (3) 櫻井芳雄: "ニューロン集団の相関活動をみる," 科学, vol. 66, no. 11, pp. 784-792, Nov. 1996
- (4) H. Fujii, H. Ito, K. Aihara, N. Ichinose and M. Tsukada: "Dynamical cell assembly hypothesis - theoretical possobolity of spatio-temporal coding in the cortex," Neural Networks, 9, pp. 1303-1350, 1996.
- (5) 池田成宏, 萩原将文: "新しい知識表現方法(領域表現)の提案とニューラルネットワークによる実現," 信学論 D-II, vol. J81-D-II, no. 6, pp. 1328-1335, 1998.
- (6) S. Fujinaga and M. Hagiwara: "Procedural Knowledge Processing based on Area Representation," IEEE International Conference on Systems, Man, and Cybernetics, Orland,

Florida, vol. 5, pp. 4519-4524, 1997.

- (7) T. Kohonen: Self-Organizing Maps, Springer-Verlag, 1995.
- (8) D. Gentner: "Structure-mapping: Theoretical framework for analogy," Cognitive Science, vol. 7, no. 2, pp. 155-170, 1983.
- (9) B. Falkenhaine, K. D. Forbus and D. Gentner: "Structure mapping engine: Algorithm and examples," Artificial Intelligence, vol. 41, pp. 1-63, 1989.
- (10) K. J. Holyoak and P. Thagard: "Analogical mapping by constraint satisfaction," Cognitive Science, vol. 13, pp. 295-355, 1989.
- (11) P. Thagard, K. J. Holyoak, G. Nelson and D. Gochfeld: "Analog retrieval by constraint satisfaction," Artificial Intelligence, vol. 46, pp. 259-310, 1990.
- (12) 渡辺 俊陽, 安井 湘三: "アナロジー学習意味ネットワーク: 抽象化写像、内部表現生成、類推," 信学技報, NC98-8, pp. 55-62, 1998.
- (13) 藤村 英明, 安井湘三: "アナロジー学習意味ネットワーク: 抽象化内部表現の保持と追加学習," 信学技報, NC98-8, pp. 63-70, 1998.
- (14) 松原 仁, 青木 義次, 折原 良平: "アナロジー入門," 情報処理, vol. 34, no. 5, pp. 522-535, 1993.
- (15) 鈴木 宏昭: 類似と思考, 共立出版, 1996.
- (16) 楠見 孝, 松原 仁: "認知心理学におけるアナロジー研究," 情報処理, vol. 34, no. 5, pp. 536-546, 1993.
- (17) 甘利俊一: 神経回路網の数理, 産業図書, 1987.
- (18) 塚田 稔: "海馬記憶神経回路と学習則," 日本神経回路学会誌, vol. 4, no.3 pp. 126-135, 1997.
- (19) 望月彰子, 大森隆司: "PATON: 文脈依存性を表現する動的神経回路網モデル," 日本神経回路学会誌, vol.3, no. 3, pp. 81-89, 1996.
- (20) W. ペンフィールド, T. ラスムッセン: 脳の機能と行動, 岩本隆茂, 中原淳一, 西里静彦 訳, 福村出版, 1986.

溝 口 健 二 (非会員) 平11慶大・理工 電気卒. 平13同大大学院理工学研究科修士課程了. 在学中, ニューラルネットワークの研究に従事. 現在, オムロン(株)勤務.

萩 原 将 文 (正員) 昭57慶大・理工・電気卒. 昭62同大大学院博士課程了 工博. 同年同大助手. 現在, 同大助教授. 1991年より2年間アメリカ Stanford 大学訪問研究員. ニューラルネットワーク, ファジーシステム, GAの研究に従事. 工学博士. 1986年丹羽記念賞, 1987年電子情報通信学会学術奨励賞, 1990年IEEE論文賞, 1994年安藤記念学術奨励賞, 1996年ファジィ学会著述賞受賞.