

ベイジアンネット、SOM、ICA、強化学習を組み合わせた 大脳皮質の神経回路モデル

A Neural Network Model of Cerebral Cortex that Combines Bayesian Network, SOM, ICA and Reinforcement Learning

一杉裕志
Yuuji ICHISUGI

産業技術総合研究所 脳神経情報研究部門

Neuroscience Research Institute, National Institute of Advanced Industrial Science and Technology(AIST)

The author is trying to achieve a breakthrough in the elucidation of information processing of the cerebral cortex, in order to realize highly intelligent robots like human beings. The author designed a neural network model of the cerebral cortex, called BESOM model. The neural network that executes the algorithm of the model is very similar to six-layer and column structures that represent the anatomical characteristics of a cerebral cortex.

1. はじめに

筆者は神経科学と機械学習に関する最近の知見を踏まえた上で、脳の情報処理原理解明の突破口を開く研究を行っている。これにより、人間のような知能の高いロボットの実現を可能にしようとしている。

筆者は BESOM モデルと呼ぶ、大脳皮質の神経回路モデルを設計した。BESOM モデルは4つの機械学習技術(自己組織化マップ、ベイジアンネット、独立成分分析、強化学習)をエレガントに組み合わせたもので、脳の機能を再現させるモデルとして計算論的に妥当な特徴を持っている。そして、計算論的に導かれたアルゴリズムを実行する神経回路は、驚くべきことに大脳皮質の主要な解剖学的特徴と非常によく一致しており [1]、大脳皮質の情報処理原理を説明する正しいモデルであることはほぼ間違いないと考えている。このモデルを用いて、概念獲得、パターン認識、行動獲得、思考、言語獲得などの、大脳皮質の主要な機能を再現する具体的方法も明らかになりつつある。

神経回路モデルはまだ不完全であり、計算機シミュレーションを行うまでには到っていないが、非常に有望なモデルであると筆者は考えている。

以下の章では、BESOM モデルの概要を説明する。また、BESOM モデルによって脳の様々な機能、パターン認識、推論、行動獲得、時系列学習、行動計画がいかにして実現されるかについて概要を述べる。

モデルのより詳細については [2] を参照されたい。

2. BESOM モデルの構成要素

BESOM モデルは脳全体のマクロなスケールの構造から、個々のニューロンの機能というミクロなスケールの構造にいたるまで、幅広く関係している。

BESOM モデルは、現在のところ BESOM ネットと強化学習機構の2つの機構からなる。BESOM ネットは図1のような構造をしている。

BESOM ネットは、基底と呼ぶ単位の階層構造で構成される。基底は、多数のノードから構成される。ノードは確率変数を

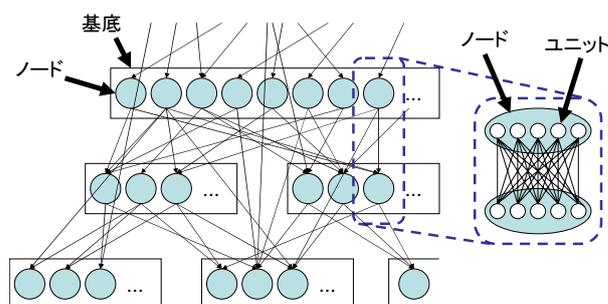


図 1: BESOM ネットの構成要素。四角は基底、基底の中の丸はノード、ノードの中の白い丸はユニットを表す。

表す。1つの基底内のノードが表す情報は独立成分分析(ICA)により互いに独立になる。

異なる階層の基底に含まれるノードどうしはエッジで結ばれる。従って、ノードは非循環有向グラフを構成する。このノードのネットワークはベイジアンネットとして動作する。

ノードは複数のユニットから構成される。ノードは確率変数だが、ユニットはその確率変数が取りうる値に対応する。各ノードは、自己組織化マップ(SOM)の競合層でもあり、自分の子ノードからの入力を圧縮する。個々の確率変数の値を持つ意味は、SOMによって獲得される。

BESOM ネットを動作させるためのアルゴリズムは、現在のところ10種類弱の変数(4章)を用いて表現されている。アルゴリズムは単純な繰り返しを行うもので、神経回路で実現可能である(5章)。

基底の階層構造、基底内のノードの数、ノード内のユニットの数はすべて最初に与えられ、学習により変化しない。学習により変化するのは、ユニット間の結合の重みのみである。

大脳皮質を構成する領野、コラム、ニューロン等の要素と、ここで述べた BESOM モデルを構成要素の間の対応をまとめたものが表1である。

連絡先: 一杉裕志、独立行政法人 産業技術総合研究所 脳神経情報研究部門 〒305-8568 茨城県つくば市梅園1-1-1 中央第2, y-ichisugi@aist.go.jp

脳の構成要素	ヒトにおけるサイズ	ヒトにおける数	BESOM モデルの構成要素
大脳皮質	約 200,000mm ²	1	BESOM ネット
領野階層	-	約 10	基底の階層
領野 (の一部)	40,000mm ² 程度	約 50	基底 (注 1)
ハイパーコラム	1mm ² 程度	約 20 万	ノード
コラム	0.01mm ² 程度	約 2000 万	ユニット
ニューロン	-	約 140 億個	10 種類弱の変数 (注 2)
シナプス	-	10 ¹³ 個程度?	ユニット間の結合の重み

表 1: 大脳皮質と BESOM モデルを構成する要素の間の対応。注 1: 基底と領野の関係は実際は一対一対応ではない。注 2: ニューロンと BESOM のアルゴリズムの変数との対応も一対一ではない。1 つの変数は複数のニューロンで実現されると考えている。

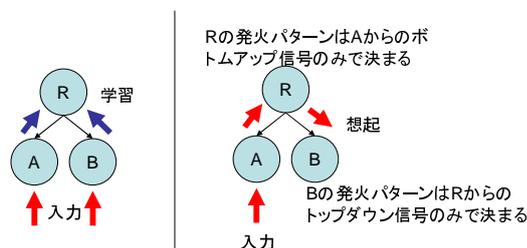


図 2: BESOM による学習と想起。各ノードは、子ノードからの入力の組を圧縮して学習する (図左)。また、子ノードの一部の情報が観測値として与えられると、他の子ノードの関連する値を想起することができる (図右)。

3. BESOM の基本動作

BESOM は、SOM と ICA を用いて外界のモデルを自己組織化して、ベイジアンネットを用いて表現する。このベイジアンネットを用いて、外界の状態の認識、運動制御、論理的推論・確率的推論など、様々な情報処理を行う。

BESOM の 1 つのノードに注目すると下記のような動作をする。個々のノードは、学習時には SOM の競合層として働き、図 2 の左のように、子ノードからの入力の組を圧縮して学習する。学習した結果はベイジアンネットの条件付確率表になり、これを用いて様々な情報処理が可能になる。例えば記憶の想起は以下のように行われる。図 2 の左のように、ノード R が 2 つの子ノード A, B の出力の関係を学習済みであるとする。このとき、図 2 の右のように、B へのボトムアップの入力を遮断すれば R のユニット出力は A からの入力のみで決定し、B のユニット出力は R からのトップダウン信号のみで決定する。つまりノード A が表現するパターンから連想された記憶がノード B 上に想起されることになる。

BESOM モデルによれば、大脳皮質の各領野は階層的 SOM と階層的 ICA を用いて巧妙に圧縮された巨大なテーブル (表) である。テーブルは最も単純だが最も汎用性のあるデータ構造であり、脳がこのデータ構造を採用したとすればそれは極めて妥当な選択である。テーブルは用途に応じて様々な情報を表現することができる。例えばベイジアンネットのための条件付確率表、知識を記憶・検索するための関連データベースの表、強

$$l_{XY}^{t+1} = z_Y^t + W_{XY} o_Y^t$$

$$o_X^{t+1} = \prod_{Y \in \text{children}(X)} l_{XY}^{t+1}$$

$$k_{UX}^{t+1} = W_{UX}^T b_U^t$$

$$p_X^{t+1} = \sum_{U \in \text{parents}(X)} k_{UX}^{t+1}$$

$$r_X^{t+1} = o_X^{t+1} \otimes p_X^{t+1}$$

$$Z_X^{t+1} = \sum_i (r_X^{t+1})_i \quad (= \|r_X^{t+1}\|_1 = o_X^{t+1} \cdot p_X^{t+1})$$

$$z_X^{t+1} = (Z_X^{t+1}, Z_X^{t+1}, \dots, Z_X^{t+1})^T$$

$$b_X^{t+1} = (1/Z_X^{t+1}) r_X^{t+1}$$

ただし

$$x \otimes y = (x_1 y_1, x_2 y_2, \dots, x_n y_n)^T$$

図 3: 近似確率伝播アルゴリズム [1]

化学習のための状態行動対の表、非線形関数を近似するための関数表、時系列情報を扱うための状態遷移表などである。

4. 近似確率伝播アルゴリズム

BESOM が外界を認識するには、確率伝播アルゴリズムをいくつかの仮定のもとに近似したアルゴリズム [1] を用いる (図 3)。大文字の T は転置行列を表す。小文字の $t, t+1$ は時刻を表し、 t における他の変数の値を使って $t+1$ における値を計算する。右下の添え字 X はノード名を表す。例えば変数 b_X は、ノードごとに存在することになる。また、右下の添え字 XY や UX は、2 つのノードを結ぶエッジを意味する。例えば変数 l_{XY} や行列 W_{XY} は、エッジごとに存在する。

全てのノードについて、ノード内のユニット数は s であるとする。行列 W_{XY} は、ノード X とその子ノード Y に含まれるユニット間の結合の重みを表す $s \times s$ の行列である。 Z_X はスカラー値、他の変数 $l_{XY}, o_X, k_{UX}, p_X, r_X, z_X, b_X$ は長さ s の縦ベクトルである。

変数 $l_{XY}, o_X, k_{UX}, p_X, r_X, b_X$ の i 番目の要素は、ノード X のユニット x_i の計算をする。行列 W_{XY} の要素 w_{ij} は、

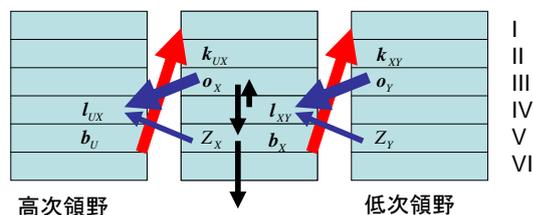


図 4: 近似確率伝播アルゴリズムは、大脳皮質の6層構造の間の接続規則にかなりきれいに対応付けられる。

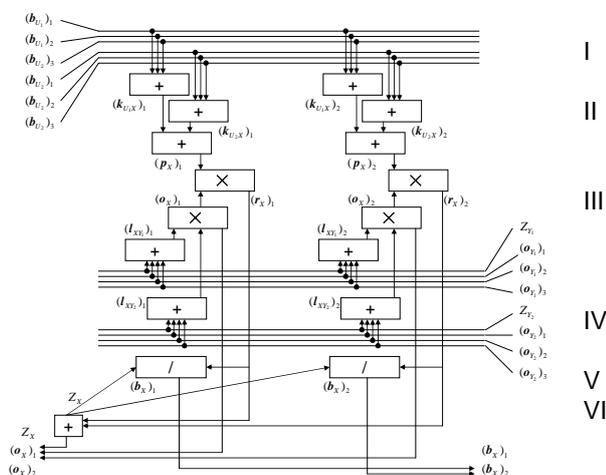


図 5: 近似確率伝播アルゴリズムを実行する神経回路。変数の場所と配線が、6層構造に関する解剖学的知見と様々な点で一致しており、BESOM モデルが正しい大脳皮質のモデルであることを裏付ける非常に強力な証拠である。

条件付確率 $P(Y = y_j | X = x_i)$ を表す。

各変数は、適当な初期値から始める。各変数の値の更新は、値がある程度収束するまで繰り返す。近似確率伝播アルゴリズムの実行中は W_{XY} の値は変化しない。

変数 o_X (observation の略) は主にボトムアップの情報を使った観測データに基づく値、 p_X (prediction の略) はトップダウンの情報を使った予測に基づく値、それらの積 r_X を正規化した値 b_X (belief の略) は最終的に得られる事後確率を表す。

5. 神経科学的知見との対応

5.1 大脳皮質の解剖学的特徴

大脳皮質は6層構造をしている。大脳皮質の領野間は双方向結合を持っており、その結合の仕方に規則性があることが知られている [3]。感覚入力に近い低次領野から、前頭葉・海馬に近い高次領野に向かうボトムアップの結合は、主に3層から4層に向かう。5層から4層への結合がある場合もある。高次領野から低次領野に向かうトップダウンの結合は、主に5・6

層から1層に向かう。(3層から1層への結合も少しある。)

また、大脳皮質内の主なニューロンの樹状突起と軸索の分布から、コラム内では4層に入力された情報は2・3層を経由し5層から他の領域に出力されると考えられている [4]。5層の情報はさらに6層を経由して4層に入力される。

この2つの知見を合わせると、コラム内における情報処理の途中結果である3層の情報が上位領野に送られ、最終結果の5層の情報は下位領野に戻されるといって、とても奇妙な構造をしていることになる。この構造の機能的意味については知られていない。

5.2 6層構造と近似アルゴリズムの対応

近似確率伝播アルゴリズムに現れる7つの変数のうち、ノード間の通信に関わる5つの変数を、領野間の結合規則に当てはめてみると、図4のようになる。内積を計算する k_{UX} はニューロンのほとんどない1層ではなく2層とした。 Z_X は3層の可能性もあるが、 b_X との関連の深さから5・6層とした。

図に示されているように、近似アルゴリズムは領野間の結合の規則と素直に対応が付き、偶然とは考えられない。

さらに6層構造に関する様々な神経科学的知見をふまえて、近似確率伝播アルゴリズムを神経回路で表現してみたものが図5である。前述の、4層 2・3層 5層の順の情報の流れは、変数 I_{XY} 、 o_X 、 r_X 、 b_X の順の情報の流れに対応している。(5層 6層 4層の情報の流れについては、6.4章参照。)

図5の神経回路は、(1) コラム内では垂直方向だけでほとんどの情報処理が行われる、(2) 2層、4層、5層には水平線が見られる、(3) 2層および4層には細かい多数のニューロンがある、といった解剖学的知見との一致が見られる。

6. BESOM による大脳皮質の機能の実現

この章では、前章で述べた構造を持つ BESOM ネットが、具体的に大脳皮質の機能をどのように実現し得るのか、概要を述べていく。

6.1 パターン認識

BESOM を用いてパターン認識が可能になるはずである。

最下端のノードから視覚刺激が与えられると、階層的 SOM の機能により情報が階層的に圧縮され、上位の領野ほど抽象度の高い情報を表現するようになる。認識時には、ベイジアンネットの機能により、最下端のノードに与えられた視覚刺激をもとに、ベイズの定理を用いて、目の前に自分が知っている文字や物体が存在する事後確率が計算される。最も高い事後確率を持つ文字あるいは物体が認識結果となる。

人間は物体を認識するときに、文脈によって認識結果が変わることが知られている。ベイジアンネットでは親ノードから子ノードに向けて文脈情報が送られるので、この脳の性質が説明できる。

BESOM によるパターン認識は、視覚野に関する神経回路モデルであるネオコグニトロン、およびそれにトップダウン信号を加えて拡張した SAM [5] の構造を定性的には踏襲しているが、ベイズを理論的背景として持つ点が異なっている。

6.2 推論

SOM は、複数の属性値の組を保持する関連データベースに似たものであり、それを使って様々な推論をすることができる。例えば図6のように、動物の名前、色、形、大きさという4つの属性の組を学習するノード R があるとすると、「うさぎの色は何色か?」という推論をするには、まず名前ノードに「うさぎ」という音素列を想起し、それと同時に色、形、大き

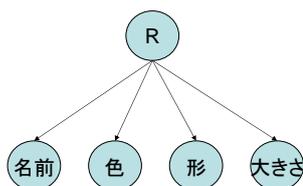


図 6: BESOM が表現する関連データベースの例。

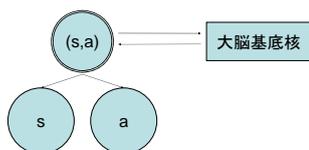


図 7: BESOM を用いた強化学習。運動野の領野は、強化学習における状態行動対を学習する。それと同時に、大脳皮質 - 基底核ループによって、状態行動対の価値の学習と、ある状態において最も価値の高い行動の選択が行われる。

さのノードへのボトムアップの入力を選択的注意の機構により遮断すればよい。ベイジアンネットの機能により、ノード R に記憶されている情報を通して、うさぎの色のイメージが、色のノードに想起される。

「うさぎの色と同じ色の動物は名前は何?」という推論をしたければ、色のイメージを保持したまま、R を経由して名前のノードに情報が想起されるように、情報の流れをなんらかの方法で制御すればよい。

このように、2つの層の双方向の情報の流れを適切に制御することによって、記号処理とパターン処理の両方の特徴を兼ね備えた、人間に似た推論が実現可能になる。このことは、PATON [6] という神経回路モデルですでに示されている。BESOM も、選択的注意等によって適切に情報の流れを制御する機構を追加すれば、PATON と同じ能力を発揮できると思われる。

6.3 運動野による行動獲得

BESOM と強化学習を組み合わせることができる (図 7)。運動野に相当するノードは、強化学習における状態行動対を学習すると考える。すなわち、運動野の SOM は、現在の状態と、現在行った行動の組を圧縮して学習する。それと同時に、状態行動対の価値も大脳基底核を用いて別途学習する。行動選択の際には、現在の状態の認識結果をもとに、最も価値のある状態行動対を選択し、対応する行動を「想起」すればよい。

これは、大脳皮質 - 基底核ループの強化学習に関する銅谷のモデル [7] に、大脳皮質の役割を加えて拡張したものになっており、神経科学的妥当性の高いモデルである。

実際の運動野周辺は図 7 よりもより複雑で特徴的な構造を持っているが、その意味についても BESOM モデルを用いて定性的に理解することができる [2]。

6.4 時系列学習

BESOM ネットに、各ノードの過去の認識結果を値として持つ特殊な子ノードを付加すれば、エルマンネットと同様、時系列学習が可能になるだろう。

解剖学的には 5.1 節で述べたように、情報処理の結果を出力する 5 層の情報に 6 層を経由して入力を受け取る 4 層に再帰的に戻っていくという構造が知られており、これが時系列学習のための構造ではないかと筆者は推測している。

6.5 前頭前野による行動計画

人間は、外界がある状態 s のときにある行動 a をとると外界が新しい状態 s' に変化することを、過去の経験に基づいて予測することができる。これは、SOM が (s, s', a) の三つ組を学習することで可能になる。この状態変化予測機構は、BESOM に少し拡張を施すことで実現可能である [2]。

この機構を使えば、頭の中で様々な行動の手順をシミュレーションし、最適な行動を見つけ出す「行動計画」が可能になると思われる。行動計画は、前頭前野が行う重要な働きの一つである。

また、部分観測マルコフ決定過程において見えない状態を推定するのも役立つものと思われる。

7. まとめ

BESOM モデルにより、脳による情報処理のかなり具体的なイメージが、明らかになりつつある。

この神経回路モデルは計算機上で効率的に実行可能であると考えており、工学応用の面でも有望である。筆者は現在、計算機シミュレーションに向けてモデルの詳細化に取り組んでいる。このモデルにより、人と同じような知能を持ったロボットの実現が現実のものになりつつあると考える。

多くの研究者が本論文および [2] で述べられている内容の有望さを理解し、まだ残されている未解決の問題に取り組み始めることで、脳の情報処理原理の実用化が一日でも早く実現することを期待する。

参考文献

- [1] Yuuji ICHISUGI, The cerebral cortex model that self-organizes conditional probability tables and executes belief propagation, In Proc. of International Joint Conference on Neural Networks (IJCNN2007), pp.1065-1070, Aug 2007.
- [2] 一杉裕志、「脳の情報処理原理の解明状況」産業技術総合研究所テクニカルレポート AIST07-J00012, Mar 2008.
<http://staff.aist.go.jp/y-ichisugi/besom/AIST07-J00012.pdf>
- [3] Pandya, D.N. and Yeterian, E.H., Architecture and connections of cortical association areas. In: Peters A, Jones EG, eds. Cerebral Cortex (Vol. 4): Association and Auditory Cortices. New York: Plenum Press, 3-61, 1985.
- [4] Gilbert, C.D., Microcircuitry of the visual-cortex, Annual review of neuroscience, 6: 217-247, 1983.
- [5] K. Fukushima, Neural network model for selective attention in visual-pattern recognition and associative recall, APPLIED OPTICS 26 (23): 4985-4992 Dec 1 1987.
- [6] T. Omori et al., Emergence of symbolic behavior from brain like memory with dynamic attention, Neural Networks 12 (7-8): 1157-1172 Oct-Nov 1999.
- [7] K. Doya, Complementary roles of basal ganglia and cerebellum in learning and motor control, Current Opinion in Neurobiology 10 (6): 732-739 Dec 2000.