

BESOM モデルとスパース符号化モデルの比較

Comparison of BESOM Model and Sparse Coding Model

一杉 裕志 (P)[†]

Yuuji ICHISUGI(P)

[†] 産業技術総合研究所 脳神経情報研究部門

y-ichisugi@aist.go.jp, <http://staff.aist.go.jp/y-ichisugi/>

Abstract— Similarity of two cerebral cortex models, BESOM model and sparse coding model, is discussed.

Keywords— BESOM model, sparse coding, generative model, SOM, Bayesian network

1 はじめに

Olshausen and Field は、自然画像に対するスパース符号化により、一次視覚野の単純型細胞の応答特性を定性的に再現できることを示した [4]。

一方、筆者は BESOM モデル [5][6] と呼ぶ大脳皮質の神経回路モデルを提案している。このモデルは、ヒトの大脳皮質が約 20 万個のノードからなるベイジアンネット [2] であることを主張するもので、大規模シミュレーションは動いていないが、神経科学的・計算論的に高い妥当性がある。

2つのモデルはまったく異なる立場から独立に見いだされたものであるが、いずれも真の大脳皮質モデルの近似であって、それぞれを変形することで統合可能であると思われる。本稿では、2つのモデルが本質的な類似点を持つ上、BESOM モデルがいくつかの点でスパース符号化モデルの拡張とみなせることを指摘する。

2 スパース符号化モデル

スパース符号化では、下記式のように符号ベクトル $y(t)$ から入力ベクトル $x(t)$ を生成する生成モデルを仮定する。

$$x(t) = Ay(t)$$

そして、符号ベクトル $y(t)$ の各要素ができるだけ 0 に近い値をとるように、行列 A を入力サンプル集合 $x(t)$ ($t = 1, \dots, N$) から求める。

スパース符号化は、特徴抽出、データ圧縮、ノイズ除去の目的で用いることができる [3]。また、もし脳がスパース符号化を行うならば、少ないニューロン発火で情報を表現できることになり、エネルギー消費を抑えられるという利点もある。

自然画像に対してスパース符号化を適用したときに基底ベクトル（行列 A の各列のベクトル）が持つ方位選択性などの特徴が、神経科学的によく知られていた一次視覚野の単純型細胞の応答特性と非常によく一致す

ることが示されており [4]、大脳皮質がスパース符号化かそれに似たことを行っていることは間違いないと思われる。

3 BESOM モデル

BESOM モデルは、BESOM ネットと呼ぶ神経回路ネットワークを用いた大脳皮質のモデルである。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)[3] 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) [1] 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が持つ意味は、SOM によって獲得される。

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。

BESOM モデルと大脳皮質の構成要素を対応づけると、基底の階層は領野の階層、ノードは直径 1mm 程度のハイパーコラム、ユニットはコラム、結合の重みはシナプスの重みに相当する。

4 2つのモデルの類似点

4.1 生成モデル

2つのモデルは、いずれも信号源から入力信号が生成される過程をモデル化する「生成モデル」と呼ばれるものである。生成モデルは、入力データから信号源の状態を推定するだけでなく信号源の状態から入力データを予測することも可能であり、大脳皮質が有する双方向性の機能的・解剖学的特徴をうまく説明することができる。

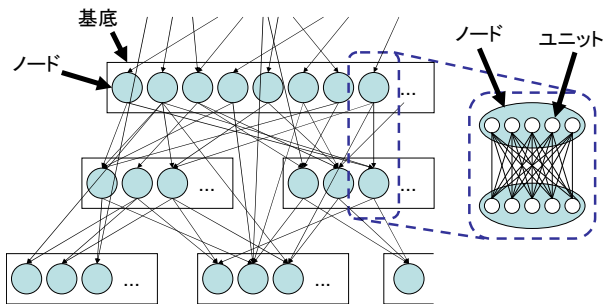


図 1: BESOM ネットの構成要素。四角は基底、基底の中の丸はノード、ノードの中の白い丸はユニットを表す。

4.2 線形和による予測

BESOM モデルでは、主に計算量とメモリ量を減らす目的で、noisy-OR[2] モデルと呼ばれるタイプのベイジアンネットワークを仮定している。これは、条件付確率表が下記の性質を見たすモデルである。

$$P(X|U_1, \dots, U_m) = 1 - \prod_i (1 - P(X|U_i))$$

もし $P(X|U_i)$ が十分小さいなら、さらに以下のように近似できる。

$$P(X|U_1, \dots, U_m) \approx \sum_i P(X|U_i)$$

この近似式が成り立つと仮定すれば、トップダウンに予測される確率分布は、個々の親ノードが予測する確率分布の線形和になる [5][6]。

これは、スパース符号化モデルが基底ベクトルの線形和で入力ベクトルの値を近似することとよく似ている。ただし、値の線形和と確率分布の線形和では、その意味が全く違う点に注意する必要がある。たとえば値 0.1 と 0.2 を足せば 0.3 という値になるが、値 0.1 をピークに持つ確率分布と 0.2 をピークに持つ確率分布を足しても、0.3 をピークに持つ確率分布にはならない。

4.3 信号源どうしの独立性

スパース符号化モデルでは、信号源が最もスパースになるように学習が進むが、これは「優ガウス性の最大化」に基づく ICA を行っていると見ることができる。

一方 BESOM モデルも、基底内のノードが表す情報を ICA によって独立にする。

5 BESOM モデルによるスパース符号化モデルの拡張

BESOM モデルは、スパース符号化モデルをいくつかの点で拡張していると思なすことができる。

上に述べたように、BESOM モデルは値ではなく値の確率分布を扱っているため、確率的な生成モデルが表現できる。

また、BESOM モデルは 2 次元 SOM を使ってある種の非線形な生成モデルが表現できる。

多層化も BESOM モデルによる拡張の 1 つであり、2 層以上の階層的な生成モデルを表現できる。

6 今後

以上で述べたとおり、BESOM モデルはスパース符号化モデルと本質的な類似点を持つ上に、さまざまな点を拡張した、非常に表現力の高いモデルである。しかし一般に、学習モデルの表現力が上がるほど、学習すべきパラメタの数が増えて、過適合に陥りやすくなる。過適合を避けるためには、学習時に正則化を行って、パラメタの自由度を下げる必要がある。

脳は巧妙な正則化の方法を進化により獲得し、それにより過適合を避けて汎化性能を上げているはずである。したがって、その方法を明らかにしないと、脳が持つ極めて高い汎化性能は再現できない。脳が行っている正則化の方法は、神経科学的知見を踏まえた計算論的考察により、今後明らかになるだろう。

参考文献

- [1] T. コホネン, 自己組織化マップ (改訂版), シュプリンガー・フェアラーク東京, 2005.
- [2] J. Pearl, Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference, Morgan Kaufmann, 1988.
- [3] A. ビバリネン, E. オヤ and J. カルーネン, 詳解 独立成分分析, 東京電機大学出版局, 2005.
- [4] Olshausen BA, Field DJ, Emergence of simple-cell receptive field properties by learning a sparse code for natural images, NATURE 381 (6583): 607-609 JUN 13 1996.
- [5] 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.
- [6] 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>