

**科学研究費助成事業 研究成果報告書**

平成 30 年 6 月 20 日現在

機関番号：17601

研究種目：基盤研究(C) (一般)

研究期間：2014～2017

課題番号：26330280

研究課題名(和文)自己組織神経回路モデルによる情報表現の形成

研究課題名(英文)Formation of information representation in self-organizing neural networks

研究代表者

伊達 章 (Date, Akira)

宮崎大学・工学部・准教授

研究者番号：60322707

交付決定額(研究期間全体)：(直接経費) 3,600,000円

研究成果の概要(和文)：多層の神経回路モデルが Deep Learning とよばれ注目されている。ところが、うまくいく仕組みがよく分かっていない。教師付き学習の前に教師なし学習をすることが、どれほどいいかという問には簡単には答えられないが、自己組織のモデルが重要な役割を果たしていることは間違いない。また、自己組織のモデルは、可視化のためには2次元の表示がわかりやすいが、情報抽出という観点からは、多次元の構造を持っていてよい。多次元構造をもつモデルを用いた場合、低次元配列のモデルを用いる場合と比較し、どのような利点があるだろうか。本研究は、その手がかりを得ることを目的とし、いくつかの基本的なモデルの性質を解析した。

研究成果の概要(英文)：Interest in the study of deep learning (i.e., feedforward neural networks trained by error backpropagation) has grown remarkably in the last several years. Many researchers have emphasized the black box nature of neural networks. However, the fundamental issues of why and how they work well have not been clearly understood. Although it is not easy to understand the effect of pretraining the network by unsupervised learning before supervised learning, the unsupervised learning must play an important role. The model of unsupervised learning or self-organizing model usually have two dimensional structure, and it can have high dimensional structure from the view point of discovering the salient features. Here we have examined the various unsupervised algorithms appropriate for learning using both computer simulation and mathematical analysis.

研究分野：知能情報工学

キーワード：神経回路モデル 数理モデル 自己組織化 数理脳科学 ニューラルネットワーク 学習 情報表現

### 1. 研究開始当初の背景

本研究課題の申請時（2013年の秋）、多層の神経回路モデルを用いて学習する手法が Deep Learning とよばれ、注目されてはじめていた。その実体は、1986年に D.E. Rumelhart らにより提案されたバックプロパゲーションによる学習機械であるので、25年前にすでにあったと言える。層状の神経回路モデルが再び注目されているには理由があった。さまざまなパターン認識・識別のコンテストで、Deep Learning を用いた手法が優勝するようになっていたのである。では25年前とは、なにが違うのか。10層の回路を使う場合を考えよう。この回路に例題と答を与え、一挙に学習させても、うまく動かない。それは調節可能な回路のパラメータ（素子間の結合係数）の数が膨大であり、多数ある局所解の一つに収束してしまうためである。パラメータの初期値が最適解の比較的近くなければ、うまく動かない。ところが、2006年頃にブレークスルーが起きた（Hinton, G.E. & Salakhutdinov R.R. Reducing the dimensionality of data with neural networks. *Science* **313**, pp.504–507, 2006). 大きな回路を一挙に学習するのではなく、とりあえずパターン識別の問題は後にして、1段づつ順に、教師なし学習で、パラメータを調整していくのである。こうして回路のパラメータを大雑把に作り、最後に誤差逆伝搬法で学習してみると、高性能のパターン認識マシンが完成する。どうしてこれで高性能マシンが実現できるのか不明な点が多いが、事実として、多くのベンチマークタスクで従来手法を上回る性能を示していた。

25年前との違いは、まずは学習ということを忘れ、一層づつ順に、自己組織のモデルを使って回路のパラメータを、教師なし学習させる点であった。ただし、これは申請時の話で、現在（2018年の春）では、とくに事前の学習なしでも学習に成功するとされている。

### 2. 研究の目的

教師付き学習の前に教師なし学習をするという準備が、どれほどいいかという問には簡単には答えられないが、自己組織のモデルが重要な役割を果たしていることは間違いない。そこで、本研究では、いくつかの基本的な自己組織のモデルの性質を解析し、なぜ精度の高い機械が実現できるのか、その手がかりを得ることを目的とした。

### 3. 研究の方法

Deep Learning の発端は、Hinton らの制約付きボルツマンマシン（RBM）の研究である。ここでは、その研究に影響を受けて、我々が実施した研究を2つに絞って紹介する。




図1 トポグラフィックマッピング形成のモデル

#### (1) ボルツマンマシンを用いたトポグラフィックマッピング形成のモデル

約25年前に倉田耕治博士は、ボルツマンマシンを用いたトポグラフィックマッピング形成のモデルを提案した。ボルツマンマシンは、理論的には見通しがよいものの数値実験に膨大な時間がかかるという致命的な欠点があり、当時は、学習のダイナミクスを追いかけることができなかった。今もその欠点は変わらないが、回路の構造が2部グラフで表現されるRBMの場合、個々のニューロンを確率的に動作させることなく学習を進める方法が発見された（Hinton, G.E. & Salakhutdinov R.R., 2006). V層（入力）とH層の2層からなる倉田のモデル（図1）は、H層の各素子が側抑制型の結合をもつため、その学習アルゴリズムを適用できない。しかし「H層には孤立局在興奮パターンしか出現しない」という制約を付け加えれば、各素子を確率的に動作させることなく学習を進めることができる。本研究では学習のダイナミクスを追いかけ、計算機シミュレーションによりこのことを確かめた。

#### (2) 高次元自己組織化マップ




図2 競合的な隠れ素子をもつ3層神経回路

自己組織化マップ（SOM）は、多次元データを2次元の配列で表現できることから、外界の情報の可視化に利用されている。可視化のためには2次元の表示がわかりやすいが、情報抽出という観点からは、多次元の構造を持っていてよい。本研究では、多次元配列の構造をもつ神経場を用いた場合、どういった情報が自己組織で抽出されるのか、低次元配列の神経場を用いる場合と比較し、どのような利点があるのか、などについて考えた。

ここでは外から与えられた入出力関係を学習する競合的な隠れ素子をもつ3層神経回路を考えた(図2)。回路は、入力層、中間層、出力層の3層からなり、情報は入力層から中間層を経て出力層に伝えられる。中間層では、素子の活動がたがいに競合する回路を考えた。このような回路は新しいものではない。ここでは、具体的に、中間層として自己組織化マップ、ニューラルガスをを用いる場合を考えた。

学習は、入力層と中間層の結合(参照ベクトル)、および中間層と出力層の間の結合を変化させることによっておこなわれる。この3層回路の性能は、どのような表現が中間層に形成されるかにかかっている。本稿で紹介する研究では、入力層の素子数  $n_1 = 784(28 \times 28)$ 、中間層の素子数  $n_2$  を約100個に固定し、出力層として線形の素子から構成される回路を用いた( $n_3 = 10$ 個)。中間層として、しばしば用いられる1,2,3次元の配列構造をもつSOMだけでなく、20次元までの構造をもつSOMやニューラルガスを試し、その性能を比較した。

#### 4. 研究成果

##### (1) 主な成果

###### ① ボルツマンマシンを用いたトポグラフィックマップ形成のモデル

図3aは学習のダイナミクスを追いかけた学習経過の様子を示す数値実験の例である。V層が $8 \times 8$ の2次元、H層が16個の素子からなる1次元の構造をもっている。図にはH層(16個)の各素子がV層の各素子に対してもつ結合係数の強度を濃淡値で表現している。図3a、上部に学習前( $t = 0$ )、下に、学習後( $t = 20000$ )の様子を示している。図3bには、同条件でH層の素子数を2倍(32個)にした場合( $t = 20000$ )を示している。

入力としては、隣接する $3 \times 3 = 9$ 個の素子が同時に興奮するような信号(全部で64種類)を等確率で与え、H層には、連続する5個の素子が同時に興奮するような構造をもたせた。すなわち、1次元の神経場を使い、64次元空間に埋め込まれている2次元構造の抽出を試みた。その結果、入出力間に、2次元を1次元でカバーする連続的な写像が形成されることを確認した。



図3 学習経過の様子

###### ② 高次元自己組織化マップ

回路は、入力層、中間層、出力層、それぞれ、 $n_1 = 784$ 、 $n_2$ は約100個、出力層として $n_3 = 10$ 個の素子からなる回路を用いた。実験は、素子を等間隔に配置したSOM、素子をランダムに配置した

SOM、ニューラルガスの大きく3つに分けられる。具体的には、中間層として、約100個の素子が等間隔に位置する1次元から7次元の構造をもつSOM、100個の素子を、1~20次元の空間 $[0, 10^{\frac{2}{d}}]^d$ に一様乱数にしたがい配置したSOM、ニューラルガスをを用いた。

実験結果を表1、表2に示す。実験では、まず中間層の素子について10,000回の学習をおこない、そのあと、出力層の素子を30,000回、学習した。表1、表2には、学習に用いたデータ1,000枚に対する識別正解率、学習に用いていないデータ1,000枚に対する識別正解率を示している。素子を等間隔に配置する実験では、超立方体を構成する一辺の素子数が整数にならないため、素子の総数が100になっていない場合がある。たとえば3D-SOMの場合、素子数 $4 \times 4 \times 4 = 64$ もしくは、 $5 \times 5 \times 5 = 125$ で実験した。素子をランダムに配置する実験では、素子を配置する次元が $d$ の場合、 $[0, 10^{\frac{2}{d}}]^d$ の空間に一様乱数にしたがい配置した。たとえば10D-SOMの実験の場合、 $[0, 1.59]^{10}$ の空間に配置した。

表1 正解率(格子状配置)

回路の構造	素子数	訓練データ	評価データ
1D-SOM	100	82.7%	73.8%
2D-SOM	100	83.5%	73.7%
3D-SOM	64	80.7%	67.8%
3D-SOM	128	86.1%	74.5%
4D-SOM	81( $3^4$ )	81.8%	70.7%
4D-SOM	256( $4^4$ )	89.8%	74.8%
5D-SOM	32( $2^5$ )	70.5%	61.0%
5D-SOM	243( $3^5$ )	89.1%	72.6%
6D-SOM	64	78.4%	64.8%
7D-SOM	128( $2^7$ )	85.0%	73.6%
Neural GAS	100	83.8%	81.8%

表2 正解率(ランダム配置)

回路の構造	訓練データ	評価データ
1D-SOM	82.7%	71.6%
2D-SOM	83.3%	70.7%
3D-SOM	82.8%	69.9%
4D-SOM	83.0%	68.6%
5D-SOM	82.3%	69.8%
6D-SOM	85.3%	75.4%
7D-SOM	83.5%	70.8%
8D-SOM	81.5%	64.4%
9D-SOM	82.9%	69.4%
10D-SOM	82.2%	74.5%
15D-SOM	82.5%	68.8%
20D-SOM	81.0%	67.7%

各パラメータを、それぞれの構造をもつ回路で、識別率をもっとも高くなる値に設定することは簡単ではない。結果を解釈する際、この点に注意する必要があるが、評価データに対する識別正解率を見る

と、ニューラルガスが、もっとも性能がよいことが分かる。これは予想していた結果ではある。素子をランダム配置した SOM では、6次元の構造をもつ素子が、ほかに比べ、識別正解率が高かった。

## (2) 成果の国内外での位置付けと impact

入力として、ある確率分布を与えてボルツマンマシンを学習させた場合に、どのような結合ができるか知りたいときは、その分布を再現するような結合を人間があらかじめ探せばよい。このような視点をもつボルツマンマシンの研究はほとんど見あたらない。今回、30年前に提案された理論研究の有効性を示せた、と考えている。今後、RBMの考え方が使える、別の回路を発見・実現したい。

脳は2次元（もしくは3次元）の神経場とみることができ、人工知能システムとしての観点からは、より高次元のモデルを考えることは問題ではない。高次元の神経場については、本研究のように、系統的に調べる研究は著者の知る範囲では見当たらない。ただし、現在のところ、いわゆる次元の呪いの問題を解決する有効な手段を発見できておらず、残念ながら実験結果としてインパクトのある結果は示せていない。

## (3) 今後の展望

自己組織のモデルはたくさんある。それらのモデルに共通な面は多い。本報告書で示したモデルの性質は、AmariモデルやKohonenのモデルでも同様な事が示せる。結局、どのモデルを使っても大きな違いはないのではないか、という話をもっともである。ボルツマンマシンを使う利点は、理論的に取り扱いがしやすいことと、コンピュータの進歩により、微分方程式によるモデル化よりも、確率分布によるモデル化が応用に適していることにある。ただ、ボルツマンマシンの致命的欠陥が解決されたわけではない。超並列マシンである脳は、この点をどう解決しているのだろうか。数理脳科学の観点からはこれが気になる。

## 5. 主な発表論文等

### 【雑誌論文】(7件)

- [1] 伊達章: ニューラルネットが「分かる」とは: 暴力的ではないアプローチ, プログラミング・シンポジウム2016「教育・学習」報告集, pp.57-64, 2017. 査読無
- [2] 伊達章, 窪田光, 山田雄輔: 構成性システムとその手書き文字認識への応用について, 電子情報通信学会技術研究報告, vol.116, no.259, pp.19-24, 2016. 査読無
- [3] 伊達章, 倉田耕治: ボルツマンマシンと自己組織化, *Clinical Neuroscience*, vol.34, pp.885-

888, 2016.

- [4] 長谷泰宏, 伊達章: 多層線形神経回路における学習ダイナミクス, 火の国情報シンポジウム2016 講演論文集, no.6C-4, 2016. 査読無.
- [5] 伊達章, 窪田光, 山田雄輔: 構成性システムとその認識アルゴリズムについて, 火の国情報シンポジウム2016 講演論文集, no.4B-3, 2016. 査読無.
- [6] 伊達章, 朝長健, 倉田耕治: 2層連想記憶モデルの記憶負荷と形成される内部表現について, 第25回日本神経回路学会全国大会 (JNNS2015) 講演論文集, pp.72-73, 2015. 査読無.
- [7] 伊達章, 倉田耕治: 高次元自己組織化マップはパターン識別にどのくらい有効か, 第16回自己組織化マップ研究会2015 講演論文集, pp.4-1-4-4, 2015. 査読無.

### 【学会発表】(4件)

- [1] 伊達章: 構成性システムとその手書き文字認識への応用について, 電子情報通信学会パターン認識・メディア理解研究会 (PRMU), 宮崎大学 (宮崎県宮崎市) 2016年10月20日.
- [2] 伊達章: ニューラルネットが「分かる」とは: 暴力的ではないアプローチ, 夏のプログラミングシンポジウム2016, ホテル恵風 (北海道函館市), 2016年9月3日.
- [3] 伊達章: 2層連想記憶モデルの記憶負荷と形成される内部表現について, 第25回日本神経回路学会全国大会 (JNNS 2015), 電気通信大学 (東京都調布市), 2015年9月3日 (ポスター), 2015年9月4日 (口頭).
- [4] 伊達章: 高次元 SOM を用いたパターン識別, 第16回自己組織化マップ研究会2015, 呉工業高等専門学校 (広島県呉市), 2015年3月21日.

## 6. 研究組織

### (1) 研究代表者

伊達章 (DATE, Akira)  
宮崎大学・工学部・准教授  
研究者番号: 60322707

### (2) 連絡研究者

倉田耕治 (KURATA, Koji)  
琉球大学・工学部・教授  
研究者番号: 40170071