

ゆとりニューラルネットワークの学習プロセスによって形成される 重みベクトルの類似性に関する研究

上手 洋子[†] 西尾 芳文[†]

[†] 徳島大学大学院ソシオテクノサイエンス研究部

〒 770-8506 徳島市南常三島 2-1

E-mail: †{uwate, nishio}@ee.tokushima-u.ac.jp

あらまし 我々はこれまでに、セルアセンブリ機能を階層型ニューラルネットワークの中間層に応用したゆとりニューラルネットワークを提案している。本ネットワークに逆誤差伝播法を適用し、関数近似およびパターン認識問題について学習を行った場合、従来のネットワークより学習能力および汎化能力が優れていることを確認している。しかしながら、ゆとりニューラルネットワークのどのような学習プロセスが、よい性能を生み出すかといった原因は明らかにされておらず、より詳細な調査が必要である。そこで本研究では、重みの変化量および学習後の重みの類似度に着目する。コンピュータシミュレーションの結果、ゆとりニューラルネットワークは従来のネットワークに比べ重みの変化量が多く、学習後の重みの類似度は低いことが分かった。

キーワード ゆとりニューラルネットワーク、ベクトル類似性、逆誤差伝播法、パターン認識

Weight Vector Similarity of Affordable Neural Network by Learning Process

Yoko UWATE[†] and Yoshifumi NISHIO[†]

[†] Tokushima University 2-1 Minami Josanjima, Tokushima, 770-8506 Japan

E-mail: †{uwate, nishio}@ee.tokushima-u.ac.jp

Abstract We have recently proposed a novel neural network structure called an “Affordable Neural Network” (AfNN), in which affordable neurons of the hidden layer are considered as cell assembly function observed in human brain function. We have confirmed that the AfNN gains good performance both of the generalization ability and the learning ability. Furthermore, the AfNN has durability, because the AfNN still performs well even if some of neurons in the hidden layer are damaged after learning process. In this study, we study the characteristics of weights of the AfNN during the learning process to make clear the reason of that the AfNNs can perform well for learning and generalization abilities and operate as usually against damaging neurons.

Key words Affordable Neural Network, Vector Similarity, Backpropagation Learning, Pattern Recognition

1. Introduction

近年の脳神経科学の飛躍的な発展に伴い、これまで明らかにされていなかったさまざまな脳の高次機能が明らかになってきている。そのため、生物学モデルを取り入れた人工ニューラルネットワークの研究も盛んに行われている。しかしながら、実際の生物ネットワークと生物モデルを応用した人工ニューラルネットワークにはまだ大きなギャップが存在する。我々は、そのギャップを少しでも埋めていくことで、より複雑な高次機能を備えた人工ニューラルネットワークの実現が可能になると考えている。

我々はこれまでの研究で、BP 学習を行う階層型ニューラルネットワークの中間層にゆとりニューロンを持たせたゆとりニューラルネットワーク (ゆとり NN) を提案している [1]。コンピュータシミュレーションの結果、ゆとり NN が従来のネットワークよりも学習能力および汎化能力が優れていることを確認した。また、学習後に中間層ニューロンの一部にダメージを与えた場合についても調査を行い、ゆとり NN は性能を保持できることも確認している [2]。

しかしながら、ゆとり NN のどのような特徴が学習能力や耐久性の良さに影響しているのかについては明らかにしていない。そこで、本研究ではゆとり NN の中間層ニューロンの重みの変

化量と重みベクトルの類似性について調査を行う。コンピュータシミュレーションの結果、ゆとりニューラルネットワークは従来のネットワークに比べ重みの変化量が多く、学習後の重みの類似度は低いことが分かった。

2. ゆとりニューラルネットワーク (ゆとり NN)

我々はこれまでに、3層階層型ニューラルネットワークの中間層にゆとりニューロンを持たせたゆとりニューラルネットワーク (ゆとり NN) を提案している [1]。ゆとり NN の中間層では、すべてのニューロンが動作するのではなく、いくつかのニューロンは正常に学習を行うが、残りのニューロンはゆとりニューロンとして選択される。ゆとりニューロンの特徴は以下のとおりである。

- ゆとりニューロンの出力はゼロとする。
- ゆとりニューロンと結合している重みベクトルは更新しない。

なお、本研究では、ゆとりニューロンの選択はランダムに行う。ゆとり NN モデルを図 1 に示す。




図 1 ゆとり NN モデル。

3. 重みの変化量

まず、ゆとり NN のどのような特徴が学習能力の良さに影響しているのかについて調査を行う。ここでは、ゆとり NN に BP 学習を適応させたときの、ゆとり NN の中間層と出力層間の重みの変化量に着目する。BP 学習は、ラメルハートによって提案された標準 BP を用いる [4]。重みベクトルの更新式は以下のように表される。

$$w_{i,j}^{k-1,k}(m+1) = w_{i,j}^{k-1,k}(m) + \sum_{p=1}^P \Delta_p w_{i,j}^{k-1,k}(m), \quad (1)$$

$$\Delta_p w_{i,j}^{k-1,k}(m) = -\eta \frac{\partial E_p}{\partial w_{i,j}^{k-1,k}},$$

ここで、 m は学習回数、 η は学習係数を示す。本研究では、以下の式で示される慣性項付き重み更新式を適用する。

$$\Delta_p w_{i,j}^{k-1,k}(m) = -\eta \frac{\partial E_p}{\partial w_{i,j}^{k-1,k}} + \zeta \Delta_p w_{i,j}^{k-1,k}(m-1), \quad (2)$$

ここで ζ は慣性項のパラメータである。

次に、BP 学習の基礎的な例として、 $y(x) = x^2$ の関数近似を行ったときの性能評価について述べる。本問題において、入力データの範囲は $[-1.0, 1.0]$ とし、サンプリング幅は 0.01 とした。シミュレーションにおいて、学習係数および慣性項パラメータはそれぞれ $\eta = 0.1$ 、 $\zeta = 0.01$ に設定し、重みの初期値は $[-1, 1]$ の乱数を与えた。また学習係数は、 $M = 20000$ である。

学習能力の性能を評価するために、“Average Error E_{ave} ” を以下の式によって提案する。

$$E_{ave} = \frac{1}{P} \sum_{p=1}^P \left\{ \frac{1}{2} (t_p - o_p)^2 \right\} \quad (3)$$

ここで、 P は入力データの数である ($P = 200$)。

図 2 に中間層ニューロンの総数は 8 個とし、ゆとりニューロンの数を 1~4 個に変化させたときの学習エラー曲線を示す。この図より、ゆとりニューロン数が 3 個以下の場合には、ゆとり NN が従来のネットワークよりも小さい誤差に収束している。このように、ゆとりニューロン数を適切に設定することで、ゆとり NN は従来のネットワークよりもよい学習能力を得られることがわかる。

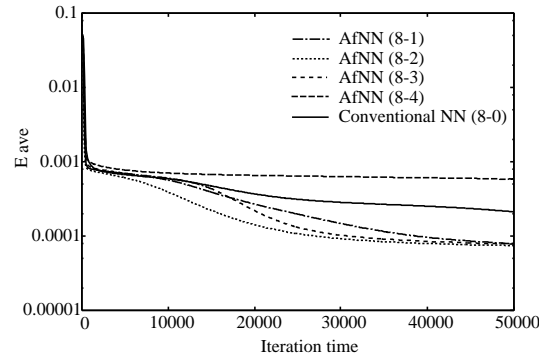


図 2 学習曲線。

ゆとり NN のどのような特徴が学習能力の良さに影響しているのかについて調査を行うために、本章では、学習プロセス中の重みの変化量に着目する。

中間層と出力層間の重みベクトルの変化量を以下の式で定義する。

$$C_{i,j}^{k-1,k} = \frac{1}{M} \sum_{m=1}^M \left| \sum_{p=1}^P \Delta_p w_{i,j}^{k-1,k}(m) \right| \quad (k=3). \quad (4)$$

図 3 に重みベクトルの変化量のシミュレーション結果を示す。この図は、変化量を簡単に理解するために学習後、それぞれのネットワークにおいて重みの変化量によって小さい順にソートした結果である。この図より、ゆとり NN のほうが従来のネットワークよりも重みの変化量が多いことがわかる。次に、重みベクトルの変化量の平均と学習能力の関係を表 1 にまとめた。ゆとりニューロンが 2 個のときに、最もよい学習性能を得ることが確認できる。

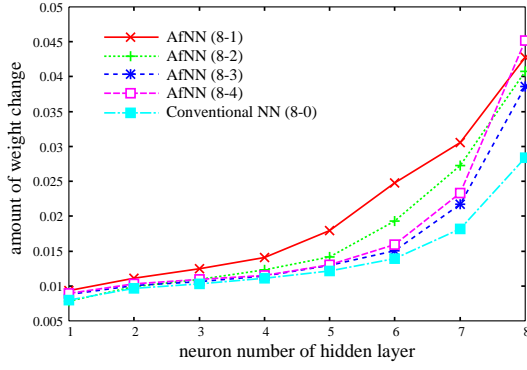


図3 重みの変化量.

表1 Total amount of weight change and E_{ave} (average: 100).

Network type	$\sum_{h=1}^8 C_{i,j}$	Eave
AfNN (8-1)	0.16305	0.624e-3
AfNN (8-2)	0.14237	0.562e-3
AfNN (8-3)	0.12916	0.586e-3
AfNN (8-4)	0.13918	0.679e-3
Conv. NN (8-0)	0.11161	0.626e-3

4. 重みベクトル類似性

次に、ゆとり NN の耐久性の要因を明らかにするために、学習後の重みベクトルの類似性について調査を行う。

学習後、ある中間層ニューロンの出力をゼロにすることでダメージを与える。図4に、2章と同様の $y = x^2$ を学習させた後に、ダメージを与えたときの性能結果を示す。この図より、ゆとり NN、従来ネットワークともにダメージのニューロン数が多くなるほど性能が悪くなっているのがわかる。しかし、性能はゆとり NN のほうがより小さい誤差を示していることが確認できる。

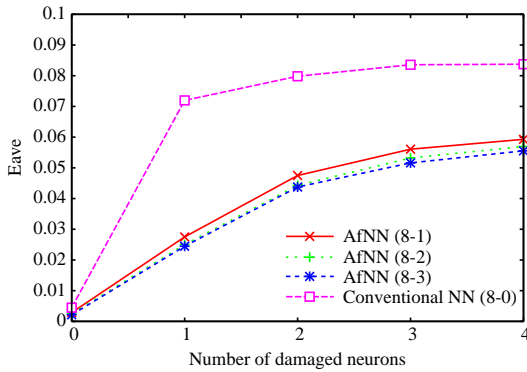



図4 ダメージに対する E_{ave} の結果.

次に、ゆとり NN の持つ耐久性のメカニズムを明らかにするために、学習後の重みベクトルの類似性について調査を行う。3層階層型ニューラルネットワークにおいて、 $y = x^2$ を学習する場合、出力層のニューロン数は1個である。よって、中間層の i 番目のニューロンの重みベクトルは以下の式のように表現できる。

$$\mathbf{w}_{i,j}^{2,3} = \{w_{i,1}^{2,3}, w_{i,b}^{2,3}\}, \quad (5)$$

ここで、 $w_{i,1}^{2,3}$ は中間層の i 番目のニューロンから出力層の1番目のニューロンへの重みを表す。また、 $w_{i,b}^{2,3}$ は中間層の i 番目のニューロンのバイアスである。

図5にゆとり NN と従来ネットワークの典型的な重みベクトルの結果を示す。ゆとり NN の場合 (Fig. 5 (a)), それぞれの重みベクトルがベクトルスペース全体に広がっている。それに対して従来ネットワークの場合 (Fig. 5 (b)), 多くの重みベクトルが同じ方向を示している。



(a) AfNN (8-4).

(b) Conventional NN (8-0).

図5 学習後の重みベクトル分布 (Hidden layer: 8) .

我々は、図5のベクトル図の特徴を評価するために、以下の式で示される Cosine similarity を用いる。

$$W_{s(a,b)} = \cos(\theta) = \frac{\mathbf{w}_{a,j} \cdot \mathbf{w}_{b,j}}{\|\mathbf{w}_{a,j}\| \|\mathbf{w}_{b,j}\|} \quad (6)$$

ゆとり NN および従来ネットワークの100回平均のベクトル類似性および行列のノルムを以下の行列に示す。

ゆとり NN のベクトル類似性 *AfNN (8-4)*:

$$W_s = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \\ 7 \\ 8 \end{matrix} & \begin{pmatrix} \mathbf{1.00} & 0.24 & 0.18 & 0.12 & 0.26 & 0.24 & 0.15 & 0.21 \\ 0.24 & \mathbf{1.00} & 0.25 & 0.26 & 0.40 & 0.34 & 0.28 & 0.40 \\ 0.18 & 0.25 & \mathbf{1.00} & 0.20 & 0.35 & 0.32 & 0.23 & 0.33 \\ 0.12 & 0.26 & 0.20 & \mathbf{1.00} & 0.31 & 0.20 & 0.07 & 0.18 \\ 0.26 & 0.40 & 0.35 & 0.31 & \mathbf{1.00} & 0.48 & 0.34 & 0.36 \\ 0.24 & 0.34 & 0.32 & 0.20 & 0.48 & \mathbf{1.00} & 0.24 & 0.29 \\ 0.15 & 0.28 & 0.23 & 0.07 & 0.34 & 0.24 & \mathbf{1.00} & 0.26 \\ 0.21 & 0.40 & 0.33 & 0.18 & 0.36 & 0.29 & 0.26 & \mathbf{1.00} \end{pmatrix} \end{matrix}$$

Norm of similarity matrix: **3.526**

従来ネットワークのベクトル類似性 *Conventional NN (8-0)*:

$$W_s = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \\ 7 \\ 8 \end{matrix} & \begin{pmatrix} \mathbf{1.00} & 0.43 & 0.38 & 0.43 & \mathbf{0.51} & 0.40 & 0.38 & 0.45 \\ 0.43 & \mathbf{1.00} & 0.40 & \mathbf{0.51} & 0.49 & 0.42 & 0.42 & 0.46 \\ 0.38 & 0.40 & \mathbf{1.00} & 0.49 & \mathbf{0.59} & \mathbf{0.55} & 0.47 & 0.44 \\ 0.43 & 0.51 & 0.49 & \mathbf{1.00} & \mathbf{0.62} & 0.42 & 0.34 & 0.39 \\ \mathbf{0.51} & 0.49 & \mathbf{0.59} & \mathbf{0.62} & \mathbf{1.00} & \mathbf{0.56} & 0.44 & 0.45 \\ 0.40 & 0.42 & \mathbf{0.55} & 0.42 & \mathbf{0.56} & \mathbf{1.00} & \mathbf{0.50} & 0.40 \\ 0.38 & 0.42 & 0.47 & 0.34 & 0.44 & \mathbf{0.50} & \mathbf{1.00} & 0.40 \\ 0.45 & 0.46 & 0.44 & 0.39 & 0.45 & 0.40 & 0.40 & \mathbf{1.00} \end{pmatrix} \end{matrix}$$

Norm of similarity matrix: **4.447**

これらの行列では、すべてのベクトルの組み合わせ W_s を計算した結果である。従来ネットワークのほうがゆとり NN に比

べて、ベクトル類似性の値が大きい値を示している。つまりこれは、従来ネットワークによって学習した中間層ニューロンの重みベクトルがよく似たベクトルであることを意味している。行列全体の評価を行うために、ノルムを行列の下に表記してあるが、従来ネットワークのほうがノルムも大きい値になっている。

これらの結果から、ゆとり NN の場合は中間層ニューロンのそれぞれの重みベクトルは異なる特徴になるように学習が行われる。これは、ゆとりニューロンが毎更新時に切り替わるためであると考えられる。

5. パターン認識におけるベクトル類似性

本章では、より一般的な問題としてパターン認識を行うゆとり NN のベクトル類似性について調査を行う。今回対象とするパターン認識は、図 6 に示す 4 つのアルファベット B, U, C, S である。入力層のニューロン数は 35, 出力層のニューロン数は 4 となる。これまでの研究でゆとり NN がパターン認識においても、すぐれた認識率を持つことを確認している (図 7)。




図 6 パターン認識。

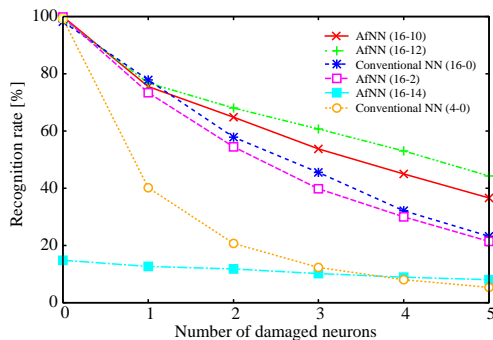


図 7 ダメージに対する認識率。

本パターン認識の場合、中間層ニューロンの重みベクトルは以下の式で表される。

$$\mathbf{w}_{i,j}^{2,3} = \{w_{i,1}^{2,3}, w_{i,2}^{2,3}, w_{i,3}^{2,3}, w_{i,4}^{2,3}, w_{i,b}^{2,3}\}, \quad (7)$$

表 2 に重みベクトル類似性の行列から得られたノルムの結果をまとめた。ゆとり NN のノルムは従来ネットワークよりも小さい値であることがわかる。これは、先ほどの $y = x^2$ を学習させた場合と同じ結果である。

最後に、ベクトル類似性のノルムと認識率の関係についてまとめたものを図 8 に示す。ゆとりニューロン数の増加に伴いノルムの値が小さくなると、ダメージを受けた場合の認識率が向上することが確認できる。

表 2 Norm of similarity matrix.

Network type	Norm
AfNN (16-2)	5.151
AfNN (16-4)	4.823
AfNN (16-6)	4.505
AfNN (16-8)	4.273
AfNN (16-10)	4.108
Conventional NN (16-0)	5.253

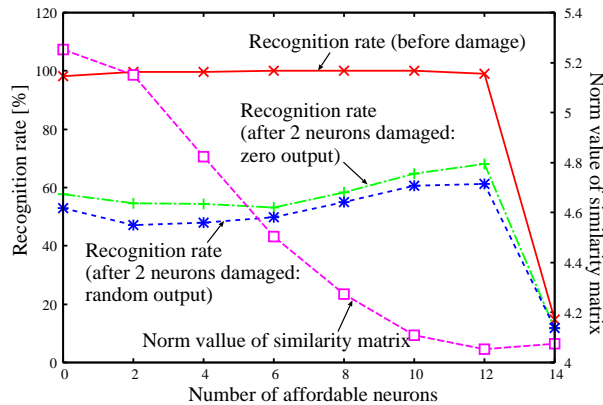


図 8 重みベクトル類似性のノルムと認識率の関係。

6. Conclusions

本研究ではゆとり NN の中間層ニューロンの重みの変化量と重みベクトルの類似性について調査を行った。コンピュータシミュレーションの結果、ゆとりニューラルネットワークは従来ネットワークに比べ重みの変化量が多く、学習後の重みの類似度は低いことが分かった。

文 献

- [1] Y. Uwate and Y. Nishio, "Performance of Affordable Neural Network for Back Propagation Learning," *IEICE Transactions on Fundamentals*, vol. E89-A, no. 9, pp. 473-478, Nov. 2005.
- [2] Y. Uwate, Y. Nishio and R. Stoop, "Durability of Affordable Neural Networks against Damaging Neurons," *IEICE Transactions on Fundamentals*, vol. E92-A, no. 2, pp. 585-593, Feb. 2009.
- [3] Y. Sakurai, "Dependence of Functional Synaptic Connections of Hippocampal and Neocortical Neurons on Types of Memory," *Neuroscience Letters*, vol. 158, pp. 181-184, 1993.
- [4] D.E. Rumelhart, G.E. Hinton and R.J. Williams, "Learning Internal Representations by Error Propagation," *Parallel Distributed Processing*, vol. 1, MIT Press, MA, pp. 318-362, 1986.