

# 多入力ニューラルネットの学習過程における中間層ニューロン数の影響

大分大学大学院 ○幸和芳 柴田克成

Effect of the number of hidden neurons in the learning of a layered neural network  
with a large number of inputs

Kazuyoshi Yuki and Katsunari Shibata, Oita University

Abstract: In this paper, it is shown through some simulations of the learning of robot behavior that in a three-layer neural network with a large number of input, learning becomes stable when the number of hidden neurons is increased. It is suggested from the simulation that that is because the weight values from the hidden layer to the output layer become small by the increase of the number of hidden neurons, and accordingly the propagated error of each hidden neuron becomes small.

## 1 まえがき

階層型ニューラルネットは、誤差逆伝播 (Back Propagation, BP) 法を適用することにより非線形関数近似能力を有し、画像認識、ロボットの制御など、幅広い分野で広く使われるようになってきている。今後、実世界でロボットの学習を行うなど、扱う問題が複雑になればなるほど、入力信号の数も増え、大規模なニューラルネットの使用が求められると考えられる。そのような中で、ニューラルネットの中間層ニューロン数を無限個用意すれば、どんな関数近似も理論的に学習が可能であることが示されている [1]。しかしながら、入力信号数や中間層ニューロン数が増加したときの学習過程における安定性や学習速度などの議論はあまり進んでいない。

一方、著者らは、与えられたタスクに対する適切な行動をロボットに学習させる際に、視覚センサ信号を始めとするセンサ信号に対して前処理をあえてせず、直接ニューラルネットに入力し、出力をモータ信号として用い、そのニューラルネットを強化学習に基づいて学習することを提案してきた [2]。これにより、中間層において自律的に連続的な状態空間を形成し、行動だけでなく、認識や記憶などまで含めたセンサからモータまでの全ての過程を合目的的、協調的に学習させることを提案してきた。そして、モノクロの視覚付き移動ロボットの目標物到達タスクや物体を押すタスクに適用し、シミュレーションや実機において、画像処理やタスクに関する事前知識を与えずに学習できることを確認した [2]。

これらのシミュレーションでは、視覚センサ信号を入力としているため、入力信号数は 1000 以上であった。入力信号数が増加すると、1 回の学習によって、その前後で同じ入力信号を入力したとしても、中間層ニューロンへの入力が大きく変化し、学習が不安定になることが危惧された。しかし、実際に学習を行うと、安定して学習できることが確認された。

筆者らは、このように、多入力にもかかわらず学習が

安定して行われることの原因として、中間層ニューロン数が多いと、BP 法に基づく学習における中間層の伝播誤差  $\delta$  が小さくなるためではないかという仮説を置いた。

本研究では、ロボットの行動学習を例として、この仮説を検証し、多入力時において、中間層ニューロン数が学習に与える影響を明らかにすることを目的とする。

## 2 多入力時の学習安定性

### 2.1 入力信号数の影響

はじめに、入力信号数が学習に与える影響について考える。ここで扱うニューラルネットは、各ニューロンにおいて、入力信号を  $x_i$  ( $i = 1, 2, \dots, N$ ) とし、その入力信号に対する重み値を  $w_{j,i}$  とすると、その内部状態  $u_j$  は、

$$u_j = \sum_{i=1}^N w_{j,i} x_i \quad (1)$$

と計算される。出力  $x_j$  は、内部状態  $u_j$  から非線形変換  $f$  を通し、

$$x_j = f(u_j) \quad (2)$$

と計算される。また、非線形変換  $f$  として、ここでは、

$$f(u_j) = \frac{1}{1 + e^{-u_j}} \quad (3)$$

と 0 から 1 の値域を持つシグモイド関数を用いた。

BP 法において、中間層の伝播誤差を  $\delta_j$ 、学習係数を  $\eta$  とおいた時の重みの更新値  $\Delta w_{j,i}$  は、

$$\Delta w_{j,i} = \eta \delta_j x_i \quad (4)$$

となる。したがって、学習後に同じ入力信号  $x_i$  を与えた時の中間層ニューロンの内部状態の変化量  $\Delta u$  は、式 (1)、(4) より、

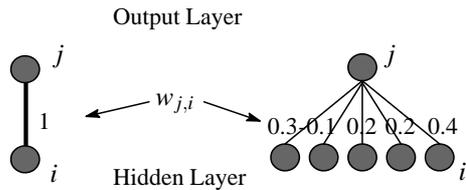
$$\Delta u_j = \sum_{i=0}^N \Delta w_{j,i} x_i = \eta \delta_j \sum_{i=0}^N x_i^2 \quad (5)$$

となる。ここで、 $x_i^2 \geq 0$  より、一般に、入力ニューロン数が多くなると  $\Delta u$  も大きくなる。つまり、入力ニュー

ロン数が多くなれば学習が不安定になる。また、学習が不安定になり、いったん入力  $u$  の絶対値が大きくなると、ニューロンの出力関数であるシグモイド関数の微分値がほぼ 0 になり、学習が進まなくなる。ただし、入力信号のほとんどが 0 である場合や入力信号の絶対値が小さい場合は、学習に与える影響は小さくなる。

## 2.2 中間層ニューロン数の影響に関する仮説

次に、中間層ニューロン数が学習に与える影響について本研究で立てた仮説について説明する。



(a) One hidden neuron (b) Some hidden neurons whose excitation patterns are the same.

Fig. 1 An example of expected weight values according to the number of hidden neurons

中間層ニューロン数が増えて冗長になれば、同じような働きをするニューロンが増えると考えられる。例えば、Fig.1 に示した例のように、同じ働きをする中間層ニューロン数が増えると、通常、初期重み値は微小であるため(本論文のシミュレーションでは、中間層と出力層間の初期重み値は 0 としている)、一般的に、上位ニューロンとの重み値の絶対値が小さくなると考えられる。また、伝播誤差  $\delta_i$  は、上位のニューロンの伝播誤差  $\delta_j$  から

$$\delta_i = f'(u_i) \sum_j w_{j,i} \delta_j \quad (6)$$

と求められるため、 $|w_{j,i}|$  が小さくなれば  $|\delta_i|$  の期待値も小さくなると考えられる。

## 3 強化学習によるロボットの行動学習

本研究でシミュレーションを行ったロボットの行動学習について述べる。

Fig.2 のように、視覚センサ信号を多数の入力信号として直接ニューラルネットに入力し、ニューラルネットの出力をモータへの出力信号とする。そして、強化学習のアルゴリズムに基づいてニューラルネットの教師信号をロボット内部で生成し、学習を行う。

強化学習は Actor-Critic の構成とした。ニューラルネットの出力の 1 つを Critic (状態評価値)、残りを Actor (動作生成部) とした。Critic の学習には、一般的な TD (Temporal Difference) 型の学習を用いた。

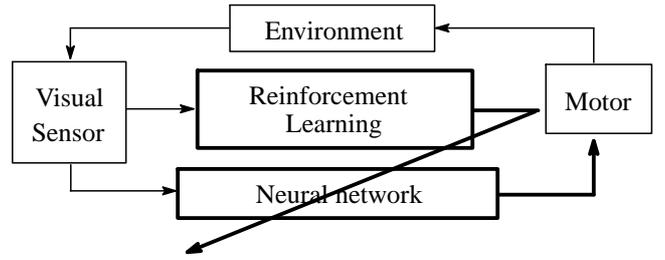


Fig. 2 Architecture for the learning of robot behavior in this paper

現在のセンサ信号  $\mathbf{x}_t$  から求められる Critic の出力  $P(\mathbf{x}_t)$  と 1 単位時間前の Critic の出力  $P(\mathbf{x}_{t-1})$  から計算される TD 誤差  $\hat{r}_{t-1}$  を

$$\hat{r}_{t-1} = r_t + \gamma P(\mathbf{x}_t) - P(\mathbf{x}_{t-1}) \quad (7)$$

と求める。ここで、 $r_t$  は報酬、 $\gamma$  は割引率である。そして、TD 誤差を減少させるように、1 単位時間前の Critic の出力  $P(\mathbf{x}_{t-1})$  に対し、教師信号

$$P_{s,t-1} = \hat{r}_{t-1} + P(\mathbf{x}_{t-1}) = r_t + \gamma P(\mathbf{x}_t) \quad (8)$$

によって、BP 法で学習していく。

一方、Actor (動作生成部) の出力  $\mathbf{a}(\mathbf{x}_t)$  に試行錯誤のための微小乱数  $\mathbf{rnd}_t$  を加えたものを実際の行動とし、

$$\mathbf{a}_{s,t-1} = \mathbf{a}(\mathbf{x}_{t-1}) + \hat{r}_{t-1} \mathbf{rnd}_{t-1} \quad (9)$$

を教師信号として BP 法で Actor を学習していく。これによって、 $\hat{r}$  が大きいと  $\mathbf{a}(\mathbf{x})$  が  $\mathbf{rnd}$  の方向に強化され、Critic の出力がより大きくなるように Actor の学習が進む。

## 4 シミュレーション

### 4.1 シミュレーション設定

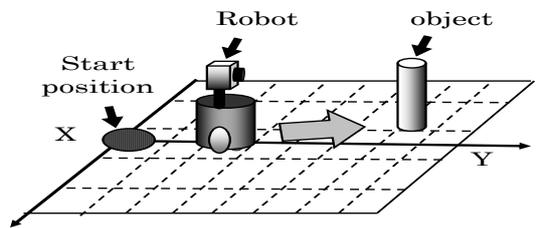


Fig. 3 Simulation environment

本研究では、Fig.3 に示すシミュレーション環境において、半径 2cm、高さ 4cm の同筒形の黒色の目標物を用意し、CCD カメラを搭載した移動ロボットが目標物に到達するタスクを扱う。シミュレーションで使用するロボットは AAI 社の小型移動ロボット Khepera を想定し、直径は 5.8cm、左右の車輪の間隔は 5.2cm、左右の車輪の出力

を-3~3とし、これに0.12cm/stepをかけた分だけ床に対して車輪を前進させ、ロボットの動きを計算した。搭載したCCDカメラは64×24画素のR,G,Bデータを持ち、横視野は114°、縦視野は44°とした。また、それぞれの入力信号は0~1の連続値とした。そして、目標物の色は黒色(R,G,B→0,0,0)とし、目標物以外は白色(R,G,B→1,1,1)とした。したがって、目標物が遠くにあるときは、ほとんどの画像信号が1である。また、簡単のため画像上の目標物は、側面部と上面部をそれぞれ長方形で近似し、画像信号を計算した。

ニューラルネットは階層型3層とした。入力ニューロン数は、画像信号数である4608個とし、中間層のニューロン数は、比較のために20、60、180と変化させた。出力は、Critic:1、左右のモータ用としてActor:2の計3つを用いた。各ニューロンの出力関数は0.5~0.5の値域のシグモイド関数を用いた。ただし、Criticの出力は0.5を足して0から1の値域とした。初期重み値の設定は、中間層と出力層間を0とし、また、その他は、-0.1~0.1の間の微小乱数とした。割引率は $\gamma = 0.98$ と固定とした。

ゴール条件は、左右のモータが前進を示し、かつ、目標物とロボットの距離が0.5cm以下で、画像から算出した目標物の重心位置がカメラ画像の中心から左右に±5ピクセルの位置にあるときとした。この時、報酬を与え、Criticは、教師信号を $P_{s,t-1} = 0.9$ として学習させた。また、ロボットが目標物を見失ったときに、罰として、教師信号を $P_{s,t-1} = 0.1$ として学習させた。その他のときは、(6)式の報酬 $r_t = 0$ として教師信号を $P_{s,t-1} = \gamma P_t$ として学習させた。毎試行ごとにロボットはスタート地点に戻し、目標物の位置はランダムに決定した。ただし、始めは目標物の位置を、ロボットの近くで、かつほぼ正面の範囲内とし、学習が進むにつれ、遠くや横の方にも目標物が置かれるように徐々に範囲を広げていった。そして、最大で距離15cm、角度±70°まで範囲を広げた。

#### 4.2 シミュレーション結果

中間層のニューロン数を20、60、180と変化させ、また、学習係数も0.1、0.3、0.6、0.9、1.2と変化させて学習させた。そして、総試行回数である10000試行のうち、目標物に到達できた試行数について、乱数系列を変化させた10回分の平均を示したものがFig.4である。

このFig.4において、中間層のニューロン数が少なく、かつ、学習係数が増加すると成功した試行回数が少なくなる傾向があり、学習が進んでいないことが分かる。つまり、中間層のニューロン数が多いほど、学習係数を大きくしても、学習が成功していることが分かる。

次に、学習中において、ロボットから距離15cmのどこ

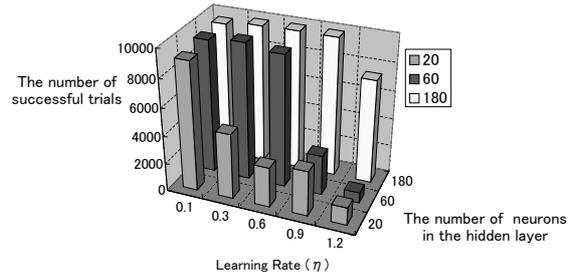


Fig. 4 The number of successful trials according to the number of hidden neurons and learning rate.

ろに、20度間隔で計5箇所の位置に目標物を置いたときの平均到達ステップが初めて40step以下になったときの試行回数の例をFig.5に示す。

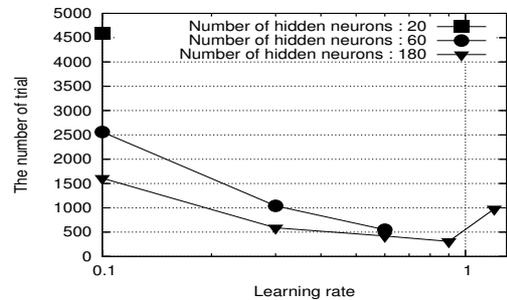


Fig. 5 The number of trial when the average number of steps to the goal for five object locations becomes less than 40.

Fig.5において、中間層ニューロン数が少ないほど、学習係数を増加させたときの学習が不安定となり、学習の収束が見られなくなった。特に、中間層ニューロン数が20個の場合は、学習係数が0.3の場合でも学習が収束しなかった。また、中間層ニューロン数が多いほど学習係数を増加させても学習の収束がみられ、かつ、中間層のニューロン数が少ないものよりも、多いものの方が短い試行回数で学習が収束していた。また、学習が収束する範囲内では、学習係数を大きくした方が学習が早い段階で収束する傾向があった。しかし、中間層ニューロン数180個、学習係数1.2のときのように、中間層ニューロン数が多いものであっても、学習係数を増加させ過ぎると学習が不安定となり、学習の収束が遅れたり、収束に至らないケースもあった。

次に、中間層ニューロン数と学習係数を変化させた時の、学習開始から2000stepまでの間での中間層ニューロンの伝播誤差の絶対値 $|\delta|$ の最大値をFig.6に示す。Fig.6より $|\delta|$ の最大値は、中間層のニューロン数が少ないほど大きくなっていることが分かる。このことから、中間層ニューロン数を増加させると、 $|\delta|$ が小さくなり学習が安定すると推測される。

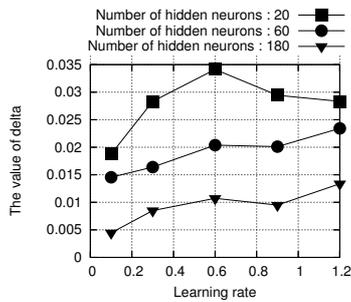
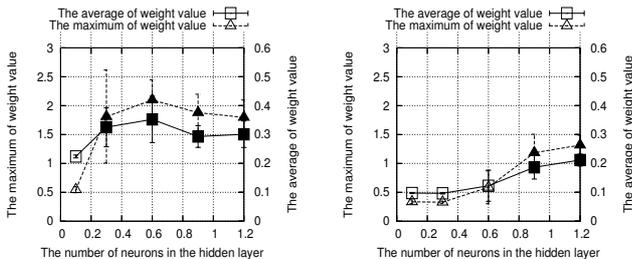
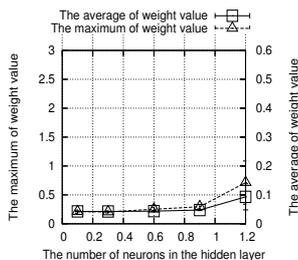


Fig. 6 The maximum value of  $|\delta|$  in the hidden layer in the first 2000steps.



(a) The number of neurons in the hidden layer is 20. (b) The number of neurons in the hidden layer is 60.

• The filled plot marks indicate that the learning failed.



(c) The number of neurons in the hidden layer is 180.

Fig. 7 The average and standard deviation of each of the average and the maximum weight value between the hidden layer and the output layer after 10000 trials over 10 simulation runs. The scale is different between the average and the maximum.

次に、学習終了後の中間層から出力層間の全重み値の大きさの平均値と最大値のそれぞれについて、乱数系列を変えた10回のシミュレーションにおける平均値と標準偏差をFig.7に示す。まず、学習がうまくいっていない時(塗りつぶされたプロット点)は、重み値が大きいことが分かる。さらに学習がうまくいっている時について良く見ると、中間層ニューロン数が多い方が重み値の大きさの平均値や最大値が小さくなっていることが分かる。この結果より、2.2で述べたように中間層ニューロン数が増加すると、似たような動きをするニューロンが増えることにより、Fig.1の例で示したように中間層と出力層間の結合重み値が大きくなる前に学習が収束していると推測される。その結果、Fig.6のように、式(6)によって、中間層ニューロン数が多いほど、伝播誤差 $|\delta|$ の大きさが小さくなり学習が安定したと考えられる。

## 5 議論

### 5.1 計算時間について

次に、学習のために実際にかかる計算時間について考える。中間層ニューロン数を増やすと学習係数を大きくすることができ、学習が収束するまでの試行回数が少なく済むことが確認された。しかし、ニューロン数が多くなればそれだけ1回の学習に時間がかかるため、トータルの計算時間としてはあまり変化がないことになる。

しかしながら、ニューラルネットは並列演算が可能であり、並列演算を行うハードウェアを用いることでその性能を引き出すことができる。この様な前提に立てば、一回の学習にかかる時間はニューロン数の影響を受けなくなるため、中間層ニューロン数を増やしたほうが学習係数を大きくできる分、学習を高速化することができる。

### 5.2 学習の可能性と学習の安定性

中間層ニューロン数を少なくすると学習が収束に至らない理由として、関数近似能力が落ちるため学習がうまくできなかったということも考えられる。しかし、学習係数を小さくすれば、中間層ニューロン数が少ない場合でも学習できることから、関数近似能力よりも学習過程における安定性が問題であると考えられる。また、中間層と出力層間の重み値や中間層への伝播誤差の値からもそのことは裏付けられていると考えられる。

## 6 まとめ

多入力時の階層型3層のニューラルネットにおいて、中間層ニューロン数を増加させると、関数近似能力が上がるだけでなく、学習が安定することが分かった。これによって、学習係数を大きくすることができ、学習を高速化させることができると期待される。

また、その理由として、中間層ニューロン数が増えると、中間層と出力層間の結合重み値の大きさが小さくなり、そのため、各中間層ニューロンの伝播誤差の大きさ $|\delta|$ が小さくなるためであることを示唆する結果を得た。

## 謝辞

本研究は、日本学術振興会科学技術研究費補助金基盤研究(B)(14350227, 15300064)の補助を受けた。ここに謝意を表す。

## 参考文献

- [1] Hornik, K. : Multi layer Feed forward Networks are Universal Approximators, *Neural Networks*, Vol.2 pp 359-266 ( 1989 )
- [2] Shibata, K. and Iida, M. : Acquisition of Box Pushing by Direct-Vision-Based Reinforcement Learning, *Proc. of SICE Annual Conf.* 2003, 0324.pdf, pp.1378-1383 (2003)