

階層型ニューラルネットにおける中間層での適応的空間再構成と 中間層レベルの汎化に基づく知識の継承

柴田 克成*・伊藤 宏司**

Adaptive Space Reconstruction on Hidden Layer and
Knowledge Transfer based on Hidden-level Generalization in Layered Neural Networks

Katsunari SHIBATA* and Koji ITO**

Humans can learn its action effectively in the real world by taking a similar action in a similar situation. In order to realize such abilities in a robot with a neural network, not only generalization on the input signal space, but also the generalization based on the similarity on the reconstructed space on the hidden layer would play an important role. In this paper, to explain the acquisition of the useful hidden representation for the generalization, a hypothesis is set up at first that when two training patterns are closer, the corresponding hidden patterns are likely to become closer through learning. In the first simulation, the hypothesis is supported by the learning of random input-output pattern sets. In the other simulations where simple visual sensor signals were the input of the network, it is shown that the hidden layer represents global information adaptively while keeping the information given by the initial connection weights from the input layer to the hidden layer. Finally, the reason why a neural network with visual inputs becomes to represent the global information in the hidden layer through the reinforcement learning of the task that a robot reaches a target caught on its visual sensor, is considered.

Key Words: layered neural network, localized input signals, global representation, hidden-level generalization, supervised learning

1. はじめに

実世界というさまざまな情報があふれている環境の中で、ロボットが状況に応じた適切な行動を学習するためには、人間のように「似たような状況では似たような行動をとる」ことによって、前に学習したことを活用し、効率的に学習すること、つまり、タスク間での「知識の継承」が非常に重要である。このような能力は、一見、入力パターンが近ければ出力も近くなるに基づく「汎化」で実現できると考えられがちである。しかし、少し考えてみれば、われわれ人間は「状況」を何らかの形で「抽象化」し、その上で「状況の類似性」をとらえており、単に入力パターン空間、つまり、センサ信号空間上での距離だけで判断しているのではないことは明らかである。つまり、脳の中で入力信号を変換し、都

合が良いように再構成した空間上での距離に基づいて状況の類似性を判断していると考えられる。

これを、階層型ニューラルネットに置き換えて考えてみると、ある二つの入力パターン間の距離が大きくても、入力層から中間層への変換後に、中間層パターン間の距離が小さくなっていけば、出力も近くなる、つまり、中間層パターン空間上で出力に対して汎化が働くことに相当すると考えることができる。

われわれ生物がそのような有効な中間層表現を獲得できる理由としては、1. 進化の過程などを経て、生得的にそのような能力を有している、2. 自己組織的な手法によって獲得している、3. 上位からの信号による学習によって獲得しているなどが考えられる。特に初期視覚については、従来、2の手法によるモデル化が試みられてきた^{1) 2)}。

しかし、たとえば、われわれは普段よく目にする光景でも必要でないことは意外と記憶に残らないことなどから考えると、内部の表現も、必要なところは細かく、そうでないところは粗くといった具合に、合目的性を持ったものとなっていると考えられる。このような内部表現の合目的性の実現には、単に自己組織的な手法による入力信号のみに基づいた獲得だけでは困難であり、3のような上位からの信号に基づく学習が必要になるであろう。特に、高次脳機能において、高

* 大分大学工学部電気電子工学科, 大分市

** 東京工業大学大学院総合理工学研究科知能システム科学専攻, 横浜市

* Dept. of Electrical & Electronic Engineering, Faculty of Engineering, Oita University, Oita

** Dept. of Computational Intelligence and Systems Science, Tokyo Institute of Technology, Yokohama

(Received March 15, 2006)

(Revised August 29, 2006)

度な抽象表現の獲得を説明する有力なモデルは現在見当たらないが、これは、抽象表現ほど目的指向性が高くなるため、その実現方法がわからなかったことが大きな原因であると筆者らは考えている。したがって、上位からの信号に基づく学習によって抽象表現が自律的、適応的に形成される仕組みが明らかになれば、ロボットの知能のみならず、高次脳機能の解明にも大きく貢献できる可能性がある」と期待している。

著者らは、強化学習に基づいて生成した教師信号によって、階層型ニューラルネットを誤差逆伝搬法 (BP 法)⁹⁾ で教師あり学習させることにより、視覚センサ付き移動ロボットが、視覚センサ信号を直接ニューラルネットに入力して、物体到達や物体を押し動作を学習できることを示した^{3) 4)}。その際、個々の視覚センサ信号は局所的な情報しか表現していないにもかかわらず、中間層に、物体の位置を表現する大域的な情報表現が獲得され、その大域的な情報表現に基づいて出力に汎化が起こることを示した。また、獲得された中間層の情報表現は、車輪の動作特性等によって適応的・合目的に変化することも確認した³⁾。このとき、ニューラルネットは強化学習に基づいて作られた教師信号によって単に教師あり学習させているだけである。したがって、BP 法に基づく教師あり学習によって、どのような中間層表現が形成されるかを知ることは非常に重要であると考えられる。

そこで、本論文では、中間層の表現に基づいて出力が効率良く学習される「中間層レベルの汎化」を定義し、中間層におけるパターン間距離の重要性を提起する。そして、BP 法の学習によって有効な中間層表現が形成される理由として、「二つの入力パターン間の距離が離れていても、教師信号パターンが他と比べて近ければ、学習を通して、両者の中間層パターンも相対的に近くなる傾向がある」との仮説を立てる。そしてまず、恣意的なものを排除したランダム入出力パターンの場合についてこの仮説を確認し、次に、中間層での自在な空間再構成を可能とする局所的な情報を表現している簡単な視覚センサ信号を入力とする場合について、中間層において大域的、適応的、合目的、抽象的な表現を獲得できるか、およびその後の学習に与える高速化などの効果を具体的に調べた。そして、最後に、前述の視覚センサを有する移動ロボットが、強化学習に基づいて単に物体到達タスクを学習することによって、ニューラルネットの中間層に大域的な空間情報が表現されるようになる理由について考察する。

従来、中間層表現については、中間層ニューロン数を適切にするなどの構造決定⁵⁾ や、個々の中間層ニューロンの働きの解釈^{6) 7)} を目的としたもの、ニューラルネット内の中間層ニューロン数と入出力間の汎化の関係を扱ったもの⁸⁾ などがある。本論文では、入出力間の汎化ではなく、中間層パターン間の距離に注目して、中間層での空間の再構成の原理とその効果をいくつかのシミュレーションを通して考察していく。そして、関連タスク間での知識の継承による学習速度の飛躍的上昇、さらには、状態の抽象化と高次機能の獲得原理の解明につながっていくことを期待している。




Fig. 1 The definition of hidden-level generalization and the difference from the input-level generalization that is generally called just generalization.

2. 入力レベルの汎化と中間層レベルの汎化

2.1 定義

汎化とは、少ないサンプルでの学習が真の分布データに対していかに有効であるかを示す指標である。Fig. 1のように、関数近似器の入出力間の滑らかさにより、入力パターン間の距離が近いと、それぞれを入力したときの出力も近い値になることで学習が効率化する、いわゆる一般的な「汎化」のことをここでは入力レベルの汎化と呼ぶ。一方、本論文で注目する中間層レベルの汎化は、入力パターン同士の距離がたとえ大きくても、入力層から中間層への変換を通して中間層パターン間の距離が小さくなることにより、それぞれの出力値同士が近くなり、少ないサンプルで効率的に学習できる能力のことと定義する。

このような中間層表現が、学習によって獲得できるとすれば、いったん学習によって獲得された後は、同様な中間層表現が有効な学習は大きく加速されると期待される。ただし、ここで、われわれ生物やロボットの学習には、三次元空間の認識を始め、タスク間で共通して使うことができる情報が多いという前提に立つ。また、入力レベルの汎化は、元々ニューラルネットが持つ性質としての能力であるが、中間層レベルの汎化は、まず、学習を通して有効な中間層表現を獲得することが求められるという点で大きく異なる。

2.2 大域表現・局所表現と汎化

本節では、情報表現が局所的か大域的かによって汎化能力が大きく異なることを示し、局所表現で情報を入力し、中間層で大域表現に変換することの有効性を説明する。

Fig. 2のように、10個のセンサセルが1列に並んだ視覚センサがその前にあるセンサセルと同じ大きさの対象物を捕えているとする。各センサセルは、対象物が投射された面積の割合を0から1の間の連続値で出力する。ここで、対象物の位置 x を0, 1, 9と変化させると、視覚センサ信号は(a)(b)(c)のように変化するが、この場合、任意の2パターン間の距離(各値の差の絶対値の総和)はすべて2となる。しかし、実際の物体の位置 x では、(a)(b)間の距離は1であるのに対し、(a)(c)間の距離は9と大きく異なる。もし、




Fig. 2 The difference of distance between two patterns depending on whether the representation of spatial information is local or global.

理想出力が物体の位置 x に対して滑らかで単調に変化するならば、物体の位置 x という大域的な情報表現をしていれば、汎化によって、(a)(b) に対応する出力同士は、(a)(c) に対応する出力同士より近くなることは容易に学習できる。しかし、局所的な情報表現の視覚センサ信号空間では、各パターン間距離はすべて等しく、そのような効果は期待できない。

人間の目や視覚センサなどの出力表現は一般的に局所的である。しかし、入力層から中間層への変換を通して、中間層において、(a) と (b) が近く、(a) と (c) が遠いという表現が学習によって獲得され、保持されれば、中間層と出力層の間で汎化が期待できる。また、求められる大域的な情報は、空間情報に対し滑らかかつ単調に変化するものだけでなく、たとえば、中心より右か左かを区別する離散情報を始め、物体の位置 x に対して非線形性の強い複雑な情報である場合も当然多いと考えられる。そのような場合、入力が多数の局所的な信号よりなっていれば、その線形和として中間層ニューロンの個々がさまざまな複雑な情報を柔軟に表現できるというメリットが生じる。一方、入力信号自体が大域的な情報表現の場合は、入力層と中間層の間で逆に複雑な非線形変換が要求されることになり、その分学習が困難になる。このように、多数の局所信号を入力とすることは、中間層で大域的な情報を適応的に表現するために非常に合理的であると言える。さらに、このような空間的な位置関係だけでなく、第 1 章で述べた「状況の類似性」といったことも、ニューラルネット内部の状態空間における距離として表現できるのではないかと期待される。

2.3 学習による有効な中間層表現の獲得を説明する仮説

2.1 節で述べたように、中間層レベルの汎化には、まず、有効な中間層表現の獲得が求められる。そこで本論文では、有効な中間層表現が獲得される理由として、「二つの入力パターン間の距離が大きくても、対応する教師信号パターン同士が他と比べて近ければ、学習を通して、中間層パターン同士も相対的に近くなる傾向がある」との仮説を提起する。

重み値やバイアス等のパラメータ数が学習パターン数に比べて多い場合はもちろんであるが、学習パターン数がパラメータ数に比べて多い場合でも、ニューラルネットの非線形性から、与えられた理想入力パターンから中間層表現が一意に決まらない場合が多い。この中間層表現の不良設定性から、「教師信号が近ければ、例外なく中間層表現も近くな

る」ことに対しては、容易に反例を示すことができ、厳密には正しくはない。これに対し、本論文での仮説は、「教師信号が近ければ、中間層の表現も、必ずではないが、近くなる傾向がある」という仮説である。しかし、やはり、中間層表現の不良設定性から、これを厳密に証明することは難しい。そこで本節では、例を使って直観的にその原理を説明する。説明を簡単にするため、中間層および出力層の各ニューロンの出力関数は、値域が -0.5 から 0.5 の原点对称なシグモイド関数とし、バイアス入力は常に 0 とする。

まず、中間層ニューロン、出力層ニューロンともに 1 個だけで、学習が誤差 0 で収束したならば、教師信号が同じ場合には中間層ニューロンの値も同じになり、逆に、教師信号が違う場合は中間層ニューロンの値も違うことは自明である。

次に、Fig. 3 のように、各層のニューロン数が入力側から 3-3-1 の 3 層ネットワークの場合を考えてみる。中間層 - 出力層間には最初に情報を持たせないように、結合の初期重み値をすべて 0 とする。入力層 - 中間層は、同じ番号のニューロン同士の結合の初期重み値は 1 で、それ以外は 0 とし、中間層パターンが、入力パターンと非常に強い相関があるように設定する。そして、入力パターン (以下入力 P とする) $P_1(1,0,0)$ と入力 $P_2(0,1,0)$ の両者に対しては教師信号を 0.4 、入力 $P_3(0,0,1)$ に対しては -0.4 を教師信号として BP 法で学習させる。また、学習定数はあまり大きくなく、かつ、入力パターンは順番に提示されて学習するとする。この場合、前述の不良設定性があり、入力層 - 中間層の重み値は変化させなくても、中間層 - 出力層の重み値を変化させるだけでも解を得ることができる。しかし、その場合は、教師信号間距離にかかわらず中間層パターン間距離は常に一定となり、両者の間に全く相関はない。

学習による重み値の変化を、実際に学習を行わせた結果をもとに Fig. 3 に模式的に示す。まず、(1) 入力 P_1 に対する学習で、中間層ニューロン 1 (以下中間層 1 とする) - 出力層間の重み値が正の値になる。次に、(2) 入力 P_2 が提示されると、中間層 2 - 出力層間に正の結合が形成されるとともに、正の誤差信号 δ は中間層 1 へ伝播し、入力 2 - 中間層 1 間にも正の結合が形成される。(3) 入力 P_3 が提示されると、中間層 3 - 出力層間に負の結合が形成されるとともに、誤差信号 δ は負となり、中間層 1,2 に伝播し、入力 3 と中間層 1,2 の間にも負の結合が形成される。(4) 再び入力 P_1 が提示されると、中間層 1 - 出力層間、入力 1 - 中間層 1 間の重み値が強化されるとともに、入力 1 から中間層 2 へ正の結合が、入力 1 から中間層 3 へ負の結合が形成される。(5) 再び入力 P_2 が提示されると、入力 2 から中間層 3 へも負の結合が形成される。

こうして、入力 1 と入力 2 は、中間層 1,2 に対しては正の結合、中間層 3 に対しては負の結合を形成するため、入力 1 か入力 2 が発火すると、中間層 1 と中間層 2 の両方が発火し、中間層 3 の発火が抑えられる。逆に、入力 3 は、中間層 1,2 に対しては負の結合、中間層 3 に対しては正の結合を形




Fig. 3 A drawing to explain intuitively the proposed hypothesis concerning the acquisition of useful hidden representation through learning. (Black circle: the output is 1.0 for input neurons, and it is close to 0.5 for hidden and output neurons. White circle: the output is 0.0 for input neurons, and it is close to -0.5 for hidden and output neurons. Solid line: a positive connection weight. Broken line: a negative connection weight. Arrow: a propagated error.)

成するため、入力3が発火すると、中間層1,2は発火が抑制され、中間層3が発火する。つまり、教師信号が同じ2パターンのときには、教師信号が大きく異なるパターンのときと比較して、中間層パターン間距離が相対的に小さくなる。

このように、中間層パターン間距離と教師信号間距離に相関がなく、かつ、そのまま中間層と出力層の間の重み値を変化させるだけで学習できる状態から学習をスタートしたにもかかわらず、学習後は、中間層パターン間距離は教師信号間距離と相関関係を形成する。このことから、「教師信号が近い方が、中間層パターンも相対的に近くなる傾向がある」ということが一般的に言えるのではないかと推測される。

3. ランダム入出力学習のシミュレーション

本章では、前章で述べた「教師信号が近い方が、中間層パターンも相対的に近くなる傾向がある」との仮説を、恣意的なものを排除したランダム入出力の学習のシミュレーションを通して実験的に検証する。

本章および次章では、ニューラルネットの計算および学習は、すべて文献⁹⁾に基づいた。特に記述がない限り、3層で学習係数0.1、慣性項の係数は0.9とした。また、前節では、説明を簡単にするため、各ニューロンの出力関数は-0.5から0.5の値域としたが、以下のシミュレーションでは、4.3節以外では、すべて出力関数は0から1の値域を持つシグモイド関数とした。初期重み値は、入力層-中間層については-1から1の一樣乱数で決定し、中間層-出力層はすべて0とした。学習は、入出力パターンをランダムに選び、繰り返すことなく、1回だけ学習する。そして、このパターンの選択と学習を繰り返した。

本章のシミュレーションでは、入力20個、出力1個のニューラルネットを用意し、個々の入力を0から1の範囲、

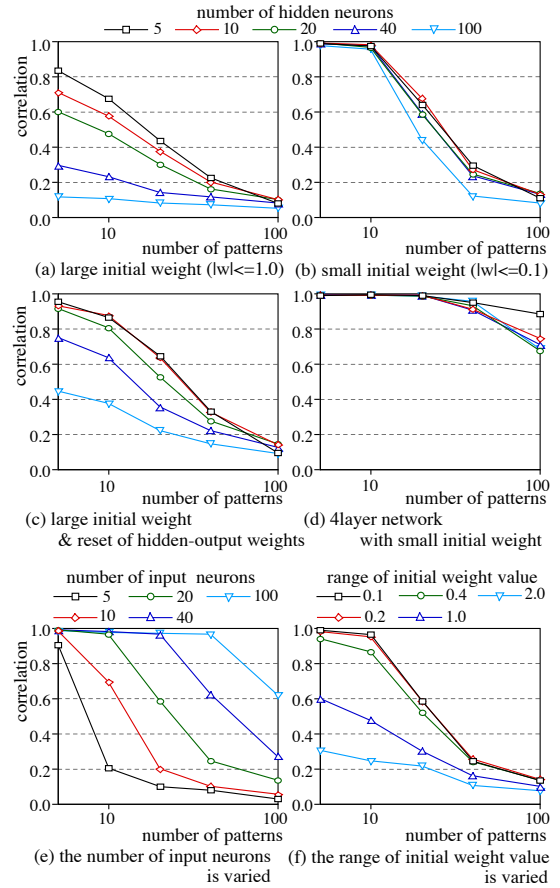


Fig. 4 Correlation coefficient between two distances, the distance between training signals and the distance between hidden patterns, after learning of random input-output patterns. In the first 4 graphs, the number of hidden neurons is varied.

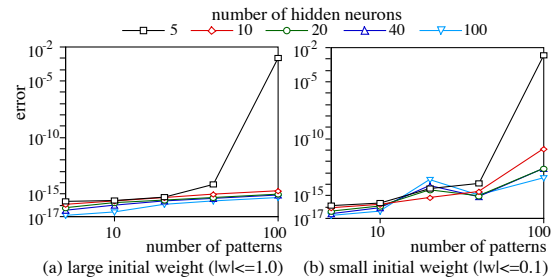


Fig. 5 Error after the learning of random input-output patterns.

教師信号を0.1から0.9の範囲の乱数で決定したいくつかの入出力パターンを用意し、それを入出力セットとした。そして、その中から毎回ランダムに入出力パターンを選んで(20000×パターン数)回学習させた。そして、学習後に、2つの入力パターンを提示した際の、教師信号同士の距離と中間層パターン同士の距離を、すべてのパターンの組み合わせについて計算し、両者の相関係数を計算した。距離は、各ニューロンの値の差を取り、その絶対値の総和とした。パターン数に応じて学習させる入出力セットをいくつか用意

し、セットごとの相関係数の平均をプロットした。パターン数とセット数の関係は、5-100, 10-40, 20-20, 40-20, 100-10 と、各プロット点ごとに、総学習パターン数が 400 から 1000 程度になるようにし、平均的な結果として意味があるようにした。さらに、中間層ニューロン数、学習パターン数などを変化させて、相関がどのように変化するかを調べた。

結果を Fig. 4(a) から (f) に示す。相関係数は、0 のときには相関がなく、1 に近いほど正の相関があることを示す。図 (a) は入力層 - 中間層の初期重み値を決める際の範囲を -1 から 1 とし、図 (b) は -0.1 から 0.1 として学習させた結果である。また、学習における誤差と相関の関係を示すために、Fig. 4 の (a) と (b) の場合について、各パターンごとの誤差を平均し、各セットごとに求め、それをさらに、セット間の対数平均を求めてプロットしたものを Fig. 5 に示す。ただし、倍精度浮動小数点の仮数の有効数字の制限から、誤差が非常に小さい場合は 0 となってしまうので、誤差が 10^{-17} より小さい場合は 10^{-17} として計算した。

Fig. 4 のいずれの場合も、相関係数が正の値であることから、教師信号間距離と中間層パターン間距離の間には明らかに相関があると言える。念のため、Fig. 4 のすべてのデータについて、平均をとったセット数分の相関の値から、不偏分散を計算し、そこから t 分布表を用いて 95% 信頼区間を計算すると、150 個のデータに関して、いずれの場合も「相関係数が 0 である」という帰無仮説は棄却された。つまり、有意に相関があると言える。

特に、パターン数が少ないとき、初期重み値の絶対値が小さいときに強い相関が見られる。また、初期重み値の絶対値が大きい場合は、中間層ニューロン数によって相関の強さが大きく変化することがわかる。これは、中間層ニューロン数が少なくなると不良設定性が減り、中間層ニューロンが教師信号と相関を持つ形への変化を強いられる一方、中間層ニューロン数が多いと不良設定性が大きく、初期重み値が大きいと、その重み値が大きく変化する前に、中間層 - 出力層の重み値の学習が進んで、誤差が減るためと考えられる。誤差に関しては、Fig. 5 の (a)(b) 間であまり大きな差はなく、両者とも、中間層ニューロン数 5 個でパターン数 100 のときに誤差が急激に大きくなっているものの、Fig. 4 を見ると、その場合に、相関係数に大きな変化は見られない。

図 (c) に、図 (a) と同じ条件で、 $(2000 \times \text{パターン数})$ 回ごとに中間層と出力層の間の重み値を 0 にリセットした場合の結果を示す。重み値のリセットは、同じ情報を必要とする別の出力ニューロンの学習が始まったと解釈することもできる。この場合、リセットをしない場合よりも相関が強くなっている。学習は、入力層 - 中間層、中間層 - 出力層の両方で同時に行われ、前者の学習によって中間層パターンと教師パターンとの間で相関が徐々に強くなるが、誤差が 0 に近づくことによってその動きが小さくなる。しかし、中間層 - 出力層の重み値を 0 にリセットすることで、誤差が再び増大し、さらに入力層 - 中間層の学習が進むことによってより相関が

強くなると考えられる。

図 (d) に、ニューラルネットの層数を 4 層にした場合の上位の中間層パターンと教師パターンとの相関を示す。初期重み値は、上位中間層と出力層間は 0、それ以外は -0.1 から 0.1 の乱数とし、下位の中間層ニューロン数は 20 とした。この場合、3 層の場合よりもさらに相関が強くなっており、パターン数が多くなっても相関が大きいことがわかる。

次に、中間層ニューロン数を 20 個に固定し、入力層ニューロン数を変化させた。その結果を Fig. 4(e) に示す。これより、中間層パターンと教師パターン間に相関が出るためには、提示パターンセットの数に対してある程度入力層ニューロン数が必要であることがわかる。これは、少ない入力ニューロンで多くのパターンを表現すると、入力層 - 中間層の変換に、より強い非線形性が必要になり、学習が困難になるためと考えられる。また、これより、図 (a)(b) において、提示パターンセットが多くなると相関が小さくなったのは、パターン数に対して入力層ニューロン数が少なかったためであると考えられる。

さらに、Fig. 4(f) に、入力層ニューロン数、中間層ニューロン数ともに 20 と固定し、入力 - 中間層間の初期重み値の範囲を変化させたときの相関の様子を示す。これより、初期重み値の範囲が小さいほど相関が大きいことがわかるが、ある程度より小さくなると、あまり変化がないことがわかる。

以上の結果から、ランダム入出力パターンの学習においては、パラメータの値により、学習後の相関係数の値は変化するものの、教師信号間距離と中間層パターン間距離の間には、学習によって正の相関関係が形成されることが示され、仮説は支持されたとと言える。

4. 局所信号入力時の学習のシミュレーション

ここでは、局所的な情報を表す信号の例として簡単な視覚センサ信号を入力としたシミュレーションによって、以下の 3 つのことを観察した。1. 局所信号を統合して、中間層で大域的な情報を表現できるようになるかどうかを検証するとともに、個々の中間層ニューロンが、どのようにその情報を表現するようになるかを観察した。2. 複数の大域的情報の中から、過去の学習で必要とされた情報を中間層が選択的に表現するようになるかどうかを観察した。3. 複数のタスク間で共通した上位の抽象的な情報表現を獲得できるか、また、獲得された情報表現によって学習が加速されるかを観察した。また、基本的には、最初の学習を終了したニューラルネットの中間層と出力層間の結合重み値をリセットし、その後、少ない数の入出力パターンの学習を行った後に、学習パターンを与えていない領域での出力から中間層レベルでの汎化を観察することによって、中間層の表現を推測した。学習のパラメータ等は、記述がないものは、前章と同様とした。

4.1 一次元の広がりを持つ視覚センサ信号入力の場合

まず、2.2 節で示した例題で、局所信号が入力された場合の学習後の中間層表現を確認する。物体の位置 x を乱数を




Fig. 6 The learning of the object location when the signals of an array-type visual sensor are the inputs.

使って 0 から 9 の間の連続値で決定し, Fig. 6 のように, そのときの 10 個の視覚センサーの出力を中間層ニューロン 10 個の 3 層ニューラルネットに入力する. そして, 物体の位置 x に対し, 教師信号を $0.09x + 0.1$ として学習させた.

1 万回の学習で誤差がほぼ 0 になった後, 中間層 - 出力層の結合重み値をすべて 0 にリセットし, 視野中の 2カ所だけ最初の学習で用いた教師信号で 1 万回学習させて, 大域的情報表現を獲得でき, それによって内挿または外挿が働くかを調べた. これは, 中間層からの結合の重み値をすべて 0 とした新たな出力ニューロンを付加して学習させたとしても良い. 学習後の物体の位置 x に対する出力の分布の例を Fig. 7 に示す. (a) は内挿, つまり, 教師信号を視野の両端である $x = 0.0$ と $x = 9.0$ で与えた場合, (b) は外挿, つまり, 教師信号を $x = 0.0$ と $x = 4.5$ で与え, $4.5 < x$ の出力も観察した場合である. それぞれ, 矢印が 2 回目に学習させた物体の位置である. この例は, 初期重み値を変化させて 20 回学習をさせたうち, 外挿, 内挿の程度が中間的なものを選んだ.

これより, 外挿の場合はかなり最初の学習の教師信号とは離れているものの, いずれも最初の学習をしなかった場合と比べて最初の学習の教師信号に近い出力となっており, 中間層において大域的な情報が表現できるようになったと考えられる. また, 最初の学習を行っていない場合は, 2 回目の学習時に視覚センサ信号が常に 0 であるところは, その部分と中間層の間の結合は学習が全く行われず, 重み値は初期値のまま変化せず, バイアスのみが学習される. よって, その場合の出力は, 2 回目に与えた 2 つの教師信号の間あたりで変動しているだけとなる. また, 最初の学習を行なった場合と行なわなかった場合で, 出力値の増減の傾向は似ていることから, 最初の学習を行なっても, 初期重み値の影響が残っていることもわかる. さらに, 最初の学習の後に, 入力層 - 中間層の結合の重み値を固定し, 中間層 - 出力層の結合のみを学習させた場合は, 中間層の表現が変化しないため, 最初の学習の際の出力分布に最も近い分布となっている. しかし, 入力層 - 中間層の重み値を固定しない場合との差はあまり大きくない. 新しい学習への適応性を考えれば, 入力層 - 中間層の重み値は固定しないほうが自然である.

次に, 実際に, 最初の学習の前と後で, 物体の位置 x に

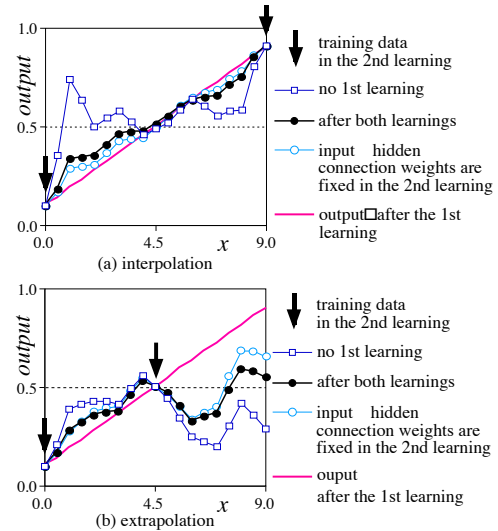


Fig. 7 The output distribution as a function of the object location after the second learning with only two training pattern sets.

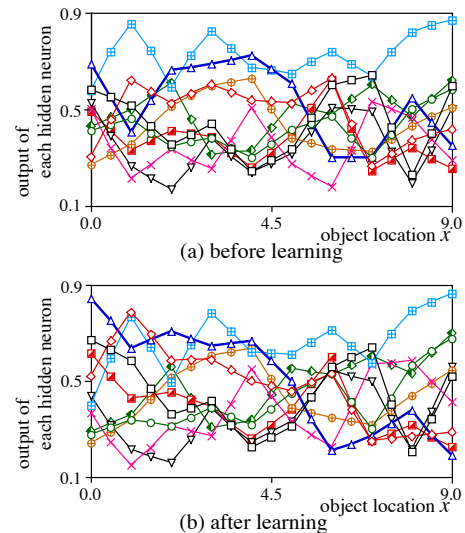


Fig. 8 Change of each hidden neuron's output as a function of the object location x through the first learning.

対する各中間層ニューロンの表現がどのように変化したかを Fig. 8 に示す. 中間層ニューロン数が 1 個の場合, 物体の位置 x に対して出力が単調増加するためには, 中間層ニューロンの値も単調な増加か減少でなければならない. しかし, この図では, 学習によって単調増加や単調減少になった中間層ニューロンは一つもない. たとえば, 図中のプロット記号が \square の太線は, 局所的に見ると増加も減少もあり, 図 (a) と図 (b) で局所的な増減の傾向は良く似ている. しかし, 図 (b) では $x = 0$ で出力が 0.9 に近く, $x = 9$ で出力が 0.1 に近くなって, 図 (a) と比較して, 全体としては右下がりの傾向が強くなっていることがわかる. 図を細かく見ると, 他の多くのニューロンも学習によって同様な変化をしていることが観察できる. そこで, 中間層ニューロンの値が, 物体

の位置 x に対して右上がりまたは右下がりの傾向を学習前より強くしているということをサポートするために、 $x = 0$ と $x = 9$ での各中間層ニューロンの出力差の絶対値の平均をとったところ、学習前には 0.18 であったが、学習後には 0.32 と大きく増加していた。これらのことから、ニューロン数を冗長にすると、個々のニューロンは学習前の情報（表現）を保持しながら少しずつ変化することで、集団として新たに学習した大域的情報を表現できるようになることがわかる。

次に、最初の学習後の中間層での表現が、本当に物体の位置を反映したものとなっているかを調べた。物体の位置 x の値を変化させ、そのときの各中間層ニューロンの出力パターンと $x = 0$ のときのパターンとの距離、つまり各ニューロンの出力の差の絶対値の総和を観察した。ネットワークの重み値の初期値を 20 回変化させ、最大値、最小値、平均値を最初の学習を行った後と前のそれぞれの場合について Fig. 9 に示す。ニューラルネットの初期値によって、ばらつきはかなりのもの、最初の学習後の中間層パターンは、明らかに物体の位置 x を反映したものとなっており、大域的な情報を表現するようになったと言える。一方、学習前は、物体の位置 x が 1 以上の際に x と中間層パターン間距離の間に相関がない。また、Fig. 9 の平均値のグラフを見ると、学習前、学習後ともに段々になっている。これは、物体の位置を 0.5 ずつ変化させて出力を観察していることによって、物体が一つのセンサセルに収まる場合と 2 つのセンサセルにまたがる場合が交互に来ることが影響している。

次に、中間層を複数層設けたときに、複数の中間層間で表現がどう違うかを調べた。共にニューロン数 10 個の中間層が 2 層の 4 層ニューラルネットで前述と同様の学習を行った。また、二つの中間層間の重み値の初期値の範囲も入力層 - 中間層と同様に -1 から 1 とした。そして、物体の位置が 0 のときと x のときの各中間層でのパターン間の距離を Fig. 10 に示す。これより、下位の層は、3 層ニューラルネットにおける中間層と似ているが、上位の層では、出力が x に関してより滑らかで、出力のばらつきも小さくなっていることがわかる。このように、多層ニューラルネットの場合は、入力空間から出力まで徐々に教師信号間の距離を反映した表現へと変化していくと考えられる。

4.2 二次元の広がりを持つ視覚センサ信号入力の場合

次に、2 次元入力空間で、そのうちの 1 次元の情報についての関数を学習させた場合の中間層の表現を観察した。Fig. 11 のように、 5×5 の正方形にセンサセルを配置した視覚センサを仮定し、物体がセンサ上に投影されるとする。ここでも、簡単のため、センサセルと物体の大きさは同じとした。まず、物体の位置 (x, y) に対し、Fig. 12(a) のように、 x に対してのみ値が変化し、 y に対しては変化しない教師信号を用意し、物体の位置を乱数で決定しながらニューラルネットワークを学習させた。中間層ニューロン数は、前節と同様 10 個とした。その後、中間層 - 出力層の結合の重み値を 0 にリセットし、視野の左下の $(x, y) = (0.0, 0.0)$ と右上




Fig. 9 The distance between the hidden pattern when the object location is 0 and the hidden pattern when the object location is x .





Fig. 10 The distance between the hidden pattern when the object location is 0 and the hidden pattern when the object location is x in the case of 4-layer neural network.




Fig. 11 The learning of the object location when the signals from a square-shaped visual sensor are the inputs.

の $(x, y) = (4.0, 4.0)$ に置いた場合の 2 つの入力パターンについてのみ最初と同じ教師信号で教師あり学習を行った。

学習後の、物体の位置に対するニューラルネットの出力の分布を Fig. 12(b) に示す。この図から、出力の分布は、最初の学習で与えた教師信号ほどきれいではないが、物体の位置 x によって変化する傾向が見える。また、ニューラルネットの初期重み値を同じとし、 y によって変化する教師信

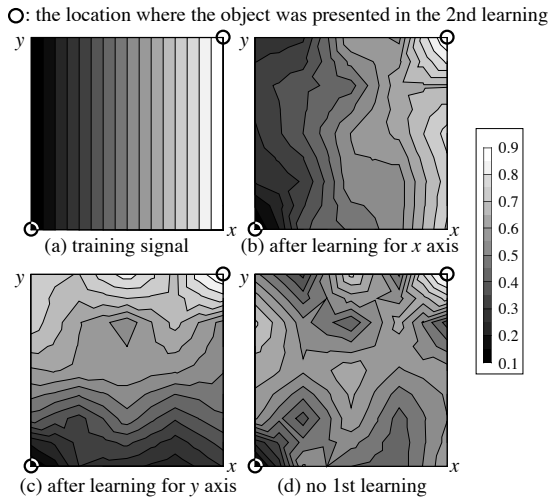


Fig. 12 The effect of the first learning to the output distribution after the second learning in the case of the square-shaped visual sensor.

号で最初の学習をさせたものを Fig. 12(c) に、最初の学習を行わなかったものを Fig. 12(d) に示す。この図より、(c) では、出力が y によって変化し、最初の学習を行わなかった (d) の場合には、 x, y に対する出力分布の傾向は見られなかった。このことから、最初の学習によって、ニューラルネットの中間層に教師信号に応じて空間が再構成され、必要とされた情報が選択的に表現されること、そして、中間層を共有することで、最初の学習で必要とされた知識が次の学習に伝えられる可能性を示した。

4.3 学習による上位空間構造の自律的獲得

本節では、複数の入出力セットに共通する上位の空間構造が中間層でどのように表現されるかを観察した。Fig. 13 のように、 8×4 の視覚センサの受容野をそれぞれ 4×4 の領域 A と領域 B に分割した。そして、 z 軸を教師信号 O_{ideal} とした場合に、それぞれの領域で教師信号が平面になり、かつ最大値、最小値がそれぞれ 0.4, -0.4 になるという拘束の下で物体の位置から教師信号を計算する一次式を乱数を用いて領域ごとに独立に決定した。そして、物体の位置をランダムに決定し、該当する領域の一次式にしたがって教師信号を求めて学習させた。その学習を 1000 回行った後、教師信号を求める一次式の係数を変え、中間層と出力層間の重み値をリセットして再びランダムに決定された物体の位置に対して出力の学習を行った。この 1000 回の学習を 1 セットとし、全部で 100 セットの学習を行った。この間、教師信号は各領域内の物体の x, y 座標の一次式で与えられること、さらに、二つの領域間で、教師信号が全く独立に与えられることは変化させておらず、そのような上位の空間構造がどのように表現されるかを調べた。ここでは、わかりやすいため、中間層、出力層ニューロンの出力関数として -0.5 から 0.5 の値域のシグモイド関数を用いた。また、簡単のため、物体はどれかの視覚センサセルと同じ位置に限定した。中間層




Fig. 13 A simulation to examine the learning of high-order spatial structure. The input space is divided into two regions and the training signal is independent between the two regions. The plane for each region indicates the training signal that is a linear combination of the two coordinates of the object location.




Fig. 14 Distribution of the input-hidden connection weights after learning. The gray or black square indicates a positive or negative weight respectively. The size of the square indicates the absolute value.

ニューロン数は 4 個とした。

前述のシミュレーションと同様に、セットごとに重み値をリセットすることは、重み値 0 の別の出力ニューロンを設けることと等価である。共通する情報を有するさまざまなパターンを学習させることによって、そこに共通する上位の情報が中間層に表現されるようになることとともに、その情報を使うことでその後の学習が加速されることを示す。

Fig. 14 に、学習後の入力層 - 中間層の結合の重み値を各中間層ニューロンごとに示す。グレーが正の重み値、黒が負の重み値を示し、正方形の面積で絶対値を示した。この図より、中間層ニューロン 1 と 2 は、領域 A へのセンサセルへの結合がほとんど同じで、領域 B への結合はちょうど反転した値となっていることがわかる。また、中間層ニューロン 3 と 4 は、両領域とも、1 と 2 と 90 度ずれた方向をコーディングしており、やはり、領域 A では、3 と 4 は同じ結合、領域 B では反転した結合となっていることがわかる。また、いずれの中間層ニューロンも、領域 A と領域 B に対してコーディングしている情報は 90 度ずれているが、ニューラルネットの初期値によっては、0 度または 180 度ずれた情報をコーディングするようになる場合もあった。

Fig. 15 に、100 セットの学習後に、中間層 - 出力層の結合の重み値を再び 0 にリセットした後、領域 A において、




Fig. 15 Output distribution after the second learning with only 3 training patterns indicated by the hatched areas. The gray or black square indicates a positive or negative output respectively. The size of the square indicates the absolute value. The square in each hatched area indicates the training signal.

右上, 右下, 左下の斜線で示した 3 箇所のいずれかに物体を置いた場合に対して, 斜線部の中の四角で表した教師信号を与えて学習し, 学習後の物体の位置による出力の分布を示した. 図中では, 斜線部以外では, 実際の出力を四角で表している. これによると, 領域 A では, 与えられた 3 つの教師信号によって規定される平面上の値に近い値が, 領域 B では 0 に近い値が出力されていることがわかる. これは, 学習を通して, 各領域では教師信号が平面状であり, 領域間は独立であるという上位の抽象的な情報表現を獲得し, ある領域での学習が他の領域での学習に影響しないように分離されたと考えられる.

ここで, 再び Fig. 14 を見ると, 中間層ニューロン 1 と 2 の値を足すと領域 B に関する情報が消え, 領域 A の x 方向が表現されることがわかる. 当初は, 4 つの中間層ニューロンが領域 A と領域 B のコーディングにそれぞれ 2 個ずつ使われることを想定していたが, 個々の中間層ニューロンは, 両方の領域の情報を表現していることがわかった. また, 恣意的に, ニューラルネットの初期重み値を, 中間層ニューロン 1 と 2 が領域 A だけ結合を持ち, かつ, 情報を表現する方向を 90 度ずらし, ニューロン 3 と 4 が領域 B だけ結合を持ち, やはり 90 度表現する方向をずらして学習してみたが, 何回か学習すると, Fig. 14 のように, 1 つのニューロンが両方の領域のコーディングを行うようになった. これは, 領域 A の学習をしているときでも, 誤差が存在すると, ニューロン 3 や 4 も誤差を減らすように学習をするためと考えられ, 分散表現のほうが学習が安定であることがわかる.

次に, 中間層レベルの汎化を通じた知識の蓄積と次の学習への継承がどのように進んでいるかを調べた. ここで知識とは, この教師信号が各領域内は平面で, 領域間は互いに独立であるというある程度抽象化された知識である. Fig. 16 に, 学習セット数が増えるにしたがって, 各セット内での学習の速度 (学習曲線) がどのように変化したかを 10 セットごとの平均として示す. 各セットの始めに, 中間層 - 出力層の結合の重み値はすべて 0 にリセットされるため, 各セットの学習初期では, 学習の進行によらず誤差は大きい. しかし, 蓄積された知識を中間層レベルの汎化という形で利




Fig. 16 Change of the average learning curve over 10 sets according to the number of the learning sets.

用することによって, 学習セット数が多くなればなるほど, セット内での学習が加速されていることがわかる.

5. 強化学習による中間層での大域的表現獲得に関する考察

第 1 章で述べたように, 筆者らは, 視覚センサを有する移動ロボットのニューラルネットに視覚信号を入力し, 視覚センサ上に映った目標物体に到達したり, 押した時に報酬を与えることで, 物体に近づいたり押したりする行動を actor-critic 型の強化学習で学習させてきた. その際, 学習によって中間層に大域的な空間情報が表現されるようになることを示してきた^{3) 4)}. ここで, なぜ強化学習を適用するだけで視覚センサ信号を統合し, 大域的な空間情報が表現されるようになるかを考えてみる.

強化学習で良く用いられる TD(Temporal Difference) ベースの actor-critic 型の強化学習の場合, 状態評価部 (critic) と動作生成部 (actor) の 2 種類の出力がある. そして, 状態評価値 (critic) $P(\mathbf{x}_{t-1})$ に対しては,

$$P_{s,t-1} = r_t + \gamma P_t(\mathbf{x}_t)$$

r_t : 報酬, \mathbf{x} : 状態 γ : 割引率 ($0 < \gamma < 1$) (1)

という教師信号が与えられてニューラルネットが学習される. ロボットが目標物に到達して初めて報酬がもらえるという設定であれば, 報酬 r_t が与えられない間は, 状態評価出力 $P(\mathbf{x}_t)$ は, 報酬に向かって, 時間に対して滑らかに指数関数的に増加するように学習が進む. つまり, 評価出力は, 報酬に到達するまでの時間を表現することになる. したがって, 障害物等がなければ, ロボットが目標物に近いと評価出力は大きく, 遠いと評価出力は小さくなる. そして, 中間層のパターン間の距離も, それに応じて変化ようになる.

一方, 動作生成部 (actor) の出力 \mathbf{a} は状態評価値 $P(\mathbf{x}_t)$ がより大きく変化するように学習が進む. そして, 目標物に到達するまでの時間が同じで, 評価出力が同じになる場合でも, ロボットの動作は, 目標物が右に見えるときは右回転, 左に見えるときは左回転, 正面に見えると前進と空間的な位置関係により求められる動作が変化する. こうして, 動作生成をする actor では, 目標物の周方向の位置によって, 求められる動作出力が異なってくる.

このように, ロボットから離れる径方向に対しては状態評価部の教師信号が滑らかに変化し, 円周方向には動作生成部

の教師信号が滑らかに変化する。そして、「教師信号パターン間距離が小さい方が、学習によって中間層パターン間距離が相対的に小さくなる傾向がある」ことによって、中間層では、入力された局所信号である視覚信号を統合し、二次元の大域的な空間情報を表現するようになったと考えられる。

また、文献³⁾では、ロボットが目標物に到達できるかどうかの境界の領域、および、ロボットの動作が回転から前進に変化する領域は、中間層において拡大して表現されている。前者は、目標物に到達できるかどうかで状態評価値が大きく変化する。後者は、その部分で動作が回転から前進に大きく変化する。いずれの場合も、空間的な位置が少しずれると出力が大きく変化するように学習されるため、結果的にその部分が中間層で拡大して表現されたと考えられる。状態評価値や動作が大きく変化するところは、ロボットにとって細かく知らなければならない重要なところであると考えれば、ニューラルネットを用いて強化学習を行うだけで重要な部分を中間層で拡大した合目的な状態表現が自律的に獲得できることになる。

また、このような空間認識能力は、さまざまなタスクで共通して利用できる情報と考えられる。したがって、一度学習してしまえば、次からは中間層における大域的な空間の上で汎化が可能となり、飛躍的に学習が効率化されると予想される。強化学習では、学習速度の遅さが致命的な欠点となっているが、本論文では、ニューラルネットの使用により、それを大きく改善する可能性を示したと考えられる。

6. まとめ

ニューラルネットでセンサ - モータ間が構成されたロボットが複数のタスクを行う場合、前のタスクの学習によって獲得された中間層表現に対し、別のタスクの学習時に「中間層レベルの汎化」が働くことによって行われる「知識の継承」の重要性を提起した。そして、その際に有効な中間層表現が獲得される理由として、「教師信号に近い方が、学習によって中間層表現も相対的に近くなる傾向がある」という仮説を立てた。そして、ランダム入出力パターンの学習のシミュレーションにおいて仮説が支持されたとともに、各パラメータによる影響を明らかにした。さらに、簡単な視覚センサ信号を入力とした場合に、空間に対して滑らかに変化する教師信号を与えると個々の中間層ニューロンが初期値の情報を保持しつつも、全体として教師信号に含まれた大域的な情報を表現するようになること、また、入力空間を分割し、それぞれで独立した教師信号で学習すると、片方の領域での学習が他へ干渉しないような中間層表現となること、さらにそのとき、各中間層ニューロンは、片方の領域の情報のみを表現するようにはならないことがわかった。今後は、実際に「知識の継承」が有効に働くのかどうか、複数のタスクをすることによる内部表現がどう変化するか、現在と過去の学習において、異なる中間層表現が求められた際に、異なる空間表現が一つの間層に共存できるかなどを探って行きたい。

謝辞


本研究は、日本学術振興会未来開拓学術研究推進プロジェクト「生物的適応システム」(JSPS-RFTF96100105) および科学研究費基盤研究 (No. 14350227, No. 15300064), 若手研究 (B)(No.13780295) の補助のもとで行われた。ここに謝意を表す。

参考文献

- 1) T. Kohonen, "Self-Organization and Associative Memory", Springer, New York Berlin Heidelberg, 1988.
- 2) S. Tanaka, "Theory of Self-Organization of Cortical Maps: Mathematical Framework", Neural Networks, Vol. 3, pp. 625-640, 1990
- 3) 柴田克成, 岡部洋一, 伊藤宏司, "ニューラルネットワークを用いた Direct-Vision-Based 強化学習", 計測自動制御学会論文集, Vol. 37, No. 2, pp. 168-177, 2001.
- 4) 柴田克成, 飯田大, "視覚センサ付き実ロボットによる箱押し行動の獲得", 第 14 回インテリジェント・システム・シンポジウム講演論文集, pp. 123-128, 2004.
- 5) Y. Chauvin, "A backpropagation algorithm with optimal use of hidden units", Advances in Neural Information Processing, Vol. 1, Morgan Kaufmann, pp. 519-526, 1989.
- 6) R.P. Gorman & T.J. Sejnowski, "Analysis of hidden units in a layered network trained to classify sonar targets", Neural Networks, Vol. 1, pp.75-89, 1988.
- 7) G.J. Tesauro, "Practical Issues in temporal difference learning", Machine Learning, Vol. 8, pp. 257-277, 1992.
- 8) N. Murata, S. Yoshizawa & S. Amari, "Network information criterion - Determining the number of hidden units for an artificial neural network model", IEEE Trans. on Neural Networks, Vol. 5, No. 6, 865-872, 1994.
- 9) D. E. Rumelhart, G. E. Hinton & R. J. Williams: Learning Internal Representations by Error Propagation, *Parallel Distributed Processing*, The MIT Press, 1, pp. 318-362 (1987)


[著者紹介]

柴田克成 (正会員)



1989年 東京大学大学院工学系研究科機械工学専攻修士課程修了。1989年 (株) 日立製作所に入社。1992年 10月 同社退職。1993年 東京大学大学院工学系研究科先端学際工学専攻博士課程中退。1993年 東京大学先端科学技術研究センター助手。1997年 東京工業大学大学院総合理工学研究科リサーチアソシエイト (日本学術振興会未来開拓学術研究推進プロジェクト研究員)。2000年 大分大学工学部電気電子工学科講師。2002年 同助教授。主として、ニューラルネットを用いた強化学習・自律学習システムの研究に従事

伊藤宏司 (正会員)



1969年 名古屋大学大学院工学研究科応用物理学専攻修士課程修了。1970年 同大工学部自動制御研究施設助手。1979年 広島大学工学部電気系助教授。1992年 豊橋技術科学大学情報工学系教授。1996年 東京工業大学大学院総合理工学研究科教授。主として、運動制御、ロボティクス、マンマシンインターフェースの研究に従事