

局所信号を入力とした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汎化

柴田 克成[†] 伊藤 宏司^{††}

[†] 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

E-mail: †shibata@cc.oita-u.ac.jp, ††ito@dis.titech.ac.jp

あらまし われわれ生物は, 視覚センサを始めとする局所的なセンサ信号を入力とし, 脳の中で大域的な情報を表現していると考えられる. 本論文では, 局所信号を入力として階層型ニューラルネットにさまざまな教師ありを行なった際の中間層を観察した. そして, (1) 空間的に滑らかに変化する教師信号で学習を行なった場合, 中間層がその変化する方向を表現するようになること, (2) 複数の中間層がある場合は上位の中間層ほどその傾向が強いこと, (3) 中間層ニューロン数が冗長の場合は, 初期重み値による情報を保持しながら全体として大域的な情報を表現していること, (4) 2つの入力領域で独立した教師信号を与えた場合, 片方の領域での学習が他の領域での学習に影響しないようになること, (5) またそのとき, 中間層ニューロンが片方の領域の情報のみ表現するようにはならないことがわかった. 以上より, 視覚信号をニューラルネットに入力し強化学習で学習を行なったときに中間層で大域的な空間情報が表現できるようになる [1] 理由として, 強化学習で状態評価値が時間とともに滑らかに変化することと, 評価値が同じ場所でも理想となる行動に少しずつ差があることが考えられる.

キーワード 階層型ニューラルネット, 局所化入力, 中間層表現, 汎化, 学習

Adaptive Space Reconstruction and Generalization on Hidden Layer in Neural Networks with Local Inputs

Katsunari SHIBATA[†] and Koji ITO^{††}

[†] Dept. of Electrical & Electronic Engineering, Oita University, 700 Dannoharu, Oita 870-1192

^{††} Dept. of Computational Intelligence and System Science, Tokyo Inst. of Tech., Midori-ku, Yokohama

E-mail: †shibata@cc.oita-u.ac.jp, ††ito@dis.titech.ac.jp

Abstract Our living creatures represent global information in their brain by integrating local sensory signals such as visual sensory signals. In this paper, the state of hidden layer in a layered neural network with local inputs after learning was observed for some cases. Some characters became clear as follows. (1) If the training signal changes gradually in space, the hidden layer becomes to represent the spatial information. (2) This tendency is stronger in the higher hidden layer. (3) If there are redundant hidden neurons, they represent the global information totally, while each of them keeps the initial fluctuation due to the initial connection weights. (4) If there is no correlation between the training signal of two input region, the learning of one region becomes not to influence to the learning of the other region. (5) However, the hidden neurons does not become to represent the information for only one region. From these results, the reason why the hidden layer becomes to represent spatial information by reinforcement learning [1] can be thought as follows. The state evaluation value changes gradually according to the time to the goal, while motion should change gradually for the states with the same evaluation value.

Key words layered neural network, localized input, hidden representation, generalization, learning

1. はじめに

実世界というさまざまな情報があふれかえっている状況の中で、われわれ人間が効率的に学習し、知的な行動を実行できる理由の一つとして「似たような状況では似たような行動をとる」ということがあげられる。これは、汎化によるものであると考えることができる。汎化とは、入力パターン間の距離が近ければ出力も近い値になるとことと一般に説明される。シグモイド関数を出力関数とした階層型ニューラルネットでは、シグモイド関数の滑らかさに基づいてこの汎化が働く。そして、これがテーブルルックアップ的な手法に対する一つの大きな利点となっている。この汎化は、過学習等との関係から、理論的な研究も進んでいる [2]。

しかし、われわれ人間をあらためて振り返ってみると「似ているかどうか」を、単に入力パターンの距離で判断しているだけではない。たとえば障害物を避ける場合、色や形が全然違う障害物があると視覚センサからの入力信号は両者の間で全く異なるが、位置や大きさが同じであれば、避け方はほとんど同じで良く、一から学習する必要はない。そもそも、われわれの持つ視覚センサセルの個々は、受容野が非常に局所的であり、見えている物体がちょっと横にずれば、入力は大きく異なったものになってしまう。しかし、われわれの意識下では、個々のセンサセルからの信号ではなく、右の方に見えているといった大域的な捉え方をしている。つまり、局所化された入力信号を脳内で統合して、再構成された空間上での距離を利用しているのではないかと考えられる。そして、その内部で形成された空間と出力との間で、前述の汎化に近い状態が働くことにより、われわれ生物は効率的な学習を可能にしているのではないかと推測される。

これらの機能は、一般的に生得的なものとして考えられがちであるが、縦じましか見えない環境で育てた仔ネコは縦の線によく反応するようになるという実験 [3] や自分で歩かないネコは空間認識能力の形成を阻害されるという実験 [4] などから、これらの機能の形成は、非常に柔軟であり、学習が大きく関わっていると推測される。

筆者らは、階層型ニューラルネットに局所的な受容野しか持たない視覚センサセルからの信号を直接入力として、強化学習のアルゴリズムによって自動生成された教師信号でバックプロパゲーション (BP) 法 [5] に基づく教師あり学習をさせることにより、中

間層に大域的な空間情報が表現され、かつ、その表現が、環境や動作特性などによって柔軟に変化することを確認した [1]。さらに、局所化された信号をニューラルネットに入力することによって、強い非線形関数を近似することが容易となるとともに、学習を高速化、安定化することもわかってきている [6]。

本稿では、この中間層での大域的な空間情報表現の獲得が、前述の、生体における脳内での空間の再構成に対応するのではないかとの立場に立つ。そして、大域的な空間情報の獲得と、そこでの汎化に対する理解を深めるために、視覚センサ信号を入力とする階層型ニューラルネットに対し、強化学習に基づく教師信号ではなく、意図的に作成した教師信号に基づく教師あり学習を適用する。そして、中間層の情報表現を直接または間接的に観察し、その仕組みおよび適応性を明確にする。学習による中間層でのコーディングの変化については、従来さまざまな解析なされてきているが、中間層ニューロン数を適切にする等の構造決定を目的としているもの [7]、および個々の中間層ニューロンの働きの解釈を目的としているもの [8][9] が多い。また、中間層と汎化の関係に関する研究もあるが、中間層ニューロン数と入力パターンに対する汎化の関係を扱ったものとなっている [10]。本稿では、入力パターンの違いによる中間層パターンの距離に注目して中間層での空間の再構成に関するいくつかのシミュレーションを行なう。そして最後に、強化学習によってどうして中間層に大域的表現が獲得されたかを考察する。

2. 入力レベルの汎化と中間層レベルの汎化

2.1 定義

図 1 に示したように、入力レベルの汎化とは、入力パターン間の距離が近い時にそれぞれを入力した時の出力も近い値になる現象であり、一般に言う汎化のことである。一方、中間層レベルの汎化は、たとえ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って、それぞれの出力値が近くなる現象のことと定義する。したがって、中間層レベルの汎化は、学習の進行によって入力層 - 中間層の結合重み値が変化するとともに適応的に変化する。

2.2 視覚センサ信号と空間情報

本節では、視覚センサ信号と空間情報を例として、同じ情報を表しながら、その表現方法によって汎化が大きく異なることを示し、中間層レベルの汎化に

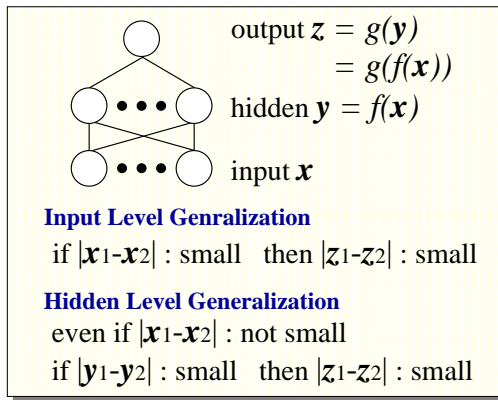


図1 入力レベルの汎化と中間層レベルの汎化の定義




図2 視覚センサ信号空間と物体の位置

期待されることを説明する。図2のように、10個のセンサセルが1列にならび、その前にある対象物を捕えている視覚センサを考える。各センサセルは、受容野に占める投射された対象物の面積の割合を0から1の間の連続値で出力するものとする。また、ここでは、簡単のため、対象物の大きさは、ちょうど1個のセンサセルの大きさと等しいものとする。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。この時、視覚センサ信号空間では、(a)(b)(c) の任意の2つのパターン間のハミング距離はすべて2であるが、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である。ここで、視覚センサレベルと、物体の位置 x というレベルでの汎化を考えると、後者は、空間の構造を反映しており、有効であると考えられる。そこで、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) が遠いという表現を学習によって獲得することが期待される。

2.3 中間層表現の不良設定性

一般的に、2つの入力パターンに対して同じまたは近い値の教師信号を与えて学習させると、学習後の中間層の表現も近くなると予想される。しかしながら、教師信号を実現するための中間層表現を一意に決定することはできないため、これを厳密に証明




図3 中間層レベル汎化の獲得の原理の模式図

することは難しい。たとえば、前節の問題で、物体の取りうる位置 x が、整数値のみであるとし、入力層、中間層ともニューロン数が10個で、出力層ニューロンが1個とする。そして、何らかの関数 $f(x)$ を教師信号として、この出力層ニューロンを学習させるとする。このとき、各中間層ニューロンが、全ての入力層ニューロンからの信号を受けているという表現でも入出力関係を実現できるし、入力層ニューロンと中間層ニューロンが一つづつペアとなって、それ以外の結合がない場合でも、その関係を実現することが可能である。もし、獲得された中間層表現が後者のようなものであれば、中間層レベルでの汎化には意味がなくなってしまう。しかし、実際にBP法によって学習を行うと、このような不良設定性があるにもかかわらず、学習時の出力の値が近いものは、たとえ入力パターンが遠くても中間層での表現が近くなり、汎化が有効になるという傾向が観察される。

2.4 同一教師信号での学習による中間層表現接近の原理

本節では、簡単な例を使って、同じ教師信号を与えて学習すると、中間層表現が近くなる理由を模式的に説明する。図3のように、各層のニューロン数が、入力側から2-2-1で中間層-出力層間の結合の重み値がすべて0の3層ネットワークを考える。入力層-中間層間は、入力ニューロン1(以下入力1とする)と中間層ニューロン1(以下中間層1とする)、入力2と中間層2の間は結合が形成されており、それ以外の結合は重み値0とする。そして、入力1(1,0)と入力2(0,1)の両者に対し、出力が0.9になるように学習するとする。また、学習定数は小さく、かつ、両入力パターンは交互に提示されて学習するものとする。

まず、(1)入力1が提示されて学習すると、中間層

1 - 出力層間の重み値が大きくなる．次に，(2) 入力 2 が提示されると，誤差信号 δ は中間層 1 へ伝播し，入力 2 - 中間層 1 の結合と中間層 2 - 出力層の結合が強化される．そして，(3) 再び，入力 1 が提示されると，学習定数が小さいため，誤差は減らず，入力層 1 から中間層 2 への結合も強化される．こうして，(4)(5) 各入力パターンに対して 1 つの中間層ニューロンしか発火しなかったものが，両方の中間層ニューロンが発火するようになる．つまり，入力パターンが違ってても，誤差が等しければ，中間層に伝播してくる誤差信号が等しいということが鍵となっていることがわかる．また，これに，入力レベルでの汎化が働くとともに，誤差の減少のために，中間層ニューロンは，その値域をたくさん使って表現しようとする．よって，出力が近いものは中間層の表現も近くなり，出力が遠いものは，中間層の表現も遠くなる可能性が高くなると考えられる．これは，ちょうど自己組織化マップ (SOM) [11] の仕組みと似ている．ただし，学習係数を大きくし，学習パターンの順番を調整することで，教師信号が同じでも伝搬誤差が異なるようにすることができるとは，その場合でも中間層の状態が近くなる傾向が見られるため，単純に上記の理由だけですべて説明できるわけではない．

3. シミュレーション

本章では，前章で述べた中間層での空間の再構成を簡単なシミュレーションを通して実際に観察する．

3.1 一次元の広がりを持つ視覚センサ信号

まず始めに，2.2 節で示した例題でその機能を確認する．図 4 のように，10 個の視覚センサセルの出力を 3 層ニューラルネットに入力する．そして，物体の位置 x を乱数を使って 0 から 9 の間の連続値で決定し，物体の位置 x とネットワークの出力が比例するように $0.09x + 0.1$ を教師信号として 1 回だけ学習させた．そして，物体の位置を変化させてこの 1 回の学習を繰り返した．各ニューロンの出力関数は 0 から 1 の値域を持つシグモイドとし，中間層のニューロン数は 10 個とした．重み値は，入力層 - 中間層間は -1 から 1 の乱数とし，中間層 - 出力層間は 0 とした．また，学習係数は 0.1，慣性項は 0.9 とし，BP 法 [5] で学習を行なった．

10000 回学習し，誤差がほぼ 0 となった後，中間層から出力層への結合の重み値をすべて 0 にリセットし，再び，視野の両端だけ同じ教師信号で学習させ，内挿がどのように働くかを調べた．この時も，10000 回学習させ，誤差はほぼ 0 となった．物体の位置 x




図 4 物体の位置の学習

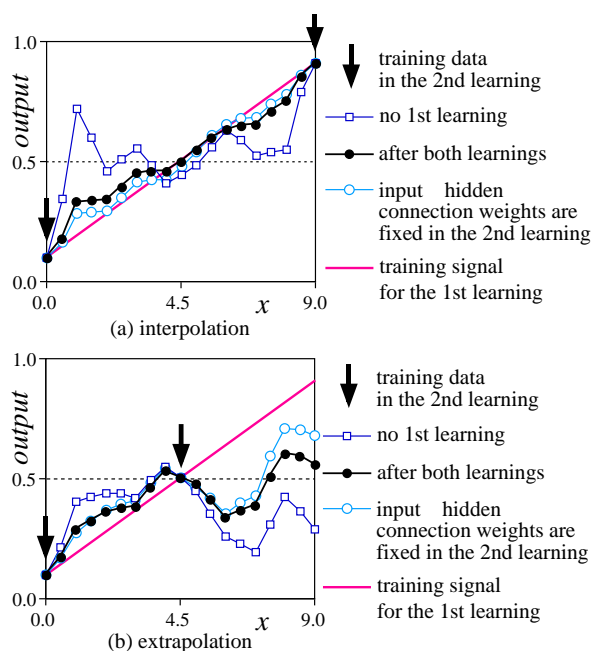


図 5 物体の位置 x を学習させた後，中間層 - 出力層間の結合の重み値を 0 にリセットし，その後視野中の 2 点のみで学習させた時の出力の分布

に対する出力の分布の例を図 5(a) に示す．物体の位置を最初に学習させた場合，2 回目の視野両端での学習だけで，最初に学習した出力分布に近い分布となっている．これに対し，最初の学習を行っていない場合は，2 回目の学習では，両端以外のところでは視覚センサ出力が 0 であるため，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しない．よって，出力は 0.5 近傍で変動しているだけとなる．また，最初の学習の後に，入力 - 中間層間の結合の重み値を固定し，中間 - 出力層間の結合のみを学習させた場合は，もとの学習した出力分布に最も近い分布となっている．これは，入力 - 中間層間の結合の重み値を固定しないと，視野の両端の学習によって，中間層での表現が多少崩れるためである．しかし，その差は，最初に学習していない場合と比較してあまり小さくなく，また，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方が自然であると考えられる。

次に、2 度目の学習で与える教師信号の位置を、 $x = 0$ と $x = 4.5$ とし、外挿がどのように働くかを観察した。その結果を図 5(b) に示す。ここでは、2 度目の学習で与えた教師信号が 0.1 と 0.505 とニューロンの値域の中で小さい値であったため、出力ニューロンのバイアスが小さくなり、最初の学習をしなかった時の $x > 4.5$ での出力は 0.505 よりも小さくなっている。しかし、最初の学習をした場合の $x > 4.5$ での出力分布は、最初の学習の教師信号とは大きく離れてはいるものの、最初の学習を行なわなかったときと比較するとかなり近くなっていることがわかる。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。

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、その時の各中間層ニューロンの出力パターンと $x = 0$ の時のパターンとの距離、ここでは各ニューロンの出力の差の絶対値の和を観察した。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場合と行っていない場合にわけて、図 6 に示す。ニューラルネットの初期値によって、ばらつきはかなりあるものの、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いる。それに対し、最初の学習を行っていない場合は、物体の位置 x が 1 以上の際に相関がない。また、ここでは、物体の位置を 0.5 ずつ変化させて出力を観察しているが、位置が 0.5 増えるごとに出力が大きくなったり小さくなったりしている現象が見られる。これは、物体の位置が 1 で割りきれられる場合は、物体がちょうど 1 つのセンサセルに収まった状態で、出力は 1 が 1 個で他がすべて 0 である。それに対し、それ以外の場合は、物体が 2 つのセンサセルにまたがっている状態で、出力は、2 つが 0.5 で、他が 0 となるという違いによるものである。また、学習係数、慣性項、初期重み値の乱数の大きさを変化させたり、中間層 - 出力層間の初期重み値も乱数で決定した場合について、同様のシミュレーションを行なった。すると、初期重み値の乱数の大きさを大きくすると距離が大きくなり、小さくすると小さくなるという傾向が出たが、それ以外はあまり大きな差異は出なかった。

次に、中間層を複数層設けたときに、複数の中間

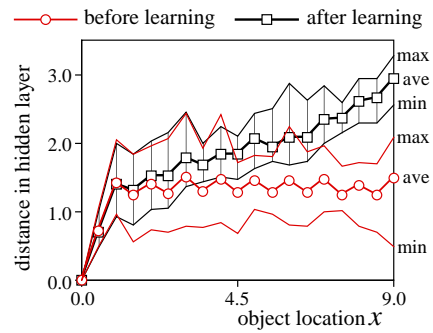
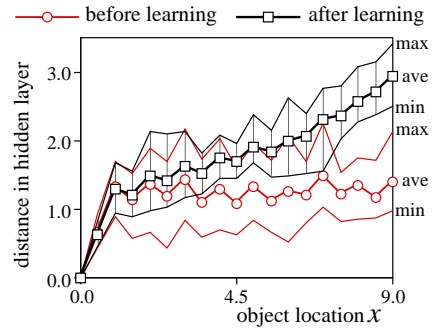



図 6 物体の位置が 0 の時と x の時の中間層パターンの距離の学習による変化。



(a) lower hidden layer



(b) higher hidden layer

図 7 4 層ニューラルネットにおける物体の位置が 0 の時と x の時の中間層パターンの距離の学習による変化。

層間で表現がどう違うかを調べた。中間層が 2 層(共に、ニューロン数を 10 個とした)の 4 層ニューラルネットでも前述と同様の学習を行った。そして、物体の位置が 0 の時と x の時の各中間層でのパターン間の距離を図 7 に示す。これより、第 1 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、第 2 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その表現を変化させていると予測される。

次に、実際に、学習前と学習後の各中間層ニューロンの表現がどのようになっているかを 3 層ニューラルネットの場合について図 8 に示す。この図から、各

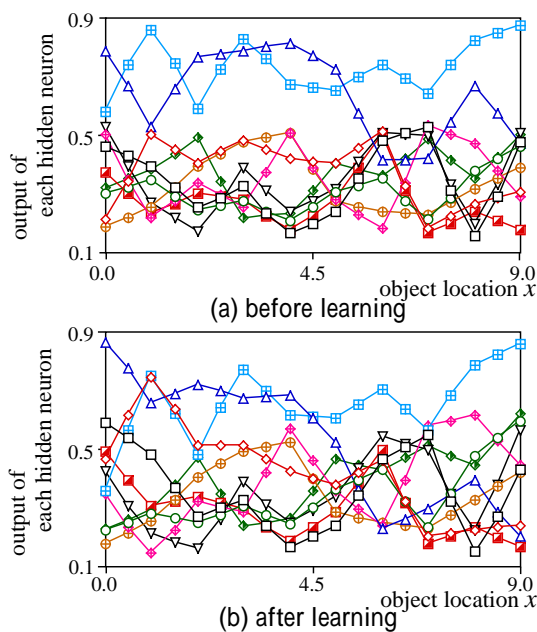


図 8 学習による物体の位置 x による各中間層ニューロンの出力値 .

ニューロンは学習後も初期状態に近い発火状態を保ちながら，物体の位置 x に対して，右上がりまたは左上がりの傾向を多少強くすることで大域的情報を表現していることがわかる．そこで， $x = 0$ 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 0.170 であったものが，学習後には 0.313 と 2 倍近くになっていた．また，中間層ニューロン数を 1 個にすると，物体の位置に対してそのニューロンの値は，単調増加または単調減少となったことから，ニューロン数を冗長にすることによって，個々のニューロンは必ずしも単調増加や減少にならず，初期重み値の情報を保持しながら，ニューロンの集団として大域的情報を表現していることがわかる．

3.2 二次元の広がりを持つ視覚センサでの学習

次に，2次元空間で，そのうちの1次元について学習させた場合に中間層の表現がどうなるかを観察した．図9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，物体がセンサ上のどこかに投影されているとする．ここでも，簡単のため，1つのセンサセルの大きさ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，図10(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する．そして，物体の位置を乱数で決定し，その教師信号を使ってニューラルネットワークを学習させる．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




図 9 二次元の広がりを持つ視覚センサによる物体の位置の学習

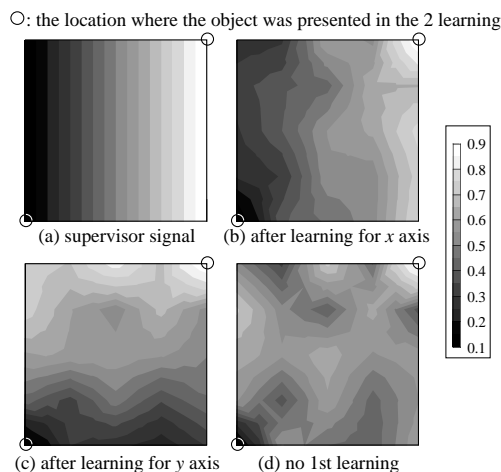


図 10 二次元視覚センサにおける最初の学習による影響

結合の重み値を 0 にリセットし， $(x, y) = (0.0, 0.0)$ と $(x, y) = (4.0, 4.0)$ という視野の左下と右上に物体を置いて，その2つの場合についてのみ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図10(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，学習前のニューラルネットの初期値を同じとし， y によって教師信号が変化するようにして学習させたものを図10(c)に，最初の学習を行わなかったものを図10(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，次の学習では，中間層レベルの汎化が起こっていると考えられる．また，見方を変えたと，中間層を共有することで，中間層での汎化を通して，最初の学習の知識が次の学習に伝えられると言える．

3.3 学習による空間の分離

本節では，視覚センサを2つの領域に分割し，それぞれの領域において，物体の位置から教師信号を




図 11 学習による空間の分離の検証のためのシミュレーション

生成する式を独立に与えて学習させた場合に、中間層表現において2つの領域がどのように表現されるかを調べた。図 11 のように、 8×4 の視覚センサをそれぞれ 4×4 の領域 A と領域 B に分けた。そして、教師信号 O_{ideal} は、 z 軸を教師信号とした場合に、それぞれの領域で平面となり、最大値、最小値が 0.9, 0.1 になるという拘束の下で乱数を用いて独立に設定した。そして、物体の位置を乱数で決定して1回学習させ、物体の位置を変化させて、1000回学習させる。これを1セットとし、教師信号の平面を変え、ニューラルネットの中間層 - 出力層の結合の重み値をすべて0にリセットして、再び1セットの学習を行う。こうして、全部で100セットの学習を行った。中間層ニューロン数は4個とした。

学習後の入力層 - 中間層間の結合の重み値を図 12 に示す。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場合もあった。

図 13 に、学習後に、中間層 - 出力層の結合の重み値を0にリセットした後、領域 A において、右上、右下、左下の3箇所に物体を置いた場合に対して教師信号を与えて学習し、物体の位置による出力の分布を示した。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出力になっており、領域 B では、すべての出力が0に近い値となっていることがわかる。これは、




図 12 学習後の入力層 - 中間層間の重み値。大きさが絶対値、色が符合を示す

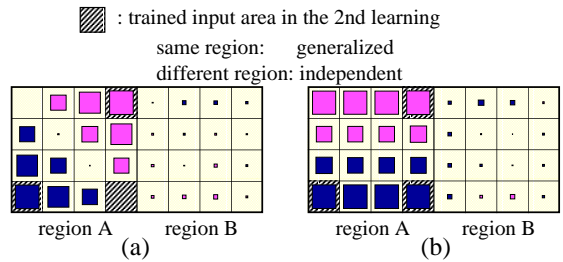


図 13 3箇所の訓練データ学習時の出力の分布。大きさが絶対値、色が符合を示す

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ことを学び、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ことがわかる。ここで、再び図 12 を見ると、領域 A の x 方向は、中間層ニューロン1と中間層ニューロン2の値を足すことによって、領域 B に関する情報が消されることがわかる。当初は、4つの中間層ニューロンのうちの2つが領域 A のコーディング、残りの2つが領域 B のコーディングに使われることを期待していたが、これとは違った形で領域 AB の分割を行っていたことがわかった。また、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 だけ結合を持たせて、やはり90度表現する方向をずらして学習したにもかかわらず、何回か学習すると、図 12 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とから、こちらの方が学習が安定であることがわかった。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であると考えられる。

次に、中間層における汎化というもの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




図 14 学習セット数による学習速度の変化 (10 セット平均)

ことである。図 14 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がどのように変化したかを示す。各セットの始めに、中間層 - 出力層間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で汎化という形で利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、セット内での学習速度が向上することがわかる。

4. 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 章でも述べたように、筆者らは、移動ロボットの視覚信号を入力としたニューラルネットを強化学習で学習させることにより、中間層に大域的な空間情報が表現されていることを示してきた [1]。ここで、なぜ強化学習を適用するだけで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。強化学習では、状態評価値が時間的に滑らかに変化するように学習が進む。目標物がロボットの近くにあれば、そのときの評価値は大きく、遠くに離れば、評価値は小さくなる。そして、その間は、ロボットの動きにともなって、視覚センサ信号が徐々に変化し、状態評価値の教師信号も徐々に変化していく [12]。これによって、目標物がロボットの近くかどうかで中間層のパターン間の距離が変わる。さらに、評価値、つまり、目標達成までの所要時間が同じでも、求められる動作が、物体が右に見えるときは左回転、左に見えるときは右回転となる。よって、物体の見える位置が右か左かで中間層のパターン間の距離が変わる。この 2 つの要因から、物体の位置という大域的な空間情報が中間層できれいに表現されるようになったと考えられる。

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、非常に学習が効率的になると考えられる。

5. まとめ

局所入力信号をニューラルネットに与えて教師あり学習を適用し、中間層の情報表現を観察した。そして、空間に対して滑らかに変化する教師信号を与えると中間層がその情報を大域的に表現ようになること、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。

謝辞 本研究の一部は、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) および文部省の科学研究費基盤研究 (No. 09750484), 奨励研究 (No. 13780295) の補助の下で行われた。ここに謝意を表する。

文 献

- [1] 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, Feb. 2001.
- [2] 甘利俊一ら, “学習の数理モデル—汎化能力と過学習”, 脳の高次情報処理, 朝倉書店, 1997.
- [3] H.V.B. Hirsch & D.N. Pinelli, “Visual Experience Modifies Distribution of Horizontally and Vertically Oriented Receptive Fields in Cats”, Science, Vol. 168, pp. 869-871, 1970.
- [4] R. Held & A. Hein, “Movement-Produced Stimulation in the Visually Guided Behavior”, J. of Comp. Physiol. Psychol., Vol. 56, pp. 872-879, 1963.
- [5] 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)
- [6] 柴田克成, 前原伸一, 杉坂政典, 伊藤宏司, “Gauss-Sigmoid ニューラルネットワーク”, 第 12 回自律分散システムシンポジウム資料, pp. 133-138, 2001.
- [7] Y. Chauvin, “A backpropagation algorithm with optimal use of hidden units”, *Advances in Neural Information Processing*, Vol. 1, Morgan Kaufmann, pp. 519-526, 1989.
- [8] 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.
- [9] G.J. Tesauro, “Practical Issues in temporal difference learning”, *Machine Learning*, Vol. 8, pp. 257-277, 1992.
- [10] 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.
- [11] T. Kohonen, “Self-Organized Formation of Topologically Correct Feature Maps”, *Biol. Cybern.*, Vol. 43, pp. 59-69, 1982.
- [12] 柴田克成, 岡部洋一: 時間軸スムージング学習, 電気学会論文誌 C 分冊, Vol. 117-C, No. 9, pp. 1291-1299, 1997.