

# 認識の学習に基づく注意と連想記憶の形成

柴田克成 伊藤宏司

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

横浜市緑区長津田町 4259

{shibata, ito}@ito.dis.titech.ac.jp

あらまし

実世界で自律学習ロボットを用いるには、空間的にも時間的にも膨大なセンサ信号をいかに効率よく利用するかがポイントとなる。これを解決する手段として、過去の文脈に基づく「選択的注意」が挙げられる。一方、連想記憶の研究において、何をどのように記憶させるか、つまりコーディングの問題はクリアではない。本論文では、Elmanタイプのリカレントニューラルネットで認識の学習をさせるだけで、過去の文脈の抽出、記憶、そして注意までの一連の機能を一貫して合目的に学習させることができることを示した。そして、文脈の保持、つまり「短期記憶」が連想記憶の働きをし、ベイスンの数が必要に応じて適応的に形成されることを示した。その際、中間層の表現が自律的に形成されることから、連想記憶におけるコーディングの問題に対する解となるものと考えられる。

キーワード：選択的注意、短期記憶、連想記憶、リカレントニューラルネット、文脈、遅延見本合わせ課題

## Formation of Attention and Associative Memory Based on Recognition Learning

Katsunari SHIBATA and Koji ITO

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

4259 Nagatsuta, Midori-ku, Yokohama 226-8502, Japan

{shibata, ito}@ito.dis.titech.ac.jp

*Abstract* - For the application of the autonomous learning robot to the real world, it is important to deal with the huge amount of sensory signals. "Selective attention" based on the context is one of the useful ways to solve the problem. On the other hand, in the research of the associative memories, how to code the information has not been clear yet. Then, in this paper, it is shown that "extracting and keeping the context" and "selective attention" can be acquired purposively only by the learning of the recognition using Elman-type recurrent neural network. Furthermore, it is also shown that the short-term memory to keep the context has an ability of the associative memory, and the number of the basins changes adaptively and purposively. The representation of the hidden layer is acquired autonomously, and the authors think that it can be one of the solutions for the autonomous coding in associative memories.

Keywords: selective attention, short-term memory, associative memory, recurrent neural network, context, delayed match to sample task

## 1. はじめに

われわれ生物は、センサ信号から外界の状態を認識し、状況に応じた行動を生成している。しかし、センサ信号の数は非常に多く、その中から必要な情報を瞬時に抽出することは難しい。これに対し、過去の文脈情報を用いて、必要な情報がどこにあるかを予め絞る 選択的注意 の機構が効率的な認識の実現に大きく寄与していると考えられる。もちろん、過去の文脈情報としてセンサ信号や行動の履歴をすべて記憶するのは、大変効率が悪い。したがって、必要な時間に必要な情報を抽出し、記憶することもまた、効率的な認識、ひいては有効な行動生成に大きく寄与していると考えられる。われわれが作るロボットを、実世界で利用できるものとするためには、この"注意"の機構の導入が不可欠であると考えられる。

筆者らは、システム全体が合目的的、適応的かつ調和的に動作する自律学習ロボットの実現を目指して研究を進めてきた。そのためには、従来のように、注意、認識、記憶、思考、行動といった各機能モジュールに分解して考えるのではなく、センサからモータまでをシームレスな構成にすべきであると考えてきた。これにより、モジュール間インターフェースの設定が不要となり、システムの柔軟性が増すとともに、システム全体を調和的に学習することが容易になる。また、その際に、非線形変換、そして、記憶の機能の必要性を考慮し、リカレント型のニューラルネットの利用が最適であると考えた。また、さらに、これらの機能をより良い行動に結びつけるためには、このニューラルネットを強化学習によって学習させることが良いと考えた。筆者らは、このような考えに基づいて、ニューラルネットと強化学習の組み合わせでどのような機能まで実現可能かを探求してきた。そして、現在までに、視覚センサ信号をニューラルネットに直接入力として、障害物回避、認識[1]、能動認識(視点移動)[2]、さらに hand-eye coordination[3]の機能を学習できることを確認した。本研究では、前述のように、実世界への適用を考えた際に非常に重要になる、過去の必要な情報(文脈)の抽出、記憶、そして、それに基づいた注意の機能をニューラルネットによって学習できるかを検討する。ただし、簡単のため、ここでは強化学習を適用せ

ず、認識と行動の間のマッピングはすでに獲得できていて、正しい認識をすると報酬がもらえるものと仮定し、認識の学習を行うという問題設定とする。

## 2. 関連研究との比較

注意(能動的注意)は、過去の文脈によって切り替わるべきものであり、また、逆に、文脈の抽出、保持は、適切な注意を向けるためのものでなければならない。そのような意味で、注意と文脈の抽出、保持は、一体として学習すべきであると考えられるが、それら一連の機能を学習によって実現させた例は見当たらない。

阪口らは、複数種類の触覚信号のどれを選択するかを決めるために、観測後に対象の内部像のエントロピーができるだけ減少する、つまり、相互情報量の大きな情報源を選択するというモデルを提案している[4]。しかし、文脈によっていかに注意を切り替えるか、また、有効な注意を行うための文脈をいかに抽出するかについては考慮されていない。

また、McCallum も、選択的注意と短期記憶に言及している[5]。彼は、不完全知覚下での強化学習における状態決定の際に、過去すべての情報を見る必要がないこと、現在のセンサ信号が同じでも、過去のセンサ信号から状態の区別ができるということ指して、注意、記憶と呼んでいる。本稿では、現在のセンサ信号のどこに注目するかを注意と呼んでおり、そのための必要な情報の短期記憶とあわせて、観点が大きく異なる。

一方、リカレントネットを用いた記憶として、連想記憶がある。Hopfield 以来、連想記憶の研究が盛んに行われ、記憶容量などさまざまな性質が明らかになっている[6]。連想記憶の学習には、Hebb 則がよく用いられる。しかし、Hebb 則では、目的指向の学習をさせることは困難である上、記憶させる情報を取捨選択し、その表現を自律的に獲得することはできない。

そのような中で、Zipser は、サルなどを使って行われる遅延見本合わせ課題(delayed match to sample task)[7][8]に焦点を当て、そのモデルとして、BPTT(Back Propagation Through Time)[9]で Elman 型のネットワーク[10]を学習させることを提案している[11]。遅延見本合わせ課題とは、最初にある視覚パターンを見せ、ある時間経過後に見せたパターンが最初のパターンと同じかどうかを答えさせるタスクである。そこで彼は、ア

ナログ信号とゲート信号の2つを入力とし、ゲート入力が入力になった時のアナログ入力を保持するように教師あり学習を行わせた。そして、中間層ニューロンが、ゲート信号入力時に新たな値を取り込み、ゲート入力がない場合に、その値を保持し、固定点に収束するダイナミクスを獲得していることを示した。また、その時の中間層の出力パターンが実際に脳で観察されたニューロンの発火パターンに類似していることを示した。しかし、画像の代わりに一つのアナログ信号を入力し、それをそのまま記憶させて出力とするという問題設定のため、認識、注意、連想記憶の自律的コーディングという点に関しては問題としていない。さらに、記憶を学習させるために、記憶させる値をそのまま教師信号として常時与えている。

本稿でも、Zipser と同様に遅延見本合わせ課題を参考にする。ただし、ここでは、視覚センサを想定し、最初に矢印のパターンを見せ、ある一定時間経過後に、別のパターンを同じ視覚センサに入力し、最初に提示した矢印の方向にある図形の形が  $\times$  かを学習させる。したがって、入力信号は、多次元である。また、最初の矢印は位置ずれを許容するため、矢印の向きで分類するには、入力パターン間の距離によらない分類をすることが要求される。また、教師信号は、ある時間経過後に、認識した結果の誤差という形で与える。これだけの情報から、矢印の向きが抽出されるか、そして、その際に、中間層の表現がどのようになり、また、時間の経過とともに固定点収束のダイナミクスが得られるのか、さらに、その記憶してきた矢印の方向の情報を使って、次に入力されたパターンの注意する領域がどのように決まるのかを検証する。そして、連想記憶という観点からは、そのコーディングが学習によって必要に応じて自律的に形成されることを示す。

### 3. ネットワークと学習

使用するニューラルネットは、Zipser と同様に、Elman 型のニューラルネット[10]、つまり、通常の階層型ニューラルネットにおいて、中間層の値を、次の時刻の入力として与える形のものとした。この入力をフィードバック入力と呼び、フィードバック入力から中間層への結合をフィードバック結合と呼ぶ。時間は、離散時間とし、各ニューロンは、-0.5 から 0.5 の値域を持つシ

グモイド関数とした。学習も、Zipser と同様に BPTT (Back Propagation Through Time)[9]とし、教師信号は最終時刻のみ与え、それ以外の時刻では与えない。入力層 中間層の初期重み値は微小乱数とし、各中間層ニューロンの内部状態  $u$  は 0 に近い値となるようにした。また、フィードバック結合の初期重み値は、自分自身への結合を 4.0、それ以外を 0.0 とした。BPTT の伝播誤差信号  $\delta$  の値は、時間を 1 単位時間さかのぼると、

$$\delta = f(u) W^T \delta \quad (1)$$

$\delta$ : 中間層の伝播誤差信号ベクトル、 $f(u)$ : 中間層の出力関数(シグモイド関数)の導関数、 $W$ : フィードバック結合の重み値行列

となる。 $f(u)$ の各成分は  $u=0.0$  で最大値 0.25 となるため、上記のようにフィードバック結合の重み値行列を設定することで、ゲインが単位行列に近い値となり、効率的に誤差が過去に伝播する。また、バイアスが 0 で、他からの結合がなく、セルフフィードバック結合が 4.0 より大きくなると、出力 0 が不安定平衡点となる。そして、0 以外に 2 つの安定平衡点が出現し、2 値の値を記憶できるようになる。したがって、フィードバック結合の重み値の初期値をそれに近い値とすることで、学習による短期記憶の形成が容易になる。

## 4. 遅延認識課題

### 4.1 問題設定

まずはじめに、注意の問題は扱わず、純粋に、最初に入力した視覚パターンを、ある時間経過後にどの分類に入るかを認識する問題を考える。Fig. 1 に学習の流れを示す。まず、 $7 \times 7$  の 4 つの画像イメージを与える。ここでは、左下、右下、左上、右上の 4 つの方向を向いた矢印(それぞれ 90 度ずつ回転させたもの)を想定する。Fig. 1 に左下を向いた矢印を示す。これに対し、乱数によって 2 回に 1 回の割合で、ランダムに選ばれた 1 ピクセルの白黒を反転させる。この画像の一部を  $5 \times 5$  の視覚センサがとらえるものとし、画像の左下を基準に、視覚センサのずれを、左、上それぞれ 0, 1, 2 の中からランダムに選ぶ。選び方は、 $3 \times 3 = 9$  通りとなる。そして、白い部分は -1.0、黒い部分は 1.0 の値を視覚センサの出力としてニューラルネットに入力した。出力ニューロンは 4 つ設け、ある時間経過後に矢印の向きに該当するニューロンに 0.4、それ以外に -0.4 の教師信

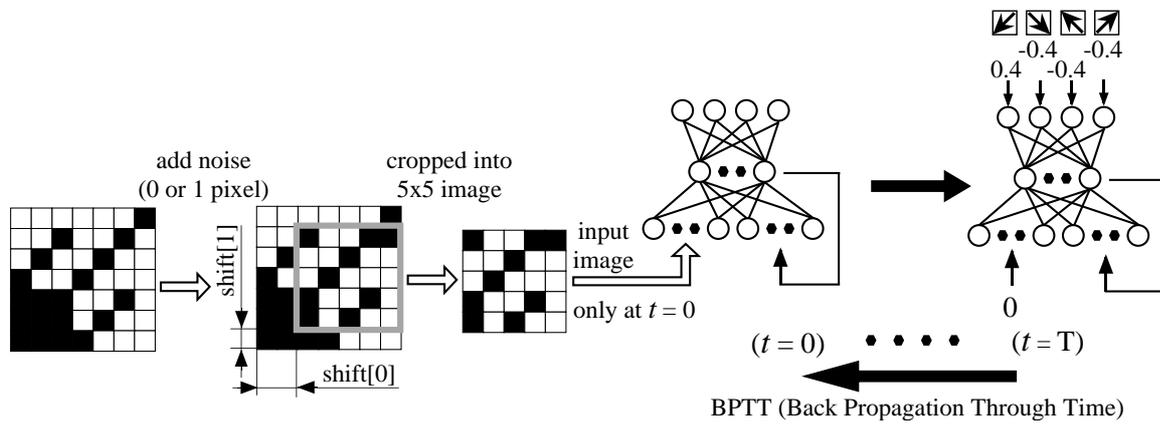


Fig. 1 遅延認識課題の流れ

号を与えて学習した。ただし、入力を与えるのは、 $t=0$ の時だけとし、それ以外の時は、すべて0を入力した。

Fig. 2 に、例として、左下と右上の矢印をもとにしたそれぞれ2つの入力信号、計4つを示す。Fig.3 の一番左の表のように、1a と 1b、2a と 2b が同じ分類となるが、ハミング距離では、1a と 2a、1b と 2b が近い。

#### 4.2 学習結果

中間層ニューロン6個のニューラルネットで学習後に、Fig. 2 に示した4つのパターンを入力した際の、中間層のパターン間の距離と、出力の距離を Fig. 3 に示す。上

段は、 $t=0$  で入力を与え、遅延なく、 $t=0$  で教師信号も与えて学習させた場合である。それに対し、下段は、 $t=5 \sim 14$  の間で毎回ランダムに決められた時刻  $T$  に教師信号を提示して学習させた後に、 $t=0$  と  $t=10$  での中間層パターン間の距離と  $t=10$  での出力間の距離を示す。両者とも、学習後の誤差はほぼ0となった。

遅延なく学習させた場合は、中間層の各パターン間の距離比が、入力間の距離比と、出力間の距離比のちょうど中間的な値を示している。それに対し、遅延学習をさせた場合には、 $t=0$  では、むしろ中間層のパターン間の距離比は、入力の距離比に近く、それから  $t=10$  までの間に、中間層のパターンが中間層 入力層 中間層のフィードバックループを通ることによって出力層のパターンの比に近づいていることがわかる。

また、遅延なく学習させた際の入力層から中間層への結合の重み値および中間層のバイアス値を初期値としてリカレントネットの学習させても、学習はうまく進まなかった。これは、中間層のバイアス値が、中間層

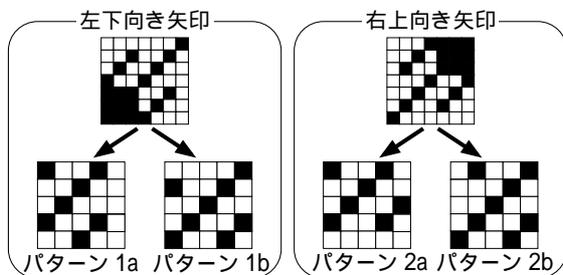


Fig. 2 入力パターンの例

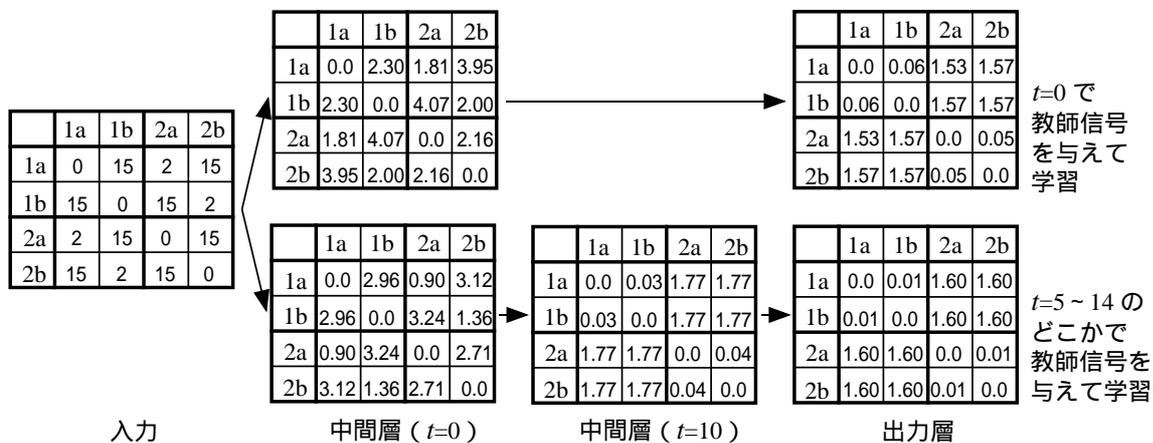


Fig. 3 学習後に、Fig.2 のパターンを入力した際の、入力、中間層パターン、出力パターン間の距離

入力層 中間層のループにおいても使用されるため、最初の時刻での中間層の値が保持されないからである。そこで、フィードバック結合の初期値を 100.0 と大きな値にすると、ループにおけるバイアスの影響が小さくなるため、学習することなく誤差はほぼ 0 になった。

もう一つ両者の大きな違いとして、フィードバック結合を除く入力層と中間層間の重み値の絶対値の大きさの違いがあげられる。遅延のない場合は、重み値の絶対値が大きく、ある時の学習後のネットワークを見ると、平均で 1.75 であったのに対し、リカレントの場合は、平均で 0.52 であった。そして、中間層の値は、前者の場合、シグモイド関数の完全に飽和した領域、つまり、-0.499 とか 0.499 といった値をとる場合が多いのに対し、遅延学習させた場合は、0.4 や -0.4 近辺の値をとるものも多かった。これは、 $t=10$  になっても同様であった。この問題では、同一カテゴリのパターン間の距離がばらばらであり、強い非線形性が要求される。そして、前者の場合、入力層 中間層 出力層の 2 回の変換で目的の値にならなければならない。さらに、出力層では、教師信号が 0.4 または -0.4 となっているため、飽和領域のような強い非線形変換は期待できず、結局、中間層で飽和領域の値をとって強い非線形変換をせざるを得ないと考えられる。それに対し、遅延学習させた場合は、ループによる固定点収束がその役割を果たしている。つまり、連想記憶の機能が形成されているため、 $t=0$  の時には、そのベイスン上のどこか一

点への変換をすれば十分であり、かつ、そのベイスン自体も学習によって適応的に形成されていると考えられる。よって、必ずしも飽和領域を利用する必要がなく、さらに、 $t=10$  での中間層のパターン間の距離は、同一カテゴリのものは同一の固定点に収束しているため、ほとんど 0 となっていることがわかる。

## 5. 遅延注意課題

### 5.1 問題設定

次に、文脈による注意を必要とする問題を考える。Fig. 4 にその流れを示す。最初の入力に関しては、基本的に前章の遅延認識課題と同じである。ただし、ここでは、問題をあまり難しくしないため、この時点でのノイズは与えなかった。そして、 $t=5 \sim 14$  の間のランダムに決められた時間  $T$  経過後、今度は、 $t=0$  で矢印の画像を入力した  $5 \times 5$  の視覚センサに、左下、右下、左上、右上の  $3 \times 3$  の領域にそれぞれ  $\times$  をランダムに配置した画像を入力した。このとき、 $5 \times 5$  のたて横それぞれ真中の 1 列、1 行は、複数の  $3 \times 3$  の領域がオーバーラップするため、その部分は、平均値を出力とした。そして、ランダムに 0 か 1 ピクセルのノイズ (値を反転させる) を加えた。たとえば、Fig. 4 中の例では、左下が  $\times$ 、それ以外の 3 つには  $\times$  を配置した例である。そして、最初に入力した矢印の向いている方向の領域にある図形が  $\times$  を 1 つの出力ニューロンに学習させ、それ以外の領域の図形は出力に影響を及ぼさない。Fig. 4 の例では、入力している矢印が、左下を向いており、 $t=T$  の入力パターンにおいてその左下の領域の図形は  $\times$  で

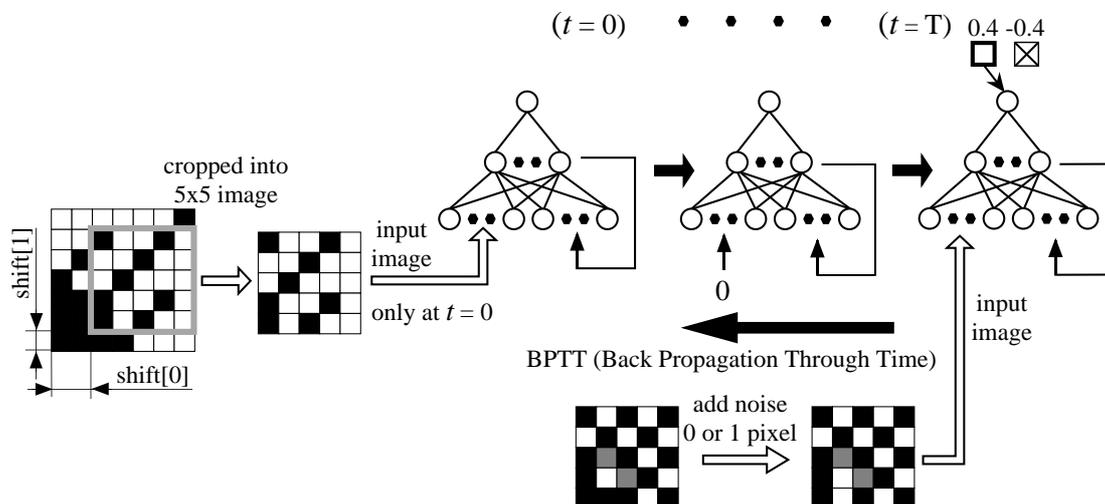


Fig. 4 遅延注意課題の流れ

あるため、 をあらわす 0.4 が教師信号として与えられ、ニューラルネットを BPTT で学習する。この時、教師信号は図形が か×を表しているのに対し、抽出、記憶させる文脈情報は矢印の向きを表しており、かなり異質なものとなっていることがわかる。

## 5.2 学習結果

中間層ニューロン数を変化させたところ、5個で学習できた。Fig. 5 に学習後の中間層ニューロンの値、および各結合の重み値の値を示す。最初の入力は、7x7 の4つの矢印の画像から 5x5 の画像を切り出すため、それぞれ9種類の入力が見られる。いずれの場合も、同一カテゴリの入力に対しては、 $t=9$  の時点で、中間層のパターンは同じ値に収束した。その時の値を Fig.5 の上部真中に示す。そして、 $t=10$  で Fig.5 の真中右にある2つの入力パターンをそれぞれ入力すると、Fig.5 上部右図のように中間層ニューロンの値がそれぞれ上段と下段のように変化した。そして、最終的には、中間層から出力層への重み値からわかるように、最初の4つの中間層ニューロンのうち、発火しているものが2個だと0.4、つまり、1個だと-0.41、つまり×と判断していることがわかる。ただし、実際には2番目と4番目の中間層ニューロンから出力層への重み値は負であったが、Fig. 5 では、正負反転させ、それにともない、中間層の値や、各重み値も正負反転させて表示した。

また、中間層から中間層へのフィードバック結合の重み値を見ると、セルフフィードバックは、初期値を 4.0 とした影響もあり、すべてで大きな値となっている。これによって、入力がない時は、値を保持していることがわかる。また、重み値が対称であれば、固定点収束になるが、ここでも、完全に対称ではないものの、対称性を見ることができる。入力層から中間層への重み値を見ると、それぞれのニューロンが、四隅の 3x3 の領域の か×かを検出しようとしていることがわかる。そして、中間層の発火状態と、バイアスの値との組み合わせにより、最初の4つの中間層ニューロンのうち、矢印の方向にある図形に反応するニューロンだけが選択的に値を変化させていることがわかる。しかし、同じニューロンが  $t=0$  では矢印の変換も行っていることを考えると、中間層の各ニューロンが非常に巧妙に様々な機能を果たしていることがわかる。

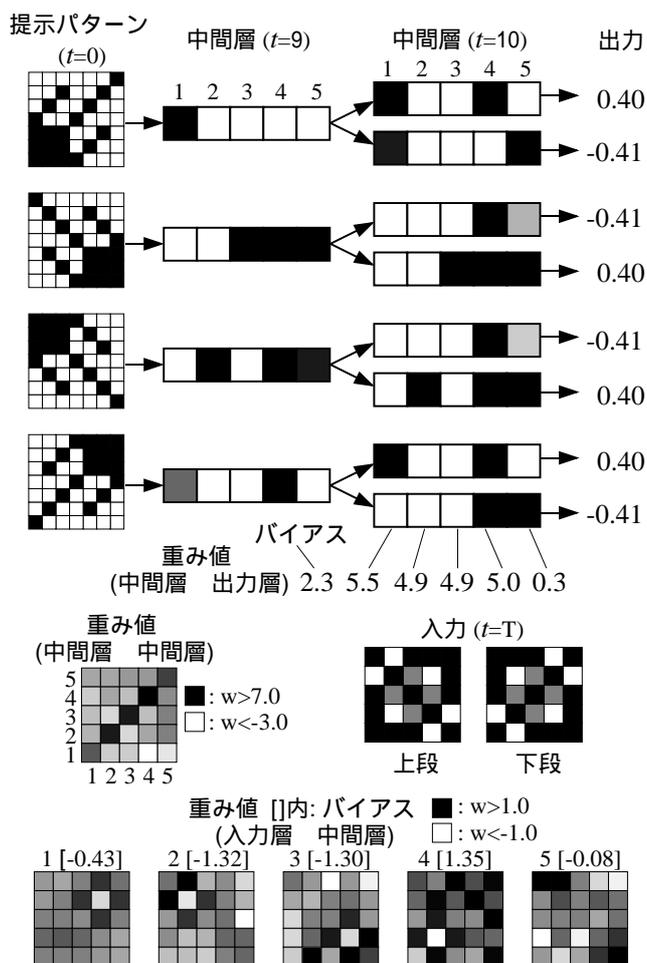


Fig. 5 遅延注意課題学習後の中間層の値と各重み値

## 5.3 中間層の値の変化と遅延時間固定の影響

次に、中間層の値が、時間の経過と共にどのように変化しているかを調べた。Fig. 6 に、 $t=0$  で左下を向いた矢印9パターンと左上を向いた矢印9パターンを提示した時について、1番目と2番目の中間層ニューロンの値および4番目と5番目のニューロンの値の時間による変化をそれぞれプロットした。左下を向いている9個の矢印パターンを入力とした場合の1番目から3番目のニューロンは、 $t=0$  の時の値のばらつきが大きく、そこから単調に変化し、0.5 または-0.5 に近い値に収束した。4, 5番目のニューロンは、 $t=0$  の時のばらつきは小さく、値の変化は単調ではないが、 $t=5$  の時にはほぼ収束した。また、左上の矢印の場合には、4番目のニューロンの値が大きく変化するなど、その変化の仕方が異なることがわかる。その後いずれの場合も、さらに時間が経過しても値は変化せず、パターンごとに別々のベイスンが形成されていることがわかった。

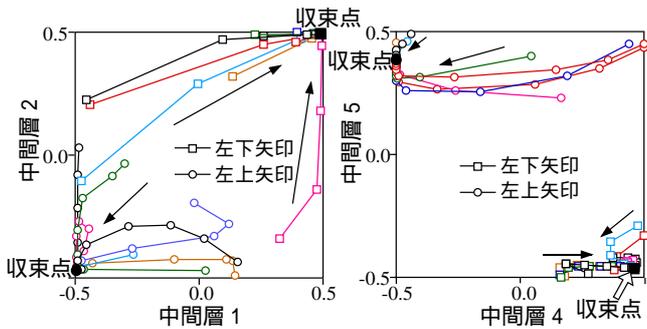


Fig. 6 可変遅延時間( $t=5 \sim 14$ )で学習させた場合の中間層ニューロンの値の時間による変化

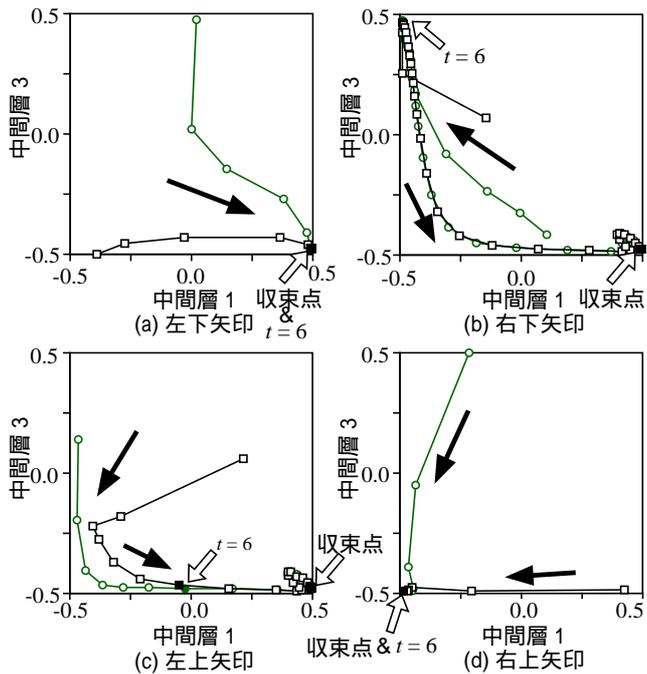


Fig. 7 固定遅延時間( $t=6$ )で学習させた場合の中間層ニューロン(1, 3)の値の時間による変化

一方、学習時に、 $t=6$  の時だけ学習させた場合の例を Fig. 7 に示す。ここでは、4 方向の矢印をそれぞれ 2 つずつ持ってきて、中間層 1, 3 の値の変化を別々のグラフにプロットした。この場合も、 $t=6$  の時に中間層の値は、同一カテゴリーの入力に対しては 1 箇所集まり、その値はカテゴリーごとに異なっていた。しかし、右下と左上の矢印の場合には、その値にはとどまらず、時間の経過とともにさらに値が変化し、最終的には、左下の矢印の場合と同じパターンに収束している。つまり、 $t=6$  の時には中間層の値は 4 つに分類できたが、時間が経過すると 2 つにしか分離できなくなった。このことから、遅延時間を可変にすることが、パターンごとのベイスンの形成を促進していると考えられる。

#### 5.4 形成されたベイスンと提示パターン数の影響

次に、可変遅延時間の場合に形成された連想記憶のベイスンの数や大きさを調べた。比較のために、矢印パターンを、各向きごとに、シフト量(1,1)の 1 個だけで学習した場合も調べた。まず、最初に入力する画像の各ピクセルをまったくランダムに -1 か 1 とし 1000 パターン生成し、それぞれ中間層の値がどこに収束するかを調べた。次に、各中間層ニューロンの初期値として、-0.4, 0.0, 0.4 の 3 通りの計 273 通りのパターンを与え、入力なしでその後の値の変化を調べた。その結果、各矢印に対応した固定点に収束した数を Table 1 に示した。学習に各方向 9 パターン用いた場合は、いずれも 4 つのどこかに収束しており、ベイスンは 4 つのみであると推測される。一方、1 パターンずつでしか学習しなかった場合は、4 つのどこにも属さない場合がかなりあった。さらに、その場合の収束先を調べると 2 通りあり、全部で 6 個のベイスンが形成されていることがわかった。また、それぞれのベイスンへの収束数はばらばらであり、形成されたベイスンの大きさが一様でないことがわかる。また、必ずしも初期値にもっともハミング距離が近いパターンに収束しなかった。

Table 1 ランダム入力、および中間層の初期値を変化させた時の各矢印の向きに対応したベイスンへの収束数

|             |     | 左下  | 右下  | 左上  | 右上  | その他           |
|-------------|-----|-----|-----|-----|-----|---------------|
| 9 パターン / 向き | 入力層 | 166 | 141 | 166 | 527 | 0             |
|             | 中間層 | 60  | 38  | 50  | 95  | 0             |
| 1 パターン / 向き | 入力層 | 389 | 111 | 114 | 129 | 257 (229, 28) |
|             | 中間層 | 102 | 41  | 29  | 25  | 46 (33, 13)   |

#### 6. 議論

上記の結果を通して、リカレントネットで文脈の抽出、保持、そして注意が単に学習できるだけでなく、中間層ニューロンが非常に巧妙に働くことにより、これらが少ないニューロン数で効率的に実現できていることがわかる。また、遅延時間固定の場合や、提示パターン数が少ない場合からもわかるように、本システムはあくまでも自律的かつ合目的的であると言える。

本稿で用いた BPTT は、過去にさかのぼって学習しなければならない上、その間の状態をすべて保持しな

ければならないという問題点がある。RTRL(Real Time Recurrent Learning)を使用してもニューロン数の3乗のメモリ、4乗の計算量が必要で現実的ではない。筆者らが[12][13]にその基本構想を示したように、ニューロン数の自乗のオーダーのメモリ量と計算量におさまる学習則の考案が急務である。ただし、問題点がクリアできる範囲では BPTT も RTRL もアルゴリズム自体は有効である。したがって、本稿の議論が学習アルゴリズムによって一般性を失うことはないものとする。

連想記憶では、スパースコーディングが記憶容量の向上につながり、実際に脳でも観察されたという報告がある[6]。値域が0から1の出力のニューロンで構成された階層型ニューラルネットを Back Propagation で学習させると、中間層のコーディングがスパースになるとの報告がある[14]。リカレントネットの場合でも同様のことが言えれば、本稿のような学習によって得られたコーディングが、連想記憶として見た時に、記憶容量、エネルギー消費の点から合理的であるということができると考える。この点を今後確認したい。

## 7. 結論

Elman 型のリカレントニューラルネットを用いて、認識の学習を行わせるだけで、認識に必要な文脈情報を画像から抽出し、保持し、現在の画像に対して選択的注意を行う一連の機能を学習によって獲得できることを示した。また、その際に、最初の画像入力を入力層から中間層の間で変換し、その値を初期値として中間層のフィードバックループによる連想記憶を通して、注意に必要な情報ごとに違う収束点に収束するダイナミクスを獲得していることを確認した。この時、ベイシンの数は、注意に必要なカテゴリの数と等しくなった。しかし、文脈情報の提示から認識する情報の提示までの遅延時間を固定すると、さらに時間が経過すると別のパターンに収束する傾向があること、さらに、最初に提示するパターン数が少ないと、カテゴリ数より多いベイシンが形成される傾向があることを示した。本研究は、自律学習ロボットを実世界へ導入するための大きな一歩であるとともに、連想記憶のあり方、コーディングの問題に対する一つの解を示したという点で大きな意義があると思う。今後、強化学習を導入し、行動との結びつけを検討していく予定である。

## 謝辞

本研究の一部は、日本学術振興会未来開拓研究プロジェクト「生物的適応システム」(JSPS-RFTF96 I00105)および文部省科学技術研究費基盤研究(#10450165)による。ここに謝意を表す。

## 参考文献

- [1]柴田克成, 岡部洋一, "ニューラルネットによる視覚入力強化学習", 第15回日本ロボット学会学術講演会予稿集, Vol. 3, pp.897-898 (1997)
- [2]西野哲男, 柴田克成, 岡部洋一, 遅延強化信号による視点移動の学習, 信学技報, NC96-135, pp. 171-178 (1997)
- [3]柴田克成, 伊藤宏司, "Direct-Vision-Based 強化学習に基づく Hand-Eye Coordination の形成", 第12回自律分散システムシンポ資料, pp. 217-222 (2000)
- [4]阪口豊, "触知覚における感覚統合と能動認識", 電子情報通信学会誌, Vol. 76, No. 11, pp.1222-1227 (1993)
- [5]McCallum, A. K., Learning to Use Selective Attention and Short-Term Memory in Sequential Task, From Animals To Animat, pp.315-324 (1996)
- [6]森田昌彦, 連想記憶の神経回路モデル, 脳とニューラルネット, 甘利俊一ら編, 朝倉書店, pp. 127-142 (1994)
- [7]渡邊正孝, 記憶・学習行動と脳, 記憶と学習, pp. 59-61, 岩波講座 認知科学, 市川伸一ら編, 岩波書店 (1994)
- [8]Funahashi, S., Bruce, C. J. & Goldman-Rakic, P. S., Visuospatial Coding in primate prefrontal neurons revealed by oculomotor paradigms, Journal of Neurophysiology, Vol. 63, pp. 814-831 (1990)
- [9]Rumelhart, D. E., Hinton, G. E. and Williams, R. J., *Parallel Distributed Processing*, Vol. 1, pp.354-362 (1988)
- [10]Elman, J. L., Finding Structure in Time, *Cognitive Science*, Vol. 14, pp. 179-211 (1990)
- [11]Zipser, D., Recurrent Network Model of the Neural Mechanism of Short-Term Memory, *Neural Computation*, Vol. 3, pp. 179-193 (1991)
- [12]Shibata, K., Ito, K., and Okabe, Y., Simple Learning Algorithm for Recurrent Networks to Realize Short-Term Memories, *Proc. of IJCNN 98*, Vol. 1, pp. 2367-2372 (1998)
- [13]柴田克成, 岡部洋一, 伊藤宏司, 短期記憶のためのリカレントネット簡易学習則の基本構想, 日本神経回路学会 8 回全国大会講演論文集, pp. 224-225 (1997)
- [14]掛谷秀樹, 岡部洋一, "論理関数を BP 学習した多層パーセプトロンの中間層発火率", 日本神経回路学会 第7回全国大会講演論文集, pp. 98-99 (1996)