

解説**連想記憶モデルの現状と動向†**

角田 達彦†

1.はじめに

脳機能と従来計算機の基本的機能の違いに着目し、新機能モデルあるいは脳機能そのものの構成的研究が行われている。よく知られているように Marr は情報処理を理解するには(1)計算理論、(2)表現とアルゴリズム、(3)ハードウェアの三つの水準で考えるのが効果的で、最も重要なのは計算理論を理解することであると述べている¹⁾。そこでここでは記憶に着目した研究についてまとめてみる。脳の記憶を従来の計算機（以下計算機とする）の記憶と有意に区別するものは、その記憶方式そのものである。脳の記憶はもともと計算理論レベルで連想記憶を実現するようなハードウェアから成り立っている。一方、計算機の最も基本的機能による記憶はアドレッシングに基づき、個々の記憶の場所は内容に依存することがなく、システムが勝手に割り当てる。いわば、法則なしに格納することがこの場合の計算理論になっている。このため、(1)部分的入力誤りに対して本来求められる出力と無関係な出力を出すことがある、(2)検索を内容と独立に行うためコストがかかる、などの問題点がある。

これに対して連想記憶を際だたせる特徴は、内容記憶と関連記憶の 2 点にまとめられる。前者は計算機のアドレッシングに対比される概念である。アドレスを指定して処理を施すのではなく、データの内容を基にして同時並列的に記憶したデータを呼びだすことができるものである。後者は個々の記憶を独立に扱うのではなく、他の事象との関係を用いて記憶することを示す。この二つから導き出せる性質を、例として顔を記憶する能力

でまとめてみると、以下のようになる。(1)人間は写真を見て名前を瞬時に当てられるのは、関連のある記憶を直接並列に想起するからである。従来の計算機では照合を繰り返しながらアドレスを逐次更新して検索するので、場合によって遅くなってしまう。(2)完全に照合するものが記憶になくても、似ている人の顔を思い浮かべたり名前を言うことができる。個々の事例を独立に記憶させるのではなく、なんらかの類似性を保った記憶方法をとるからである。(3)斜めから撮った写真や一部不鮮明な写真から思い出すように、入力情報の不完全性、歪みへの耐性がある。また脳のニューロンは時々刻々破壊されているという知見があるが、記憶はそれに比例することはない。つまりハードウェア欠損、歪みへの耐性がある。(4)政治家はこんな顔、研究者はこんな顔と、多事例の統計的な相違点を抽出して類別する、汎化能力があるが、必要に応じて顔の区別も行える。(5)時間順序のあるパターンを記憶し、顔からその人の典型的な行動パターンを想起する。(6)因果律のような時間順序のある想起を独立した事例の記憶を組み合わせて行う。このように、連想記憶はパターン認識との結び付きが強いことが次章以降の議論からうなづけるであろう。

連想記憶の内容によって並列に検索する能力、部分情報によって完全情報を引き出す能力は 1970 年代にデータベースマシンに応用するためにも研究されていた²⁾。その考え方は現在の連想プロセッサ^{3),4)}にも使われている。また通常の計算機アーキテクチャではメモリ使用のコストを抑えるために、計算機の記憶を連續した大空間に見せる仮想記憶という技術があるが、高速バッファ（キャッシュ）にコピーするページを主メモリ中から決める、頻度に基づく変換テーブル（TLB: Translation lookaside buffer）として連想記憶が使われている。さらに内容をハッシュ関数を用い

† Present Status and Tendency of Research on Models of Associative Memory by Tatsuhiko TSUNODA (Information Engineering Course, Graduate School of Engineering, The University of Tokyo).

† 東京大学大学院工学系研究科。

て高速にアドレスに変換する方法はハード化もされており、重要な要素技術になっている⁵⁾。

以上のように連想記憶は実用的な領域でも研究されているが、ここでは近年のニューラルネットワークのブームによって逆に見えづらくなってしまっていた、ニューラルネットワークの計算論的側面としての連想記憶に、特に焦点を当ててみたいと思う。ニューラルネットワークはニューロンという素子を定義し、ニューロン自体の性質や複数のニューロンを組み合わせてどのような振舞いが現れるかを調べること、そして場合によっては工学的に役立つものを探すという立場と、解決したい問題を設定し、その計算理論レベルの目的に合わせて素子やその組合せなどのハードウェアを決定する立場がある。どちらも重要な考え方であるが、ここでは後者の立場での計算理論としてニューラルネットワークの発展を本質的に促してきた連想記憶をとりあげてみたいと思う。

2. 連想記憶モデル

ニューラルネットワークなどでの文脈では以下のように、連想記憶モデルは目的に応じて空間的想起と時系列想起の二つに大きく分類できる。

2. 1 空間的想起

入力されたパターンに最も近いパターンを想起し、さらに関連するパターンを出力する方法は大きく分けて二つある。それは入力パターンから出力パターンへの変換関数を使う方法（相関型）と、学習時に決められた分類に従って入力パターンを識別し、該当するカテゴリに対応するパターンを出力する方法（識別型）である。入力パターンを N 次元のベクトル $\mathbf{x} \in \mathbf{R}^N$ で表現し、特徴ベクトル空間 $X = \{\mathbf{x}\}$ の要素とする。相関型の目的は変換関数を用いて対応する M 次元出力ベクトル $\mathbf{y} \in \mathbf{R}^M$ を直接求める事である。識別型は出力ベクトルを直接求めるのではなく、カテゴリ集合 $\Omega = \{C_j\}_{j=1}^k$ の中から一つのカテゴリ（類） C_j を選び出すことである。さらに対応するパターンを求めるためには、選ばれたカテゴリから望ましい出力パターンへのリンクを張っておく必要がある（図-1）。

2. 1. 1 相 関 型

相関型の連想記憶は大別して、入力された信号を1回だけ写像を施して出力を得る適応フィルタ

型と、何回も写像を施して出力を補正することによってノイズに強い変換を行うアトラクタ型の2種類ある。

適応フィルタ型：

入力情報から必要な情報のみを濾過して出力するのがフィルタであるが、理想的出力ベクトル（教師信号）が分かっている場合は、入力から出力に変換する関数であるとみなすこともできる。そのような関数を学習する（適応する）のが適応フィルタの目的である。また使用する変換関数の違いによって事例どうしが似ているか（類似性）が異なり、未知事例に対する振舞いが変化する。複数のパターンを記憶させることを考慮し（記憶パターン数 l , $1 \leq m \leq l$ ），入力ベクトルを $\mathbf{x}^{(m)} \in \mathbf{R}^N$ ，出力ベクトルを $\mathbf{y}^{(m)} \in \mathbf{R}^M$ ，変換関数 f を用いて $\mathbf{y}^{(m)} = f(\mathbf{x}^{(m)})$ と書ける（図-1 参照）。 f は一般に無数に存在するが、理論的解析のしやすい線形変換関数が用いられることが多い。それを行行列表現して W とすれば $\mathbf{y}^{(m)} = W\mathbf{x}^{(m)T}$ と書くことができる。さらに簡単に \mathbf{y} の要素の一つに着目し y とすれば他の要素に関係なく $y^{(m)} = \mathbf{w}\mathbf{x}^{(m)T} = \sum_i w_i x_i^{(m)}$ が成立する。複数のパターンを記憶するために一つの行列しか使用しないことが注意点である。一つのパターンに注目すると、行列内に入り込む他のパターンからの干渉をいかに少なくするかが学習の際に重要である。 x, y の各成分は連続の実数値とする。 W は一般化逆行列を求めれば良いのだが⁶⁾、計算量を克服すること、神経回路網での学習方式と結合することを^{7)~11)} 目的に相関型学習と直交型学習の二つの近似法が提案されてきた。

1. 相関型学習^{12)~18)}：

入力ベクトルと与えられた出力値の相関を重みの修正値に用いる方法である。 $\delta\mathbf{w} = c\gamma\mathbf{x}^{(m)}$ (c は定数) で特に学習信号 r として教師信号 $y^{(m)}$ を用いる。この結果 $\mathbf{w} = \sum_m y^{(m)} \mathbf{x}^{(m)T}$ に収束する（ただし複数回学習させる場合は平均をとる。以下、 m

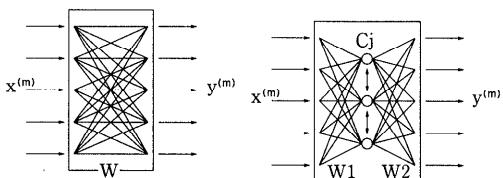


図-1 変換関数型と識別型

に対してすべて平均をとるアンサンブル平均として $\langle \cdot \rangle$ という記法を適宜使用する)。これは損失関数 $L(\mathbf{w}) = \frac{1}{2}|\mathbf{w}|^2 - c\langle \mathbf{w}y\mathbf{x}^T \rangle$ を最小にするようになっている。特に x, y が 2 値の場合、 $w_i = cp(x_i=1|y=1)P(y=1)$ となり、環境情報の条件つき確率(頻度)を習得する学習になる⁹⁾。

2. 直交型学習^{6),19)}:

正解との 2 乗誤差 $\langle |y^{(m)} - \mathbf{w}\mathbf{x}^{(m)T}|^2 \rangle$ を直接小さくする学習。ポテンシャル関数 $R = \frac{1}{2}|\mathbf{w}|^2 + \frac{c}{2}(y - \mathbf{w}\mathbf{x})^2$ を最小にするため、 $-\frac{\partial R}{\partial \mathbf{w}} = 0$ を解いて教師信号 $r = \mathbf{w}\mathbf{x}^{(m)T} - y^{(m)}$ を用いることになる。

歴史的経緯としては、相関学習では入力パターン群が互いに直交していない場合に完全な想起ができないため正規直交ベクトルを中間表現として使う直交学習が考え出されたのだが、以下にまとめるような得失がある。相関学習は入力ベクトルが正規直交系をなすことを前提に考案されたものである。 $\mathbf{x}^{(m)}$ が学習後のシステムに入力されたとして

$$y = \mathbf{w}\mathbf{x}^{(m)} \quad (1)$$

$$= (\sum y^{(n)}\mathbf{x}^{(n)T})\mathbf{x}^{(m)} \quad (2)$$

$$= y^{(m)}\mathbf{x}^{(m)T}\mathbf{x}^{(m)} + \sum_{n \neq m} y^{(n)}\mathbf{x}^{(n)T}\mathbf{x}^{(m)} \quad (3)$$

となるが、(a) $\mathbf{x}^{(m)T}\mathbf{x}^{(m)} = 1$ (b) $\mathbf{x}^{(n)T}\mathbf{x}^{(m)} = 0 (n \neq m)$ が成り立てば右辺第一項が $y^{(m)}$ 、第二項は 0 となり、望みの出力が得られる。しかし (b) が成り立たなければ干渉が起こり完全な想起が望めない。ただし (a) の不成立は符号だけを出力する 2 値モデルの場合は問題にならない。雑音混入時の除去の様子もこれに準ずる^{20),21)}。(b) の不成立による干渉の問題に対し、直交共有ベクトルを作つて用いることにより回避する方法が考え出された。入力ベクトルの組 $\{\mathbf{x}^{(m)}\}$ に対して直交共役なベクトルの組 $\{\mathbf{s}^{(n)*}\}$ が存在する ((a) $\mathbf{s}^{(m)*T}\mathbf{x}^{(m)} = 1$ (b) $\mathbf{s}^{(n)*T}\mathbf{x}^{(m)} = 0 (n \neq m)$)。これは $\mathbf{s}^{(m)*} = \sum_n (\mathbf{x}^{(m)}\mathbf{x}^{(n)})^{-1}\mathbf{x}^{(n)}$ によって求められる。相関学習の干渉の問題を解決するにはこの共役ベクトルを用いて $\mathbf{w} = \sum_m y^{(m)}\mathbf{s}^{(m)*}$ を学習する。こうすれば (3) 式の第二項が常に 0 になり、目的が達成される。直交学習は以下の式から共役ベクトルを求めることで近似になっていることが分かる。

$$\mathbf{w} = \langle r\mathbf{x}^T \rangle \quad (4)$$

$$= c\langle (y^{(m)} - \mathbf{w}\mathbf{x})\mathbf{x}^T \rangle \quad (5)$$

$$= c\langle y\mathbf{x}^T \rangle \left(\frac{1}{c}I_N + \langle \mathbf{x}\mathbf{x}^T \rangle \right)^{-1} \quad (6)$$

ここで括弧内の単位行列 I_N が残るため、正確には一般化逆行列にはなっていないので、 c をなるべく大きくとって近似する場合が多い⁹⁾。直交学習は教師信号(出力ベクトル)との最小 2 乗誤差を実現しており、統計的決定理論の枠組では確率的学習サンプル $p(\mathbf{x}, \mathbf{y})$ と損失関数 $r(\Psi(\mathbf{x})|\mathbf{y})$ から求まるリスク

$$R[\Psi] = \iint r(\Psi(\mathbf{x})|\mathbf{y})p(\mathbf{x}, \mathbf{y})d\mathbf{x}d\mathbf{y}$$

を最小にする学習であるとも解釈できる²²⁾。ここで Ψ は超関数で、 $R[\Psi]$ は Ψ の汎関数である。この理論から確率的急降下法による逐次学習の一般的枠組が導かれ²³⁾、後の誤差逆伝搬法がすでに含まれていた。特殊例として、写像である超関数 Ψ が線形である場合は直交学習に相当し、ADALINE のデルタルール²⁴⁾ もこれに属する。さらに多変量解析の外的基準が判別的な場合の線形重回帰分析の逐次解法に相当する点で統計学とも密接なつながりがある^{21),22)}。一方、雑音が存在する場合は逆に相関学習が有利になってくる。例として入力パターンに分散 σ の雑音を加えて学習させると、

$$\mathbf{x}'^{(m)} = \mathbf{x}^{(m)} + \mathbf{e},$$

$$\mathbf{w} = c\langle y\mathbf{x}^T \rangle \left(\frac{1+c\sigma^2}{c}I_N + \langle \mathbf{x}\mathbf{x}^T \rangle \right)^{-1} \rightarrow c'\langle y\mathbf{x}^T \rangle$$

となり、雑音が大きくなるに従い第一項(相関学習の項)が効いてくる。つまりこの場合には相関学習のほうが直交学習に比べて雑音に強いことが分かる^{9),7),20)}。相関学習のほうが未知のパターンに対しての引込み領域(ペイズン)が大きいことを示しており、次のアトラクタ型のように繰り返し引込みをするタイプで特に有用であるので、現在も研究が続けられている。フィードバックなしの適応フィルタ型での解析としては他にも相関学習である程度誤りを認めた場合に記憶できるパターン数を確率的モデルにより解析した例²⁵⁾や、入力されたパターンと望ましいパターンとのずれを距離(安定数)にとり、望ましいパターンが正しく想起される場合を確率的に解析した例^{12),26)}が

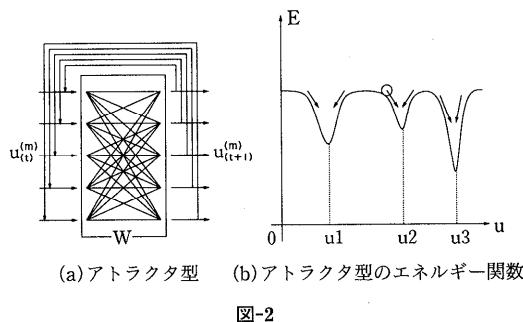


図-2

ある。

アトラクタ型：

適応フィルタ型の連想記憶で得られた出力解をさらに入力として用い、それを収束するまで更新する方法であり（図-2(a)参照），特に2値モデルなど非線形のときに意味をもつ。学習する入力・出力対が同じ自己想起型は $\mathbf{u}(0)=\mathbf{x}$, $\mathbf{u}(t+1)=sgn(W\mathbf{u}(t))$, $y=\mathbf{u}(\infty)$ と書ける。ここで $\mathbf{u}(t)$ は時間 t での内部状態ベクトルで、最初は入力ベクトル \mathbf{x} が与えられる。このベクトルに変換が施され、変換後のベクトルが新たな入力ベクトルとして入力に入れ直され、変換が繰り返される。ベクトルの修正量が小さくなっている収束したものを \mathbf{y} として出力する。また入力・出力対が異なる相互想起型は BAM²⁷⁾ などが例としてあげられるが、簡単に $\mathbf{y}(t)=sgn(W\mathbf{u}(t-1))$, $\mathbf{u}(t-1)=sgn(W^T\mathbf{y}(t-1))$ と書け、自己想起型の変形とみなして同様な議論が進められるので、歴史的にも自己想起型に絞られて研究される場合が多い。アトラクタ型は相関型の延長として数学的解析から始まり¹²⁾， $W=\mathbf{x}\mathbf{x}^T$ の非同期型で統計物理学のスピングラスとの類似性からエネルギー関数、容量について論じられた²⁸⁾。たとえば $E(t)=-\frac{1}{2}\sum_i\sum_j W_{ij}u_i(t)u_j(t)$ で $W_{ij}\geq 0$ のとき $\Delta E(t)\leq 0$ なので収束性が保証されている（図-2(b)参照）。またレプリカ法により収束までの振舞いを解析した研究もある^{29),30)}。さらに記憶したパターンを完全に想起する必要がある場合に記憶できるパターン数（絶対容量） $\frac{n}{2\log n}$ や³⁰⁾、想起パターンの元のパターンからのずれをパラメータにより、繰り返し想起によってそれが減少する場合の記憶パターン数の臨界点（相対容量） $0.15n$ な

ど^{28),31)} の記憶容量解析や、近さを表すマクロ変数の時間変化による想起過程^{31)~33)} や回り込み現象³⁴⁾などのダイナミクス、そして記憶パターンの相互干渉による偽記憶がノード数の指数オーダーになる事実の発見³⁵⁾など、現在でも解析が続けられている。記憶容量と偽記憶の問題に対して一般化逆行列^{6),7)}、最良容量の最適記憶行列³⁵⁾などが提案されたが、近年はスペースコーディングという、活動度が非常に小さい分散表現の研究が盛んである。データ効率から考えると、パターンの半分が1になるような表現（たとえば10 bit だったら0110010101など）が最もデータ数を多くとれる効率の良い表現なのだが、その反面パターン間の干渉も大きく、記憶容量に関しては不利な面がある。それに対して1を少なくする表現（たとえば0001000000）ではデータ数は一割程度しかとれないものの、パターンどうしの干渉が少ないという利点がある。スペースコーディングを使うと記憶容量が飛躍的に拡大することを Willshawらが提唱して以来、全記憶容量が $\log n$ へ拡大³⁶⁾されるという事実、ダイナミクスの安定平衡状態数が $(\log n)^2$ に比例するという解析、記憶情報容量の解析例³⁷⁾などがみられた。ただしその一方、実装時に疎結合³⁸⁾や神経素子の興奮性・抑制性への分離が必要³⁹⁾など、複雑になりがちであるという欠点もあった。これに対し森田らの部分反転法から発展した非単調神経素子を用いたダイナミクス^{34),40)~42),33)}を用いることで、簡単な回路によってスペースコーディングを自動的につくり出すことができるようになった。そのモデルではさらに偽記憶なし、想起失敗時のカオス的振舞い⁴³⁾などの利点が見い出されている。猿を用いた側頭葉短期記憶での图形に反応する細胞のスペースコーディング^{44),45)}や图形の特徴に反応する細胞（田中ら³³⁾）の解剖学的生理学実験があり、また細胞レベルの生理学実験の結果を説明するようなモデル化⁴¹⁾もなされている。

2. 1. 2 識別型

識別型は、相関型のように連続関数で入力・出力の変換をするのではなく、入力ベクトル \mathbf{x} をあらかじめ（教師つき学習などで）決められたカテゴリ C_i の一つに分類（識別）する方法である。 C_j に分類すべき入力を C_i に分類するときの損失を $r(C_i|C_j)$ とし、リスク

$$R[d] = \sum_{j=1}^k \int r(d(\mathbf{x})|C_j) P(C_j|\mathbf{x}) p(\mathbf{x}) d\mathbf{x}$$

を最小にする決定関数 $d(\mathbf{x})$ を求ること（統計的決定理論）が基本的な考え方である。認識の成否のみで決める場合は 0-1 損失 $r(C_i|C_j)=1-\delta_{ij}$ を用い、ベイズ識別 $\mathbf{x} \in C_i$ if $p(C_i|\mathbf{x}) \geq p(C_j|\mathbf{x})$, $\forall j=1, 2, \dots, k$. に帰着する。さらに各類の確率分布構造を事前に完全に知ることができないので、なんらかの識別関数で $\mathbf{x} \in C_i$. if $g_i(\mathbf{x}) \geq g_j(\mathbf{x})$, $\forall j=1, 2, \dots, k$. と識別する場合が多い²²⁾。この識別関数の一つとして線形識別関数 $g_i(\mathbf{x}) = \mathbf{w}\mathbf{x}$ がパターン認識で使われてきた理由は(1) 計算しやすい、(2) 理論的に扱いやすい、(3) 2 個の類のパターンがおのおの正規分布に従うとき線形関数が最適であることが証明されている、からである⁴⁶⁾。ただし線形分離不可能で複雑なパターンの場合は線形関数ではうまくいかないので非線形関数や NN 法などを使う例⁴⁷⁾ があり、場合によってうまくいく例もあるのだが、すべての問題に万能な関数は存在せず、したがって具体的な事例に応じて手法を吟味し適用するのが現状である。したがって手法の選択を行う基準が求められている。

以上は教師つきの学習の場合であるが、教師なしでモデル自身で学習する競合フィルタ型もある²¹⁾。その代表的な形は 3 層で中間層の個々の細胞が C_i に対応し、側抑制結合により学習する権利を争うものである。高次元空間を低次元空間に情報をなるべく保存する形でマッピングするので、繰り返し試行回数を多く必要とし、非常に学習が遅いという難点がある。Grossberg の ART⁴⁸⁾ も基本的に同じであるが、閾値をあらかじめ設定し、蓄積されているパターンと入力パターンとの違いが閾値を越えると閾値中間ノードを増加させるため、高速に学習させることが可能である。しかし閾値のとり方や類似度の計算方法に関しては、研究しつくされているとは言えない段階である。競合フィルタ型および ART は入力ベクトルに対し幾何的射影の最も大きい記憶パターンを代表する中間層中の 1 個の細胞が勝者となり(Winner-take-all)，学習・解答をする直交型学習の極端な場合で、それらは細胞と代表分類ベクトルが一致しベクトル量子化(LVQ)による情報圧縮とも解釈できる。現在のところ、相関型のようにダイナミクスを取り入れる研究はまだなく、類別、

識別の段階でとどまっているが、類別の基準の設定をうまく言えば、相関型に比べて容量の面で非常に有利になる可能性がある⁴⁹⁾。さらに周囲の細胞も同時に学習させる形では²¹⁾ 入力の位相を物理的な細胞の発火位置で表現する位相保存マップを作ることができる。またパターン認識の文脈で、ベイズ統計学、類似度による比較、回帰分析、LVQ、特徴抽出、クラスタリングなどとの関係が研究されている²¹⁾。

2.2 時系列想起

時間方向も含めた連想記憶は系列的情報の順序のみを扱う順序型と、実際の連続時間と対応させ時間軸の頑健性をもたせた実時間型がある。

2.2.1 順序型

前述のように空間型想起で使われる相関型連想記憶は、入力と望ましい出力が同じ自己想起型と、異なる相互想起型がある。後者の相互想起型の出力をそのまま入力にフィードバック結合すると、 $\mathbf{x}_{t+1} = T\mathbf{x}_t$ のように次々に異なる記憶パターンが想起する。これは前のパターンのみに依存するマルコフ過程である。学習に際しては、相関学習 $T = c\langle \mathbf{x}_{t+1}\mathbf{x}_t^T \rangle$ あるいは直交学習 $T = c\langle \mathbf{x}_{t+1}\mathbf{x}_t^{*T} \rangle$ で重み行列を学習する。マルコフ過程に限らず過去のパターンとの相関も加えることによって想起の安定性が良くなることも解析されている^{12), 9)}。

また 3 層型神経回路網と誤差逆伝搬を利用した形も多くみられる。その代表例として、少しずつ異なる時間遅れをもつ遅延ユニットを入力にはさみ、時間情報を空間情報に変換して学習させる Time-Delayed Neural Network (TDNN)⁵⁰⁾ があげられるが、その考え方は簡単であるものの規模の問題が指摘されている。原因は時間方向の変化もすべて空間方向に展開させて入力・出力対として記憶させている点にある。この問題を解決する方法として、フィードバック結合をもつリカレントタイプのネットワークについての研究が進められている。リカレントタイプは文脈として状態層を新たに設け、パターンの時系列をそのまま入力させる。それには大別して出力を状態層へフィードバックさせる Jordan ネットワーク⁵¹⁾、中間層の出力を状態層へフィードバックさせる Elman ネットワーク⁵²⁾ の 2 種類がある。これらにより規模の問題は解決されているものの、フィードバックの寄与、未知事例に対する動作、評価方

法などが十分検討されていなく、現在も研究され続けている。

変わった想起ダイナミクスとしてカオスを使う方法もある^{53),54)}。アトラクタ型のフィードバックに、細胞発火後に閾値を一時的に増加させる不応性を加えると、不応性がフィードバックよりも弱い場合には空間型想起でのアトラクタ型連想記憶として振る舞うようになり、強い場合には異なる複数のパターンが順番に想起されるようになる。ただしその順序を制御する方法はまだ見い出されていない。

2. 2. 2 実 時 間 型

実時間モデルは研究例が少ない。それは時間の基準点、取扱いの解析が不十分のためかと思われる。研究の一例として Avalanche model があげられる⁴⁸⁾。3層型の中間層の細胞の活性値に時間に関する指数的減衰項があるモデルを使い、相互結合させる。想起過程はそれまでのシーケンスと時間を反映する。学習時は中間層の細胞間での相關学習を使う。また自己相関と次のパターンとの相関を重みをつけて混ぜた $T = c \langle \mathbf{x}_t \mathbf{x}_t^T \rangle + \epsilon c \langle \mathbf{x}_{t+1} \mathbf{x}_t^T \rangle$ を学習させるモデルも研究されている⁵⁵⁾。

3. 連想記憶プロセッサ

実際に連想記憶を実装したプロセッサは思いのほか少なく、それも直接的実用性を目指したものが多い。空間的想起の相関型の性質をもつ連想記憶チップは Caltec や AT&T で作られている⁵⁴⁾。

自然言語処理や知識ベースなどの知識表現形式である意味ネットは連想、マーカ伝搬、交差演算の三種類の高速処理を必要とするが、これに対し IXM 2³⁾ は 256 K 語の大容量連想記憶をもち、64K ノードの意味ネットを並列処理可能である。また Prolog の節の起動と引数のユニフィケーションの連想処理を連想メモリチップ(CAM)を用いて高速に実現した研究例³⁾ がある。これらの例を含めて人工知能やデータベースのアプリケーションに対して内容検索を高速に行う必要があるため⁵⁾、ハード化をする試みも多いが⁵⁶⁾、上記のような連想記憶の特徴は必ずしも有していない、通常計算機の連想アドレッシング方式の延長のビット演算を強化したものである。ハードウェア化はさ

れていながら、似たような方式をとっている HASP⁵⁷⁾ は、簡単な考えに基づいて人間の心理学実験を説明しようとする認知モデルになっている。

4. 応 用 例

連想記憶が応用された実世界の問題は、アダリンによる音節認識、天気予報、ノイズフィルタ、パターン分類⁵⁸⁾ や、倒立振子⁵⁹⁾ がある。空間的想起の識別型に側抑制をつけて発展させた Kohonen の特徴マップを用いた音素マップや言語の概念マップ⁶⁰⁾、BAM を利用した概念ファジィ集合による顔の表情認識⁶¹⁾、ユーザインタフェースにおける意図認識⁶²⁾、また自然言語の文脈処理の要素として絵辞書と連想記憶を用いた場面同定⁶³⁾ などのほかにも、有効例は多数ある。特徴抽出後のデータに対しては学習、処理とも高速で解析性が良いので、実用的なシステムを作ることができるのが特長である。ほかにも TDNN を利用した音声認識は HMM よりも認識率が良かったとの報告もある⁵⁰⁾。

5. おわりに

近年の多層ネットワークと誤差逆伝搬の流行のため連想記憶の有効性が忘れられがちであるが、ニューラルネットワークの基盤を築いたのは連想記憶という計算理論であり、それはパターン認識、さらには統計学と密接に関連をもつことを再認識することが重要に思われる。実世界は一般により複雑な現象であり、さまざまな分布を仮定して解析的に解いてもそれは完全ではないのだが、特徴抽出により、より簡単な現象にまで分類し、性質の分かった個々の現象に対して、たとえば連想記憶などの適切な処理を用いるのが、これから的是非論議の使い方になるのではないかと予想する。

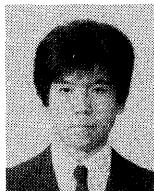
謝辞 本稿の執筆にあたり、日頃からご指導いただいている東京大学の田中英彦教授に深く感謝いたします。また電子技術総合研究所の知能情報部の大津展之部長と情報科学部の栗田多喜夫氏には討論と本稿執筆の機会を与えていただきました。大変感謝いたします。なおこの調査研究の一部は、文部省科学研究費の助成によります。

参考文献

- 1) Marr, D.: Vision, Freeman, San Francisco, (1982). (乾他訳: ビジョン, 産業図書(1987)).
- 2) 第5世代の電子計算機に関する調査研究報告書
—データベースマシン・要求工学技術, (財)日本情報処理開発協会(JIPDEC)(3 1980).
- 3) 橋口哲也, 古谷立美, 半田剣一, 高橋直人: 並列連想プロセッサ IXM 2, 電気学会論文誌 D-I, Vol. J 75, No. 8, pp. 615-625(1992).
- 4) 長沼次郎, 小倉 武: 連想メモリを用いた prolog マシンの実現とその評価, 電気学会論文誌 D-I, Vol. J 73, No. 11, pp. 856-863(1990).
- 5) 村岡洋一, 古谷立美: 知的連想メモリマシン, オーム社(1989).
- 6) Kohonen, T. and Ruohonen, M.: Representation of Associative Data by Matrix Operators, IEEE Trans., Vol. C-22, No. 7, pp. 701-702(1973).
- 7) Amari, S.: Neural Theory of Association and Concept-Formation, Biol. Cybernetics, Vol. 26, pp. 175-185(1977).
- 8) Kohonen, T. and Oja, E.: Fast Adaptive Formation of Orthogonalizing Filters and Associative Memory in Recurrent Networks of Neuron-Like Elements, Vol. D-II(4), Biol. Cybernetics(1976).
- 9) 甘利俊一: 神経回路網の数理, 産業図書(1978).
- 10) 松本清利: 直交射影型連想回路の種々の構造について, 電子情報通信学会論文誌, Vol. D-II(4), pp. 641-647(1990).
- 11) Matsuoka, K.: An Associative Network with Cross Inhibitory Connections, Biol. Cybern., Vol. 61, pp. 393-399(1989).
- 12) Amari, S.: Learning Patterns and Pattern Sequences by Self-Organizing Nets of Threshold Elements, IEEE Trans., Vol. C-21, pp. 1197-1206(1972).
- 13) Kohonen, T.: Correlation Matrix Memories. IEEE Trans., Vol. C-21, No. 4, pp. 353-359(1972).
- 14) Nakano, K.: Association—A Model of Associative Memory, IEEE Trans., Vol. SMC-2, pp. 380-388(1972).
- 15) Anderson, J. A.: A Simple Neural Network Generating Interactive Memory, Math. Biosciences, Vol. 14, pp. 197-220(1972).
- 16) Wigstrom, H.: A Neuron Model Learning Capability and Its Relation to Mechanism of Association, Kybernetik, Vol. 12, pp. 204-215(1973).
- 17) Wigstrom, H.: A Model of a Neural Network with Recurrent Inhibition, Kybernetik, Vol. 16, pp. 103-112(1974).
- 18) Wigstrom, H.: Associative Recall and Formation of Stable Modes of Activity in Neural Network Models, J. Neuroscience Research, Vol. 1, pp. 287-313(1975).
- 19) Kohonen, T.: Associative Memory, Springer-Verlag(1977).
- 20) 松岡清利編著: ニューロコンピューティング, 朝倉書店(1992).
- 21) Kohonen, T.: Self-Organization and Associative Memory (Second Edition), Springer-Verlag(1987).
- 22) 松本 元, 大津展之共編: ニューロコンピューティングの周辺, 培風館(1991).
- 23) Amari, S.: A Theory of Adaptive Pattern Classifiers, IEEE Trans., Vol. EC-16, pp. 279-307(1967).
- 24) Widrow, B. and Hoff, M. E.: Adaptive Switching Circuits, In 1960 IRE WESCON Conv. Record, Part 4, pp. 96-104(1960).
- 25) 上坂, 尾関: 連想形記憶の二, 三の性質, 電子通信学会論文誌, Vol. 55-D, pp. 323-330(1972).
- 26) 甘利俊一: 自己組織しきい素子回路におけるパターンの学習, 電子通信学会論文誌, Vol. 55-D, pp. 456-463(1972).
- 27) Kosko, B.: Bidirectional Associative Memories, IEEE Trans. SMC, Vol. 18, No. 1, pp. 49-60(1988).
- 28) Hopfield, J. J.: Neural Networks and Physical Systems with Emergent Collective Computational Abilities, In Proc. Natl. Acad. Sci. USA 79, pp. 2554-2558(1982).
- 29) Amit, D. J., Gutfreund, H. and Sompolinsky, H.: Spin-Glass Models of Neural Networks, Phys. Rev., Vol. A 32, pp. 1007-1018(1985).
- 30) Amit, D.: Modeling Brain Function, Cambridge University Press(1989).
- 31) Amari, S. and Maginu, K.: Statistical Neurodynamics of Associative Memory, Neural Networks, Vol. 1, pp. 63-73(1988).
- 32) Nishimori, H. and Ozeki, T.: Retrieval Dynamics of Associative Memory of the Hopfield Type, Phys. Rev. A, Vol. 26, pp. 859-871(1993).
- 33) 甘利俊一, 酒田英夫編: 脳とニューラルネット, 朝倉書店(1994).
- 34) 森田昌彦, 吉澤修治, 中野 騒: 自己相関連想記憶の想起過程とその改良, 電子情報通信学会論文誌, Vol. J 73-D-II, pp. 232-242(1990).
- 35) Gardner, E.: Structure of Metastable States in the Hopfield Model, J. Phys. A, Vol. 19, pp. 1047-1052(1986).
- 36) Amari, S.: Characteristics of Sparsely Encoded Associative Memory, Neural Networks, Vol. 2, pp. 451-457(1989).
- 37) Meunier, C., Yanai, H. and Amari, S.: Sparsely Coded Associative Memories: Capacity and Dynamical Properties, Network: Computation in Neural Systems, Vol. 2, pp. 469-487(1991).
- 38) Yanai, H., Sawada, Y. and Yoshizawa, S.: Dynamics of an Autoassociative Neural Network Model with Arbitrary Connectivity and Noise in the Threshold, Network, Vol. 2, No. 3, pp. 295-314(1991).
- 39) Shinomoto, S.: A Cognitive and Associative Memory, Biol. Cybernetics, Vol. 57, pp. 197-

- 206(1987).
- 40) 吉澤修治, 森田昌彦, 甘利俊一: 非単調性をもつ神経素子を用いた自己相関連想記憶の記憶容量, 電子情報通信学会技報, Vol. NC 91-90, pp. 57-64(1992).
- 41) Morita, M.: Associative Memory with Non-Monotone Dynamics, Neural Networks, Vol. 6, pp. 115-126(1993).
- 42) 森田昌彦, 吉澤修治, 中野 韶: 非単調ダイナミクスを用いた構造をもつパターンの連想記憶, 電子情報通信学会論文誌, Vol. J 75-D-II, pp. 1884-1891(1992).
- 43) Yoshizawa, S., Morita, M. and Amari, S.: Capacity of Autocorrelation-Type Associative Memory Using a Non-Monotonic Neuron Model, Neural Networks, Vol. 6, No. 2, pp. 167-176(1993).
- 44) Miyashita, Y.: Neuronal Correlate of Visual Associative Long-Term Memory in the Primate Temporal Cortex, Nature, Vol. 335, pp. 817-820(1988).
- 45) Sakai, K. and Miyashita, Y.: Neural Organization for The Longterm Memory of Paired Association, Nature, Vol. 354, pp. 152-155(1991).
- 46) 坂井利之編: パターン認識の理論, 共立出版(1967).
- 47) 森 健 監修: パターン認識, 電子情報通信学会(1988).
- 48) Carpenter, G. A. and Grossberg, S.: Pattern Recognition by Self organizing Neural Networks, MIT Press(1991).
- 49) 角田達彦, 田中英彦: 連想推論における逐次学習方式の定式化とその評価—曖昧性解消に必要な文脈情報の定量化, 情報処理学会第47回全国大会, Vol. 2, pp. 35-36(1993).
- 50) Waibel, A.: Modular Construction of Time-Delay Networks for Speech Recognition, Neural Computation, Vol. 1, pp. 328-339(1989).
- 51) Jordan, M. I.: Attractor Dynamics and Parallelism in a Connectionist Sequential Machine, In Proceedings of the Eighth Annual Conference of the Cognitive Science Society, pp. 531-546(1986).
- 52) Elman, J. L.: Finding Structure in Time, Cognitive Science, Vol. 14, pp. 179-211(1990).
- 53) 合原一幸: カオスーカオス理論の基礎と応用, サイエンス社(1990).
- 54) 甘利俊一編著: ニューラルネットの新展開, サイエンス社(1993).
- 55) Kuhn, R. and van Hemmen, J. L.: Models of Neural Networks, chapter 7, Springer-Verlag, pp. 213-280(1991).
- 56) Grosspietsch, K. E.: Associative Processors and Memories: A survey, IEEE Micro, pp. 12-19(6 1992).
- 57) 平井有三: 記憶と認知のニューロコンピューティング, ニューロコンピュータの現状と将来, 共立出版(1990).
- 58) Widrow, B. and Stearns, S. D.: Adaptive Signal Processing, Prentice-Hall(1985).
- 59) Tolat, V. V. and Widrow, G.: An Adaptive Broom Balancer with Visual Inputs, In Proceedings of IEEE ICNN, Vol. 2, pp. 641-647(1988).
- 60) Kohonen, T.: The Self-Organizing Map, Proceedings of IEEE: Special Issue on Neural Networks I, Vol. 78, No. 9, pp. 1464-1480(1990).
- 61) Ushida, H., Takagi, T. and Yamaguchi, T.: Recognition of Facial Expressions Using Conceptual Fuzzy Sets, In Proceedings of the Second IEEE ICFS(FUZZ-IEEE'93) (1993).
- 62) Imura, A., Takagi, T. and Yamaguchi, T.: Intention Recognition Using Conceptual Fuzzy Sets, In Proceedings of the Second IEEE ICFS(FUZZ-IEEE'93) (1993).
- 63) Tsunoda, T. and Tanaka, H.: Analysis of Scene Identification Ability of Associative Memory with Pictorial Dictionary, In Proceedings of COLING-94, Vol. 1, pp. 310-316, 8(1994).

(平成6年6月20日受付)



角田 達彦 (正会員)

昭和42年生。平成元年東京大学理学部物理学教室卒業。平成3年同理学系大学院物理学修士課程修了。現在、同工学系大学院情報工学専攻博士課程在学中。日本学術振興会特別研究員。IJCNN'93 Nagoya Student Award受賞。情報処理学会第48回全国大会奨励賞受賞。推論、特に自然言語処理の情報の数理化について研究中。脳機能の数理化に興味を持つ。日本認知科学会、人工知能学会、言語処理学会、神経回路学会、電子情報通信学会各会員。