

## 脳からニューラルネットワークへ — 連想記憶への数理的なアプローチ —

門田 成治\*

### From Brain to Neural Networks — Mathematical Approach to Associative Memory —

Seiji KADOTA

Key Words : Neural Networks, Associative Memory, Retrieval Process, Spin Glass, Genetic Algorithms

#### 序 文

近年における科学技術の発展は驚異的であり、社会の様々な分野において多くの革新的な変化をもたらしている。科学技術の3本柱はエネルギー、物質、情報といわれている。半世紀前に登場したノイマン型コンピュータは特筆に値する情報に属するが、情報だけでなく、この3本柱の画期的な発展に貢献した。21世紀初頭の今日、人間の脳の生理学、医学、情報科学的な研究の進歩は加速度的であり、そこで得られた知見の集積は脳の情報処理機能の解明に近づける可能性を示唆し始めている。多くの研究者により21世紀は『脳の時代である』ともいわれている所以である。

一方、脳の情報処理機能の特性を模擬し、数理工学的に活用することを目的としたニューラルネットワーク(neural network)の研究も驚くべき進歩を見せ、その成果は社会の多くの領域に浸透している。また生物の進化を模擬した新たな情報処理方式である遺伝的アルゴリズム(GA:genetic algorithms)も誕生し脚光を浴びている。さらに人間の判断のあいまいさという主観を取り入れたファジィ制御(fuzzy control)なる情報処理技術が出現し、知能化システムを目指す研究者の関心の的となっている。将来これらの技術は融合されますます優れた知能技術に発展していくであろう。

ところで、『見慣れた人の顔写真の一部分を見てその人の顔を思い出す』といった人間なら容易にできる人工知能システムの完成にはまだまだ遠い技術レベルである。この機能はニューラルネットワークの『連想記憶』というテーマで多くの研究者により取り組まれている。本稿では、『連想記憶』という側面より、人間の脳のメカニズムを模擬した人工的なニューロン(neuron)の取り扱い、そのニューロンの結合であるニューラルネット

ワークの種類と特徴、ニューラルネットワークの一つである相互結合型ネットワークへの磁性体理論の適用、連想記憶の統計力学的な取扱い、GAの連想記憶への適用事例を紹介する。

#### 脳の数理的な特徴とニューラルネットワーク

##### 1 神経細胞の機能的非線形性

脳の情報処理素子は神経細胞(ニューロン)であり、その数は $10^{10}$ 個から $10^{11}$ 個程度であるといわれている。ニューロンは本体である細胞体(soma)、本体からつきだした樹状突起(dendrite)、他の細胞へつながらる軸索(axon)からなる。軸索の末端はほかのニューロンの樹状突起または細胞体に付着している。この結合部分をシナプス(synapse)という。軸索は数十から数百に分岐しており、1つの細胞が受けるシナプス結合の数は数百から数万に及ぶ。これらすべてのシナプス結合がニューロン間の信号の伝達に寄与している(図1)。ニューロンのモデルとしてニューロン内の電気パルスの発生、軸索の膜電位変化、電気パルスの伝達機構を記述するHodgkin-Huxley方程式<sup>1)</sup>が有名である。各ニューロンはほかのニューロンと信号のやりとりを行いながら集団で高度な情報処理を行っている。このニューロンの機能的な働きは信号の入力に対して出力への閾値作用であり、




図1 ニューロンの模式図

\*愛媛県立医療技術大学保健科学部臨床検査学科

信号の非線形的な変換を行っている。脳、つまりニューロンの集団の性質は個々のニューロンの性質の線形的な和でなく、複雑に絡み合った非線形的な性質を示す。ニューロン間の相互作用には正と負の作用がある。この正負の作用が複雑に非線形的な動作を営んでいる。脳のミクロな状態からマクロな状態に構造的に変化する相転移現象<sup>3)</sup>が生じている。

## 2 分散並列情報処理

脳の情報処理と従来のノイマン型コンピュータとの大きな違いは分散並列処理である。脳は一部のニューロン群が情報処理をしているのではなく、情報を分散的に表現し、それらを多くのニューロン群が並列に処理している。現在の大型コンピュータの記憶素子数は脳のニューロン数を超えるまでに至ったが、脳の柔軟な情報処理には及ばず、その実現にはほど遠い。

ニューラルネットワークを構成する情報処理素子であるニューロンのモデルとして、McCullochとPitts<sup>3)</sup>は(1)式と(2)式で表される「形式ニューロン」というモデルを提案した(図2)。

$$y = \sum_{k=1}^N w_k x_k \quad (1)$$

$$z = f(u) \quad (2)$$

ここで  $u = y - h$  である。 $u > 0$  のとき  $f(u) = 1$ 、 $u \leq 0$  のとき  $f(u) = 0$ 、 $x_k \in \{0, 1\}$  ( $k = 1, 2, \dots, N$ )、 $x$  はニューロンへの入力、 $y$  は膜電位、 $h$  は興奮の閾値、 $w_k$  はシナプス結合係数、 $z$  は出力である。 $f$  は入出力関数で図3(a)に示すステップ関数である。なお、ニューラルネットワークでは図3(b)に示すシグモイド関数もよく用いられる。

脳で行われている記憶をつかさどる素過程として、Hebbがシナプス強化則<sup>4)</sup>(Hebb則)を提案した。「ニューロンAからニューロンBに信号が入力されたとき、ニューロンBが興奮すると、ニューロンAからニューロンBへのシナプス結合係数が大きくなる」という仮説で





図2 形式ニューロン

(a)



(b)




図3 ニューロンの入出力関数  
(a) ステップ関数 (b) シグモイド関数

ある。これを「シナプスの可塑性 (synaptic plasticity)」と呼ぶ。この原理は学習則として、ニューラルネットワークの基礎概念となっている<sup>5)</sup>。

## 3 ニューラルネットワークの分類

ニューラルネットワークはその形態によって、階層型ニューラルネットワークと相互結合型ニューラルネットワークの2種類に大別される。階層型ニューラルネットワークの原型はパターン認識のため Rosenblatt<sup>6)</sup>により提案された単純パーセプトロン (perceptron) である(図4(a))。この単純パーセプトロンは形式ニューロンの自然な拡張モデルであり、パターンの線形分離が可能である。

階層型ニューラルネットワーク(図4(b))は単純パーセプトロンの機能をさらに拡張し、パターンの非線形分離が可能である。このネットワークは入力層、出力層、

複数の中間層からなる多層構造である。この階層型ニューラルネットワークはRumelhart<sup>7)</sup>により誤差逆伝搬法 (back-propagation) へと発展され、優れた認識能力を有しており、ニューラルネットワークの応用範囲が爆発的に拡大した。




図4 ニューラルネットワークの種類  
○はニューロンを表す  
(a)単純パーセプトロン (b)階層型ニューラルネットワーク  
(c)相互結合型ニューラルネットワーク

相互結合型ニューラルネットワーク (図4 (c)) はネットワークの構成要素である各ニューロンは他のすべてのニューロンと結合しており、すべてのニューロンが入力を受けて出力を出す。情報処理はすべてのニューロンの出力が平衡値に収束することで完了する。Hopfield<sup>8)</sup>によりこのネットワークに対して、物性物理学における磁性体の電子スピンと同様な取扱いが導入され、系のエネルギーが減少する方へ状態変化するモデルが発案された。このモデルはHopfieldモデルと称されニューラルネットワークの分野の発展に画期的な貢献をした。さらに、このネットワーク系の変化で、温度の概念を導入し、各ニューロンの状態が確率的に変化する Boltzmannマシン<sup>9)</sup>も登場した。このマシンでは任意の状態から出発して平衡状態では最小エネルギーの状態を最も高い確率で実現する。

ニューラルネットワークの機能の特徴に学習と自己組織化がある。学習方式には教師あり学習と教師なし学習がある。教師あり学習ではネットワークの出力と教師データとの差が小さくなるようにシナプスの結合係数の値が変更される。教師なし学習ではネットワークの出力とネットワークに内蔵された学習の質を評価する評価基準との差が小さくなるようにシナプスの結合係数の値が変更される。自己組織化とはネットワークが外部からの入力に応じて自分自身の構造を変えていくことである。これは学習の機能であり記憶も含まれる。つまり、ネットワークは入力と出力に応じてシナプスの結合係数の値を変化させる。これが先に述べたシナプスの可塑性に相当する。教師なし学習と自己組織化の代表として Kohonenにより学習ベクトル量子化法 (Learning Vector Quantization)<sup>10)</sup>が提案され注目されている。

最近、合原<sup>11)</sup>により生物の脳に近づけたニューロンのモデルから構成されたカオスニューラルネットワークが紹介された。このモデルは脳のニューロンから検出されるカオス現象を導入したものである。カオスは脳の情報処理で重要な役割を果たしていると考えられている。現在このモデルはニューラルネットワークという知的情報処理の世界での新たな息吹であり、多くの研究者により活発に研究されている。

## 統計力学的な取扱い

### 1 磁性体とスピングラスの理論

物性物理学によれば磁性体は原子レベルの小さな磁石の集合から成っている。このマイクロな原子磁石は量子力学的振る舞いをしていて、N極に相当する端が上下の2方向しか向けないと簡略化したものをイジングスピンと呼ぶ。多くのイジングスピンが相互作用してマクロな磁性体が構成されるというイジングモデルが提案された<sup>12)</sup>。

このモデルでは、2つのイジングスピン  $S_1$  と  $S_2$  の相互作用のエネルギーを  $-J S_1 S_2$  とし、 $S_1$  と  $S_2$  が平行なら  $J$ 、反平行なら  $-J$  のエネルギー値をとるとする。このモデルでは、強磁性体は低温で全体としてスピンの向きが同じ方向を向いており (図5 (a))、常磁性体は温度の上昇とともに反対向きのスピンの多数表れ磁石の性質が消えたものである。




図5 イジングモデル  
(a)強磁性体 (b)スピングラス

スピングラス<sup>13)</sup>は強磁性体や常磁性体と異なる性質をもつ磁性体である。空間的にはスピン間の相互作用の強さと符号がランダムに分布しており、時間的には変動しないスピンパターンである (図5 (b))。つまり、スピンの向きがランダムに凍結している。EdwardとAnderson<sup>14)</sup>はスピングラスの理論的なモデル (E Aモデル) としてつぎのハミルトニアンを提案した。

$$H = -\sum_{\langle ij \rangle} J_{ij} S_i S_j \quad (3)$$

ここで  $J_{ij}$  は隣り合うスピン  $S_i$  と  $S_j$  の間の相互作用を表すパラメータであり、スピンの組  $\langle ij \rangle$  ごとに独立な値をとる。この  $J_{ij}$  は空間的にランダム分布しており、系全体のマクロな特性を知るには系の時間平均と空間平均をした量を求める必要がある。統計力学<sup>12)</sup>によれば、マクロな系の性質に関する情報は、ミクロなハミルトニアン  $H$  に関係する自由エネルギー  $F$  に含まれている。自由エネルギー  $F$  は、可能なすべてのスピン配置に対する和として定義される分配関数  $Z$  から、 $F = -T \log Z$  で求められる。ところで、自由エネルギー  $F$  の空間平均 ( $[ ]$  で表す)  $F = -T [\log Z]$  の計算は困難であり、EdwardとAndersonはつぎの恒等式

$$\lim_{n \rightarrow 0} \frac{[Z^n] - 1}{n} = [\log Z] \quad (4)$$

を用いて計算することを発案した。これをレプリカ法という。同じ  $J_{ij}$  分布の  $n$  個の複製 (レプリカ) の分配関数の積  $Z^n$  の平均を求め、その結果を有限の  $n$  から 0 極限へ外挿する数学的技法である。

さらに Sherrington と Kirkpatrick<sup>15)</sup>は、このE Aモデルに無限レンジモデルを導入して、厳密解を導出した (S Kモデル)。無限レンジモデルとは、すべてのスピンの組の相互作用が無数の遠方まで同じ強さであるとする考え方である。S Kモデルではスピン  $S_i$  のそりい具合の指標である2つの秩序パラメータ  $m = [\langle S_i \rangle]$  と  $m = [\langle S_i^2 \rangle]$  は ( $\langle \rangle$  は時間平均を表す) つぎの連立方程式<sup>16)</sup>

$$m = \int_{-\infty}^{\infty} \frac{\exp(-z^2)}{\sqrt{2\pi}} \tanh \beta (J\sqrt{q}z + J_0 m) dz \quad (6)$$

$$q = \int_{-\infty}^{\infty} \frac{\exp(-z^2)}{\sqrt{2\pi}} \tanh^2 \beta (J\sqrt{q}z + J_0 m) dz \quad (7)$$

で与えられる。ここで  $\beta = 1/T$ 、 $J_0$  は  $J_{ij}$  の平均、 $J$  は標準偏差である。この式から、図6 (a) に示すように強磁性体、常磁性体、スピングラスの相転移および磁化率の磁場と温度依存性が明確にされた。

## 2 連想記憶の統計力学的な手法

脳には、記憶された内容がある手掛かりによって想起される機能が存在している。これを一般に連想記憶という。この想起は手掛かりと想起された内容によって、自己相関連想記憶と相互相関連想記憶に分類される。手掛かりと想起された内容が同じ場合が前者であり、異なる場合が後者である。たとえば、本稿序文で述べた『人の顔写真の一部分からその人の顔を思い出すこと』は自己相関連想記憶である。『日本の高い山と聞いて富士山を思い出すこと』は相互相関連想記憶である。

Hopfield モデルは自己相関連想記憶に適用されている<sup>20)</sup>。このモデルの大きな特徴は次の2点である。(i) 系のエネルギーが減少する方向にネットワーク系が状態変化をする。エネルギーの極小値で状態変化は安定な状態となる。(ii) ニューロン間のシナプス結合が対称である。各ニューロンの状態変化は同期的と非同期的取り扱いが可能である。

以下、磁性体理論でのイジングスピンとの類似性を考慮して2値 Hopfield モデル ( $S = \pm 1$ ) で自己相関連想記憶を説明する。ニューロン数  $N$  の系に  $p$  個の記憶パターン  $\xi^\mu$  ( $\mu = 1, \dots, p$ ) を埋め込む。埋め込んだパターンが直交しているとき想起可能となり、この直交化の数学的方法が幾つか提案されている<sup>17)</sup>。





図6 相図  
(a)磁性体 (b)自己相関連想記憶  
(文献16と文献18を元に作成)

ニューロン  $j$  からニューロン  $i$  への結合係数  $J_{ij}$  はHebb則に従い

$$J_{ij} = \frac{1}{N} \sum_{\mu=1}^p \xi_i^{\mu} \xi_j^{\mu} \quad (8)$$

とする。  
系は離散時間で同期的に動作するモデルを用いる。  
ニューロン  $i$  の時間 ( $t$ ) 変化は

$$S_i^{t+1} = \text{sgn}\left(\sum_{j \neq i} J_{ij} S_j^t\right) \quad (9)$$

とする。  
系のエネルギー  $H$  は磁性体の理論と同様に

$$H = -\frac{1}{2} \sum_{i,j=1(i \neq j)}^N J_{ij} S_i S_j \quad (10)$$

で定義され、系は時間変化とともにエネルギー  $H$  が減少する方向に変化する。

系の分配関数  $Z$  は

$$Z = \sum \exp(-\beta H) \quad (11)$$

$$= \sum_{S_i} \exp\left\{ \frac{\beta}{2N} \sum_{\mu=1}^p \left( \sum_{i=1}^N (S_i \xi_i^{\mu})^2 \right) - \frac{p\beta}{2} \right\}$$

となる。ここで  $\beta = 1/T$  である。

スピングラスの理論で導入されたレプリカ法、無限レンジモデルと鞍点法を駆使して、1ニューロンあたりの自由エネルギー  $f (= F/N)$  は自由エネルギー  $F (= -T \log Z)$  より次の式で与えられる<sup>16)</sup>。

$$f = \frac{1}{2} m^2 - T \langle \log 2 \cosh(\beta m \cdot \xi) \rangle \quad (12)$$

この1ニューロンあたりの自由エネルギー  $f$  からニューロン系の秩序パラメータ等のマクロな物理量が求まる。思い出そうとするパターン  $\xi^{\mu}$  の場合、系との重なり程度を示すオーバーラップは

$$m^{\mu} = \frac{1}{N} \sum_{i=1}^N S_i \xi_i^{\mu} \quad (13)$$

である。

ニューロン系の秩序パラメータ  $q$  はスピングラスと同様に  $q = \frac{1}{N} \sum \langle S_i \rangle^2$  で定義され、想起するパターン以外との系の重なり程度は

$$r = \frac{1}{p} \sum_{\nu \neq \mu} m_{\nu}^2 \quad \text{で定義される。}$$

スピングラス理論の(6)と(7)式に相当する状態方程式<sup>18)</sup>は

$$m^{\mu} = \int_{-\infty}^{\infty} \frac{\exp(-z^2)}{\sqrt{2\pi}} \tanh \beta(\sqrt{cr}z + m) dz \quad (14)$$

$$q = \int_{-\infty}^{\infty} \frac{\exp(-z^2)}{\sqrt{2\pi}} \tanh^2 \beta(\sqrt{cr}z + m) dz \quad (15)$$

$$r = \frac{q}{[1 - \beta + \beta q]^2} \quad (16)$$

と導かれる。(14)式と(15)式は(6)式と(7)式に非常に似ている形である。この状態方程式の解析結果を図6(b)に示す<sup>16)</sup>。この図の縦軸は温度  $T$  で横軸は1ニューロンあたりのパターン数  $\alpha (= p/N)$  である。図6よりスピングラス理論と自己相関連想記憶の類似性<sup>18)</sup>が分かる。 $T = 0$ での記憶容量の限界は  $\alpha = 0.138$  である。

### 3 想起過程のダイナミクスと想起能力

ここではAmariら<sup>19)</sup>に従い説明する。想起する記憶パターンを $\xi^1 = (1, 1, \dots, 1)$ とする。 $i$ 番目のニューロンへの入力信号の総和 $h_i$ は $t$ を時間として

$$h_i^t = \sum_j J_{ij} S_j^t = \frac{1}{N} \sum_j \sum_{\mu} \xi_i^{\mu} \xi_j^{\mu} S_j^t = m_i + N_i^t \quad (17)$$

と変形できる。

$m_i$ はオーバーラップ(13)式である。次の式

$$N_i^t = \frac{1}{N} \sum_{\mu \geq 2} \sum_{j \neq i} \xi_i^{\mu} \xi_j^{\mu} S_j^t \quad (18)$$

は思い出そうとしている記憶パターン $\xi^1$ 以外からの集

合でありノイズ $N_i^t$ と呼ぶ。想起の成功にはこのノイズ $N_i^t$ が大きな役割を示す。

Amariらは、オーバーラップ $m_i$ とノイズ $N_i^t$ の分散 $\sigma_i^2$ という2つのマクロな変数で系の時間発展方程式を理論的に導出した。(詳細は文献19参照)

森田ら<sup>21)</sup>は入出力関数を図7(a)に示す非単調関数にとれば、想起能力が大きく増加することを計算機計算で示し、その方法を部分反転法と名づけた。

Nishimoriら<sup>22)</sup>はAmariらの方法で、入出力関数を一般的な非単調関数 $f(h)$ に拡張し、以下の時間発展方程式を導出した。

$$m_{t+1} = \int_{-\infty}^{\infty} \frac{dz}{\sqrt{2\pi}} \exp(-z^2/2) f(m_t + \sigma_t z) \quad (19)$$

$$\sigma_{t+1}^2 = \alpha + 2\alpha m_t m_{t+1} h(m_t, \sigma_t) + \sigma_t^2 h^2(m_t, \sigma_t) \quad (20)$$

ここで、 $f' = df(h)/dh$ として

$$h(m_t, \sigma_t) = \int_{-\infty}^{\infty} \frac{dz}{\sqrt{2\pi}} \exp(-z^2) f'(m_t + \sigma_t z)$$

である。彼らは入出力関数を図7(b)に示す階段型非単調関数 $f(h)$ で計算機計算を行い、森田らの提案による想起能力の向上を確認した。

さらに我々<sup>23), 24)</sup>はダイナミクスを変え、入出力関数と想起過程の様子を詳細に調べた。ニューロンの入出力関数を図7(c)に示す矩形関数にとり、パルスの位置 $a$ と幅 $w (=b-a)$ を変え、特定な時間にこのパルスを適用した。その結果、Nishimoriらの理論の確認と矩形関数の想起能力の有効性を提案した。

## 遺伝的アルゴリズム (GA) の適用

### 1 GAの基本概念

GAはミシガン大学のHolland<sup>25)</sup>により1975年、自然界の適応現象とそのメカニズムを計算機システムに導入した生物進化過程のモデルとして発表された。染色体(chromosome)の集団から生殖のためそれを選択し、環境と適合する染色体は適合しない染色体より多くの子孫を生み出すという生物進化を模倣したアルゴリズムである。その計算手法は、個体(individual)の集団から選択(selection)、交叉(crossover)、突然変異(mutation)などを用いて新たな別の集団を生成し、最適解を探索する方法である。

最適化問題<sup>26)</sup>におけるGAによる解の探索は、目的関数を設け、それを適合度にとり、この関数に対して最大値を与えるような解を確率的に繰り返して探索する方法である。このGAの手法は極めて革新的であり、解の確




図7 非一様型入出力関数

- (a) 森田らの入出力関数 (b) Nishimoriらの入出力関数  
(c) 矩形入出力関数

率的探索手法として多くの複雑な計算問題の問題解決に適用された。ナップサック問題、遺伝子情報の解析、画像復元への応用、人工生命等、理工学的な応用例は数知れない。HollandのGAの拡張は多くの研究者により本格的に取り上げられるようになり、発展途上の研究領域となっている。

## 2 GAの相互結合型ネットワークへの応用

GAを用いて非ノイマン型の情報処理の一つとして、奈良たち<sup>27)</sup>による自己相関連想記憶での記憶探索の報告がある。その概要を彼らの文献の表現に従い述べる。ランダムに設定した遺伝子群からランダムに2個あるいは1個の遺伝子を取り出し、突然変異あるいは組替えを独立に行い、これを想起の初期パターンとする。ニューラルネットワークの収束アトラクターに対して所望の特徴をチェックし、評価を下し、遺伝子群に対して、遺伝子の入替えを行う。これらの生殖と想起の操作を指定した世代まで繰り返し行う。

我々<sup>32)</sup>も同様に、ニューロン数400の2値Hopfieldモデル( $S=\pm 1$ )で文字、数字、人の顔等の意味のある記憶パターン $\xi^{\mu}$ を50個埋め込み計算機実験を試みた。一般に埋め込んだパターンは直交していない。直交化の操作として、ムーア・ペンローズの一般化逆行列 $\xi^* = (\xi^T \xi)^{-1} \xi^T$ から導かれる結合係数 $J = \xi \xi^* = \xi (\xi^T \xi)^{-1} \xi^T$ を利用した。個体

とし400ビットの-1と1の記号列を染色体に対応させ、各記号を遺伝子として取り扱った。さらにこの個体に評価値を付加した。個体の集団である母集団 (population) に対して選択、交叉、突然変異という基本的な遺伝的操作<sup>28)</sup>を行い、収束アトラクターの評価と母集団の個体の入替えを繰り返し行い、想起がどこまで成功するかという想起能力を調べた。図8にこの流れを示す。生殖操作の概要を以下に列記する。

【母集団の初期化】複数の個体をランダムに生成した集団を初期母集団とする。【評価】想起アトラクターと見出し出す記憶パターンとオーバーラップを評価値とし、これを適合度(fitness)と同一に取り扱った。【選択】母集団から親となる個体 (染色体) を確率的に2個選ぶ操作で、ルーレット選択、トーナメント選択、エリート保存戦略、ランク戦略等の選択方法がある。我々はルーレット選択を採用した。【交叉】選択された2つの親から子孫をつくる操作である。親の染色体情報 (遺伝子) を交換する方法には、一点交叉、二点交叉、複数点交叉、一樣交叉等がある。我々は一点交叉を採用した。個体集団のうち交叉する個体数の割合を交叉確率という。【突然変異】染色体上の遺伝子座の遺伝子を別の遺伝子に置き換える操作である。染色体のうち変異する割合を突然変異率という。なお突然変異率を動的に変化させる適応変異という手法もある。【終了条件】世代数と1世代の想起回数とした。

数値実験の結果、GAは想起能力の増加には有益であるが、解の探索と最適なパラメータの決定に多大な計算時間を必要とすることが判明した。(詳細は文献32を参照)

## 3 分散遺伝的アルゴリズム (島モデル) と連想記憶の想起能力

GAでは次のような問題が生じる。(i)染色体数や世代数の増加、評価値や適合度計算の複雑化は多大な探索時間を要する。(ii)局所的な解 (擬似アトラクター) に陥る可能性が増大する。この問題を回避する方法として提案された方法が分散遺伝的アルゴリズム<sup>28)</sup> (DGA:Distributed GA) である。母集団を複数の集団に分割し、分割された集団で並列的に処理を行う方法である。分割された集団は島 (island) と呼ばれ、DGAは島モデルとも呼ばれる (図9)。この方法により、探索の並列化により探索時間は減少し、新たな移住 (migration) という操作を加えることにより一母集団のGAより良質な解が求められると予測される。このDGAを発展した並列分散処理方法には、セルラーモデル<sup>30)</sup>、マスタースレーブモデル<sup>31)</sup>等多くのモデルが提案され活発な研究が展開されている。移住は、生殖操作を独立に各島で行い、数世代に1回、各島内の複数個の個体 (移住個体:migrant) を別の島の個体と交換する方法であ

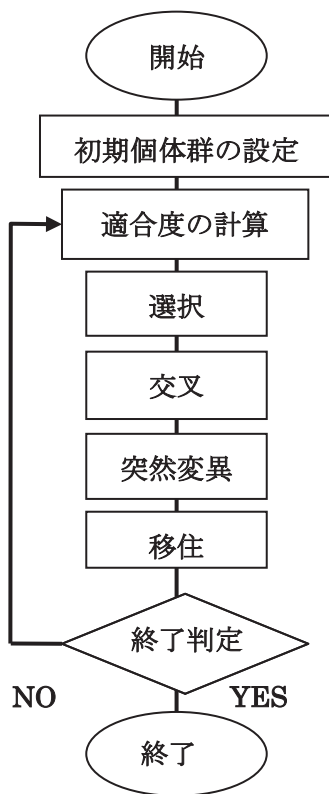


図8 GAの操作手順




図9 DGAの概念図  
4つの島の場合

る。各島における移住個体の割合を移住率、移住を行う世代間隔を移住間隔と呼ぶ。

我々<sup>32)</sup>は総個体数30、島数2で連想記憶の想起能力を調べた。移住個体の抽出には、各島の適合度の大きい個体を選ぶ方法をとった。単一母集団よりも移住の効果が反映されるDGAの方が想起能力の向上に有効であることを確認した。(詳細は文献32を参照)

## 結 語

本稿では、20世紀半ばの脳に対する生理学的な知見から生まれたニューロンのモデル化から、今日に到るニューラルネットワークでの重要課題である『連想記憶』を取り上げた。相互結合型ネットワークへの磁性体理論と統計力学の適用例、ニューロンのダイナミクスと想起能力、遺伝的アルゴリズム(GA)の連想記憶への適用例を中心に紹介した。

ニューラルネットワークの研究は、McCullochとPittsの形式ニューロンと学習機能の仮説であるHebb則が基になっている。これを基に、パターンを学習認識するパーセプトロンの登場がニューラルネットワークを大きく進展させた。Hopfieldによる相互結合型ネットワークへの物理学的な知識の導入により、ニューラルネットワークは最適化問題の解法に適用された。磁性体理論と自己相関連想記憶の数理的な類似性は脳の機能が数理的に解明される一側面を有していることを示唆している。

現在、脳の情報処理のモデル化としてニューラルネットワークのほか、新たなモデルであるGAやファジィ制御という技術が登場している。これら3つの技術には相違点や類似点があるが融合しつつある。将来、この21世紀に人間の脳の機能を模倣した柔軟な情報処理システム

や人工知能の登場が期待される。

## 参 考 文 献

- 1) Hodgkin, A.L., Huxley, A.F.(1952): A quantitative description of membrane current and its application to conduction and excitation in nerve, J.Physiol., 117, 500-544.
- 2) Amit, D.J., Gutfreund, H., Sompolinsky, H.(1987): Statistical mechanics of neural networks near saturation, Annals of Physics, 173, 30-67.
- 3) McCulloch, W.S., Pitts, W.H.(1943): A logical calculus of the ideas immanent in nervous activity, Bull. Math. Biophys., 5, 115-133.
- 4) Hebb, D.O.(1949): The organization of behavior, John Wiley.
- 5) 中野馨編著(1990): ニューロコンピュータの基礎, コロナ社
- 6) Rosenblatt, F.(1958): The perceptron: a probabilistic model for information storage and organization in the brain, Psychological Review, 65, 386-408.
- 7) Rumelhart, D., Hinton, G., Williams, R.(1986): Learning internal representation by error propagation, In Parallel distributed processing: Explorations in the microstructures of cognition, 1, p.318-362, MIT press.
- 8) Hopfield, J.J.(1982): Neural networks and physical systems with emergent collective computational abilities, Proc. Natl. Acad. Sci. USA, 79, 2554-2558.
- 9) Hinton, G. E., Sejnowski, T. J.(1986): Learning and re-learning in Boltzmann machines", In Parallel distributed processing, 1, p.282-317, MIT press.
- 10) Kohonen, T., Barna, G., Chrisley, R.(1988): Statistical patterns recognition with neural networks: Benchmarking studies, Proc. ICNN, I, 61-68.
- 11) 合原一幸(1990): カオスニューラルネットワーク, 「カオス」, 合原一幸編著, p.289-317, サイエンス社
- 12) Nishimori, H.(2001): Statistical physics of spin glasses and information processing, Oxford University Press.
- 13) Young, A. P.(1997): Spin glasses and random fields, World Scientific.
- 14) Edward, S. F., Anderson, P. W.(1975): Theory of spin-glasses, J. Phys., F5, 965-974.
- 15) Kirkpatrick, S., Sherrington, D.(1978): Infinite-ranged models of spin-glasses, Phys. Rev., B17, 4384-4403.
- 16) 西森秀稔(2002): スピングラスと連想記憶, 岩波書店
- 17) Denker, D.S.(1986): Neural network models of learning and adaptation, Physica, 22D, 216-232.
- 18) Amit, D. J.(1989): Modeling brain function, p.155-214,



Cambridge University Press.

- 19) Amari, S., Maginu, K. (1988): Statistical neurodynamics of associative memory, *Neural Networks*, 1, 63-73.
- 20) Hertz, J., Krogh, A., Palmer, R. G. (1991): Introduction to the theory of neural computation : p.11-41, Westview Press.
- 21) 森田昌彦, 吉沢修治, 中野馨 (1990): 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, J73-D- II , 2, 232-242.
- 22) Nishimori, H., Opris, I. (1993): Retrieval process of an associative memory With a general input-output function, *Neural Networks*, 6, 1061-1067.
- 23) 門田成治 (2006): 連想記憶におけるダイナミックスの特性, 電子情報通信学会2006年総合大会講演論文集, D-2-5, 8.
- 24) 門田成治 (2007): 連想記憶における想起過程の改良, 平成19年電気学会全国大会講演論文集, 3, 115.
- 25) Holland, J. H. (1975): Adaptation in natural and artificial systems, University of Michigan Press.
- 26) Goldberg, D. E. (1989): Genetic algorithms in search, optimization and machine learning, Addison-Wesley.
- 27) 奈良重俊, Davis, P., Banzhaf, W. (1993): 神経回路における複雑なダイナミックスの機能性, 「ニューラルシステムにおけるカオス」, 合原一幸編著, p.285-308, 東京電機大学出版局.
- 28) 伊庭齊志 (1994): 遺伝的アルゴリズムの基礎, オーム社.
- 29) Tanase, R. (1989): Distributed genetic algorithms, Proc. 3rd International conference on genetic algorithms, 434-439.
- 30) Gorges-Scheleuter, M. (1989): ASPARAGOS: an asynchronous parallel genetic optimization strategy, Proc. of the 3rd ICGA, 422-428.
- 31) Levine, D. (1994): A parallel genetic algorithm for the set partitioning problem, Technical report ANL-94/23, MCS, Argonne National Laboratory
- 32) 門田成治, 野島一雄 (2008): 遺伝的アルゴリズムの自己相関連想記憶への応用, 愛媛県立医療技術大学紀要, 4, 9-16.

特徴である非線形性を模擬した人工的なニューロンが提案された。(ii)ニューロンの結合システムであるニューラルネットワークは階層型ネットワークと相互結合型ネットワークに大別される。(iii)Hopfieldにより相互結合型ネットワークへのエネルギーという概念が導入され, ニューラルネットワークの研究は飛躍的な発展を行う。(iv)スピングラスの磁性体理論がEdwardとAnderson や Sherrington と Kirkpatrickにより発展され, その理論が相互結合型ネットワークに導入される。(v) Amariらや Nishimoriらによる自己相関連想記憶の統計力学的な取扱いとダイナミックスの研究を紹介した。(vi) Holland の遺伝的アルゴリズム (GA) は生物の進化を模倣した確率的探索方法である。GA の自己相関連想記憶への適用を, 我々が取り組んだ事例を織り込み紹介した。

---

## 要 旨

ニューラルネットワークは脳の情報処理機能の特性を模擬し, 理工学的に活用することを目的とした研究分野である。本稿では, 脳の機能である『連想記憶』への数理的なアプローチという観点より以下の6つの内容を中心に解説した。(i) McCulloch と Pitts により脳の神経細胞の