

非対称結合連想ネットワークによるパターンの記憶、検索機能

石井俊直 奈良重俊 久間和生
三菱電機中央研究所 岡山大学工学部電気電子工学科 三菱電機中央研究所

概要 フィードバックのある神経回路網のダイナミクスを積極的に利用した情報処理について述べる。最近、ダイナミクスの発生する複雑さを情報処理系として考える試みがなされているが、ここでは神経細胞の状態遷移方程式のパラメータを変えることで情報処理上重要なアトラクタの構造が変化する様子について議論する。その次に、sparse pattern を埋め込むことのできる新しい結合行列によるネットワークについても議論する。この結合行列による連想記憶は記憶パターンの小数個の重ね合わせがアトラクタになるという性質がある。記憶パターンに無相関なランダムパターンが入力されるとすべての神経細胞が静止する。

Memorization of Patterns and its Search by Neural Networks of Asymmetric Connection Matrix

Toshinao Ishii Shigetoshi Nara Kazuo Kyuma
Mitsubishi Electric Corp. Okayama University Mitsubishi Electric Corp.
Central Research Lab. School of Engineering Central Research Lab.

abstract We discuss about dynamics of feedback neural networks and information processing in which the dynamics is used. Recently there are many research works of application of Neural network dynamics, which is a complex dynamics, to information processing. In this article we investigate on the structure of basins of embedded attractors which is caused by parameter modulation. After that we discuss on a new Hebb type connection matrix. Sparse patterns can be embedded, as attractors, in neural network by the connection matrix. In this network dynamics the superpositions of a few embedded patterns are also attractors. In addition when input of network is a random pattern which has no correlation with embedded patterns, all neuron states goes to zero.

1 はじめに

神経回路網はその構造から階層型回路網 (layered network) と相互結合型回路網 (recurrent network) に分類される。例えば、neocognitron [1] は階層型のネットワークで自己組織によって画像認識を行なう神経回路網である。また 1970 年代前半に Nakano[2] などによって提案された連想記憶アルゴリズムは相互結合型回路網によって実現されている。ここでは相互結合型神経回路網について論じ特にそのダイナミクスを利用した情報処理について述べる。

相互結合型神経回路網では回路網の初期値が与えられると各神経細胞の状態遷移規則に依存してネットワーク全体の状態遷移が起こる。つまり回路網の状態が時間と共に変化してゆく。このようなシステムは一般に力学系と呼ばれている。ダイナミクスを利用した情報処理とはこの状態の時間変化によって行なう情報処理ということである。例えば、自己相関行列による対称結合行列を用いた連想記憶アルゴリズムにおいては「記憶パターン」は力学系の不動点として埋め込まれ、「連想」とは回路網の初期状態が埋め込まれた不動点に引き込まれることによって実現されている。

連想記憶を含む神経回路網はミクロな構造がシンプルであるのに対してマクロな振舞いが極めて複雑である。例えば連想記憶にアトラクタ¹としてパターンを記憶させた場合それにもなっているかに多くのアトラクタが作られるが、これらがどのような構造になっているかを理解するのはそれが複雑であるため難しい。またアトラクタの引き込み領域の大きさを計算機シミュレーションによって測ることはできるが、異なるアトラクタ引き込み領域の境界の構造はきわめて複雑であると考えられる。これと対照的に現在のコンピュータテクノロジーを支える記号処理に基づく情報処理においては、およそその系の振舞いの複雑さは系を記述するプログラムの複雑さと等価である。従って複雑な情報処理にはそれに応じた複雑なプログラミングが行なわれなくてはならない。

繰り返すが、神経回路網などの非線形な系はシンプルな構造から複雑な振舞いを発生する。先に述べた例のほかに非線形系の複雑さは、非対称結合連想記憶ネットワークにおける chaotic な状態遷移、パラメータを変化することによって起こる分岐現象²などにおいてもほとんど常に現れる。この複雑さは新たな情報処理を考える時、極めて魅力的である。なぜなら情報処理を、自己組織を含んだ、系のダイナミクスの複雑さに多くに依存することによって、

¹ アトラクタとは大まかに言うと力学系の状態の部分集合 A で、その周りの状態が時間が立つとアトラクタの中に入ってしまうようなものである。つまり、時間に依存した力学系の状態を $u(t)$ とすると、 $u(0) \in A$ の近傍であるなら、ある充分大きな t_0 に対して

$$t > t_0 \Rightarrow u(t) \in A$$

となるような A のことである。またこのような $u(0)$ の集合を A の引き込み領域あるいは basin という。

² 分岐現象とは系の振舞いが定性的に変化すること。




図 1: パラメータによるアトラクタの構造の変化。横軸がパラメータで縦軸が力学系の状態の集合。

プログラミングのコストを減少することが可能であると共に、系の並列性を利用してシリアル処理では計算量の爆発が起こって実際には解くことのできないような問題に対するアプローチが可能であるからである。我々は、非線形のダイナミクスを情報処理系と考えた時に、どのような情報処理機能が系にどのような形で表現されるかということを研究し、その機能のためには複雑さをどのように制御してゆくかということ調べるのがこの新たな情報処理への研究課題であると考えている。

奈良 & Davis [3] は非線形動力学系を非ノイマン型の情報処理媒体として用いることを提案し、その例として chaotic attractor の非常に複雑な構造を用いたパターン検索アルゴリズムを提案している。この方法は chaotic attractor が図 1 のようなパラメータによる分岐構造を持つことをもっている。この図は模式的なものであるが、横軸はパラメータの値を示し縦軸は神経回路網の状態である。パラメータの値が決まると、これに応じて状態がいくつかのクラスタに分かれて、アトラクタを形成する。この図では、黒く塗りつぶされたところが一つのクラスタである。アルゴリズムは、このようなクラスタ化された状態空間内で検索の際の制約条件によってカオス軌道を部分的に制御することによって実現されている。

本論文では、まず系のパラメータによるダイナミクスの振舞いの変化について考察し、次に非対称結合回路網での特徴的な性質である wandering orbit の軌道を調べる。埋め込まれたアトラクタを記憶と考えるときそれらのアトラクタ間の関係は言わば記憶の組合せである。アトラクタ間の関係は力学系のグローバルなダイナミクスに依存して決まるものであるが、パラメータでダイナミクスの振舞いを変化させるということは、記憶の組合せの構造を変化させることに相当し、このような方法によってより柔軟な情報処理が期待される。また wandering orbit は状態空間を動き回る軌道であるので例えば情報検索の際のグローブとして用いることができるであろう。その次に、ランダムス

パースパターンを埋め込むことができる新しい Hebb 型の結合行列を提案する。この結合行列による入力されたパターンが記憶されているものであるか否かを区別する神経回路網についての報告をし、それを用いた automaton のエミュレーションについて述べる。

2 入力を蓄積する神経細胞によるネットワーク

本章では、入力信号を蓄積する神経細胞によるネットワークおよびその性質について述べる。

2.1 神経細胞のダイナミクス

一般に用いられる神経細胞の McCulloch & Pitts のモデルは、離散時間で各時刻に神経細胞の入力の大きさがスレッシュホールド値より大きいか否かで二値の出力をするモデルであった。ここで用いるモデルは各神経細胞の状態遷移が非同期的に行なわれることを考慮に入れたものである。すなわち神経細胞は入力された信号を蓄積しそれがスレッシュホールド値を越えた時刻に信号を出力する。またスレッシュホールドとは別のリークパラメータが導入されていてこれらのパラメータをネットワークのダイナミクスを制御する時に積極的に利用する。

モデルの定式化のためまずいくつかの変数の定義をする。ネットワークを構成する N 個の神経細胞に番号を振り第 i 番目の神経細胞の時刻 t での状態を $s_i(t)$ ($i = 1, \dots, N$) であらわす。この「状態」とはその神経細胞が信号を出力しているか否かを表すので $s_i \in \{0, 1\}$ とする。1 は信号を出力していることを示し、これを神経細胞が興奮状態 (excited state) にあるとかあるいは神経細胞が発火している (firing state) と呼び、0 は出力していないことを示し、これを神経が静止状態 (resting state) にあると呼ぶことにする。神経細胞が興奮するか否かは外部からの信号がどのくらい届いているかによって決まる。時刻 t でそれまでに信号がどのくらい届いたかを表す変数を $u_i(t)$ ($i = 1, \dots, N$) とし、これをポテンシャルと呼ぶ。また第 i 神経細胞と第 j 神経細胞と神経細胞間の結合強度を w_{ij} とする。以上の状態変数が以下の状態遷移方程式にしたがう。

$$v_i(t) = (1-l) u_i(t-1) + \sum_j w_{ij} s_j(t-1) \quad (1)$$

$$s_i(t) = \Theta[v_i(t) - h] \quad (2)$$

$$u_i(t) = (1-s_i(t)) v_i(t) \quad (3)$$

$v_i(t)$ は式を簡単に書くための仮の変数である。また、 Θ はステップ関数で、

$$\Theta[x] = \begin{cases} 1 & \text{if } x > 0 \\ 0 & \text{otherwise} \end{cases}$$

である。 l と h はパラメータであり、 l はそれまで蓄積されたポテンシャルがダンピングする割合を示すものでリークパラメータと呼ぶ。 h はポテンシャルがその値に達する

と神経細胞が発火する値であり、スレッシュホールドと呼ぶことにする。式 (1) は、一ステップ前の時刻でのポテンシャルの値がダンプリ、そこに外部からの信号が結合行列の重みつきで加わっていることを示している。式 (2) はポテンシャルの値で信号を出力するか否かを決めている式である。式 (3) は神経細胞が発火した時にはポテンシャルを 0 にリセットしそうでなければその値を次の時刻に持ち越すという式である。

2.2 ネットワークの構成

結合行列が対称である場合にはそのダイナミクスは状態が不動点に収束するものであることが証明されている。これに対して非対称結合ネットワークでは一般には収束定理は成り立たず、パラメータによってそのダイナミクスは様々な振舞いを示すことが知られている。そこで我々の問題意識から非対称結合行列のネットワークを考え、ここではリミットサイクル型のアトラクタとしてパターンを埋め込む結合行列について考える。

記憶する第 μ 番目のリミットサイクルの第 ν 番目のパターンを $p^{\mu\nu} = \{p_i^{\mu\nu}\}$ ($\mu = 1, \dots, L, \nu = 1, \dots, M(\mu), i = 1, \dots, N$) というベクトルで表す。ただし、 $p_i^{\mu\nu} \in \{0, 1\}$ である。結合行列は、

$$w_{ij} = \sum_{\mu} \sum_{\nu} p_i^{\mu\nu+1} p_j^{\mu\nu\uparrow} \quad (4)$$

とする。ただし ν に関しては、 $\nu = M(\mu) + 1 := 1$ とする。また $p_j^{\mu\nu\uparrow}$ は $p_j^{\mu\nu}$ の随伴ベクトルと呼ばれるもので、 $\{p^{\mu\nu}\}$ の線形結合で $p^{\mu\nu} \cdot p^{\mu'\nu'\uparrow} = \delta_{\mu\mu'} \delta_{\nu\nu'}$ ³ となるベクトルである。このようなベクトルは $p^{\mu\nu}$ が一次独立である場合に一意的に存在する。この方法によれば直交していないパターンを連想記憶に埋め込むことが可能となる。このとき結合行列 $W = \{w_{ij}\}$ と埋め込むパターン $p^{\mu\nu}$ の積は

$$W p^{\mu\nu} = p^{\mu\nu+1}$$

となる。したがって、パターンはリミットサイクルとして埋め込まれていることがわかる。特別の場合として $M(\nu) = 1$ ($\mu = 1, \dots, L$) である場合にはすべてのパターンは不動点として埋め込まれる。

2.3 パラメータと引き込み領域の大きさ

連想記憶のノイズのはいつた記憶パターンの復元能力は、記憶パターンの basin の大きさをできる。なぜなら入力パターンが記憶パターンの basin にあれば復元ができるからである。ここで議論するモデルでは神経細胞が l と h というパラメータを持っていた。これらのパラメータの値を変化すると basin の構造が変化する。このことを確かめるために l の値を変えて basin の大きさを計算したものが図2と図3である。

³. はベクトルの内積




図 2: 連想記憶のアトラクタの引き込み領域の大きさ。アトラクタが不動点である場合




図 3: 連想記憶のアトラクタの引き込み領域の大きさ。アトラクタがリミットサイクルである場合。

このグラフは横軸が加えられたノイズの大きさ、⁴縦軸がパターンの復元（あるいは連想）が成功した割合である。図2はパターンを不動点として埋め込んだ場合であり図3はリミットサイクルで埋め込んだ場合である。これらのグラフはすべての記憶パターンの平均であるが、basinは大きなノイズに対して高い復元確率を持つほど（測度が）大きい。どちらの場合も神経細胞は400個で、36のパターンを埋め込んでいる。ここではスレッシュホールドは $h = 0.5$ に固定してリークパラメータの値を0.0から0.4まで変化させている。

記憶パターンのbasinの構造がどうなっているかを知ることが情報処理上重要であるが、これを調べるために、パターン復元に成功しなかった際に軌道がどのようなかを計算してみるとその振舞いは、

1. 他の埋め込まれたアトラクタに引き込まれる。
2. spurious⁵なアトラクタに引き込まれる。

⁴ここでノイズの量は記憶したパターンとのハミング距離である。

⁵spuriousなアトラクタとはパターンを記憶したときそれ以外で




図 4: 連想において、(1) ノイズを加える前の original パターンが復元される、(2) original アトラクタではないアトラクタに引き込まれる、(3) spurious アトラクタに引き込まれる、(4) すべての神経細胞が静止あるいは発火する、(5) どのようなアトラクタにも引き込まれない、の5つの場合が考えられる。 $l = 0.1, h = 0.5$ では(1)あるいは(2)が起こる確率が高い。

3. すべての神経細胞が静止する。
4. すべての神経細胞が発火する。
5. どのようなアトラクタにも引き込まれない。

の5通りであった。リークパラメータを変えた場合にそれぞれの場合がどのような割合で起こったかを示しているのが、図4および図5である。ここでスレッシュホールドはともに $h = 0.5$ である。 $l = 0.1$ の場合にはパターンの復元に失敗した場合には状態がどのアトラクタにも引き込まれない確率が大きいに対して、 $l = 0.3$ のときはその場合状態は他の埋め込まれたアトラクタに引き込まれる確率が大きくなる。またどちらの場合においても spurious アトラクタに引き込まれることと全部の神経細胞が興奮あるいは静止するという確率は非常に小さいものであった。

従って $l = 0.1$ の場合には各記憶パターンの basin の間にはどのアトラクタにも引き込まれないような wandering orbit の存在する空間があるのに対して、 $l = 0.3$ ではその空間の大きさが減少し wandering orbit が現れる確率が減少していることが予想される。

2.4 wandering orbit のダイナミクス

図4のさいに用いられたパラメータでは、wandering orbit が発生するにはかなり大きなノイズが加えられる必要があった。パラメータを様々に変えてダイナミクスの振舞いを分類すると、

type A 記憶パターンの basin が非常に小さく、アトラクタにある状態にわずかな数ビットのノイズを加えただけで状態が basin の外に出てしまうようになる。このてしまうアトラクタのことである。




図 5: $l = 0.3$ $h = 0.5$ の場合には、(1) と (5) の起こる確率が大きくなる。

場合軌道は原点 (すべての神経細胞が静止した状態) に引き込まれることが多い。

type B ノイズによって状態を記憶パターンからある程度引き離すと、wandering orbit が発生し、その軌道はどのアトラクタにも引き込まれない。

type C どのような初期状態もいずれかのアトラクタに引き込まれる。

の三種類であることがわかった。

wandering orbit は系が自律的に発生するものでありこの性質を調べることはこの系のダイナミクスに可能な情報処理機能を考える上で重要である。そこで wandering orbit が記憶パターンの basin 上をどのように移動してゆくかを調べた。このシミュレーションを示したのが図 6 である。まず状態がある記憶パターンに引き込まれたところでパラメータを type A の値にし、そこで数ビットのノイズを加える。これによって回路網の状態は遍歴的な軌道をたどりはじめるが、このままではすべての神経細胞が静止するので数ステップ後にパラメータを type B の値にする。これであるアトラクタの近くから始まる wandering orbit が得られる。この軌道が各アトラクタの basin 上をどのように移動してゆくかを調べるには各時刻にパラメータを type C の値にして軌道を記憶パターンに引き込ませれば良い。どのアトラクタが wandering orbit を引き込んだかによって wandering orbit に関する情報が得られるわけである。

このシミュレーションを実行した結果が図 7 と図 8 である。これらの図の水平面上の軸はリミットサイクルの番号を表し (i, j) の位置にある棒の高さは、wandering orbit が第 i リミットサイクルから第 j リミットサイクルに移動した確率を表わしている。図 7 は wandering orbit のはじめてから 100 ステップまでの平均で、図 8 ははじめてから 2000 ステップまでの平均である。この二つの図から wandering orbit ははじめて出発点が属していたアトラクタの basin 上




図 6: wandering orbit の初期状態との相関を調べる計算機実験。アトラクタを不安定化した状態から得られる状態を初期値としてアトラクタに引き込ませることによって wandering orbit がどのアトラクタの上にあるかを調べる。

に留まっていた徐々に他の basin を訪れるようになり、時間が充分立つとランダムに状態空間を移動するようになることがわかる。いい方を変えれば、wandering orbit は出発点の情報ははじめのうちは保持していてそれが状態遷移が繰り返されるに従って徐々に失われ充分時間が立つとほとんど完全に出発点の情報を失うのである。

2.5 パターン検索への応用

最後に wandering orbit を用いたパターン検索アルゴリズムについて考える。前節において、wandering orbit に、ある一定の情報保持しつつ状態空間を動き回る性質を持たせられることが示された。これは wandering orbit が状態空間のある部分空間のなかを高い確率で通過しつつ状態空間内を移動させられることを示すものである。そうすると、パターン検索として検索したいパターンの部分的な特徴 (制約) がわかっていて記憶パターンの中に必要とするパターンがあるかもしれないような場合にこの制約に相当する部分空間を高い確率で訪れる wandering orbit によってこの検索を行なうことができるであろう。

3 Hebb 型結合行列によるランダムパターンの記憶と I-don't-know-state

もう一つのダイナミクスを利用した情報処理の例として、Hebb 型で、sparse pattern⁶を記憶することもできる結合行列とそれによるダイナミクスについて論じる。この結合行列では記憶された sparse pattern の重ね合わせ (パターンの or をとったもの) もアトラクタになるという

⁶sparse pattern とは、パターンの興奮している神経細胞の数が静止している神経細胞の数に比べて非常に少ないようなパターンのことである。




図 7: アトラクタが不安定化された状態での wandering orbit の初めから 100 ステップまでの状態遷移確率。平面上の二つの軸はリミットサイクルの番号を表す。不安定化する前には回路網の状態は第 1 リミットサイクルにあった。




図 8: 初めから 2000 ステップまでの状態遷移確率。

特徴があり、これを利用した神経回路網による automaton のシミュレーションについて述べる。

3.1 モデル

ここでは前章と異なった結合行列の回路網について議論するので、改めていくつかの定義をする。回路網に埋め込むパターンを $p^\mu = \{p_i^\mu\}$ ($i = 1, \dots, N$) とする。 $p_i^\mu \in \{0, 1\}$ である。パターンの活動度を $a := \sum_i p_i^\mu$ と定義する。ランダムに発生された一定の活動度のパターンの集合 $\{p^\mu\}$ に対して⁷結合行列 $W = (w_{ij})$ を

$$w_{ij} := \frac{1}{R} \sum_\mu p_i^\mu (r p_j^\mu - 1) \quad (5)$$

とする。ここで、 $r > 0$ と $R > 0$ は定数である。この結合行列に対して記憶パターンからその一つ p^ν を選ぶと、 $\sum_j w_{ij} p_j^\nu = \sum_\mu p_i^\mu (\sum_j r p_j^\mu p_j^\nu - p_j^\nu)$ であるから、 N が充分大きければ、

$$\sum_j r p_j^\mu p_j^\nu - p_j^\nu = \begin{cases} (ra^2 - a)N & \mu \neq \nu \\ (ra - a)N & \mu = \nu \end{cases} \quad (6)$$

となる。ここで $r = 1/a$ $R = (1 - a)N$ とすれば、

$$W p^\nu = p^\nu \quad (7)$$

となる。また上の計算を p^ν の代わりに式 (5) できおとしたパターンに独立なランダムパターン x にして計算を行なうと、 N が充分大きいとき、

$$W x = 0 \quad (8)$$

となる。したがって、

命題 1 N が充分大きい場合、式 (5) と以上の仮定のもとでは、以下が成立する。

$$\begin{aligned} x = p^\mu &\Rightarrow W x = p^\mu \\ x \text{ がランダム} &\Rightarrow W x = 0 \end{aligned} \quad (9)$$

この命題だけでは式 (5) の記憶パターンがアトラクタであるという保証はない。この確認のために前章と同様のノイズを含む初期状態からのパターンの復元の計算機実験を行なってみた。このシミュレーションにおいては神経細胞の状態遷移方程式はよりシンプルな McCulloch & Pitts のモデルを用いた。すなわち、神経回路網の状態遷移方程式は神経細胞の状態を $s_i(t)$ として、状態遷移規則は

$$s_i(t+1) = \Theta \left[\sum_j w_{ij} s_j(t) + f_i(t) - h \right] \quad (10)$$

である。 h はスレッショルド、 $f_i(t)$ は外力である。 w_{ij} は式 (5) によって作られていて sparse pattern が回路網に埋め込まれている。シミュレーションの結果が図?? の

⁷ ここではパターンを埋め込むことを考えているのでこの集合は有限であり高々回路網の記憶容量程度の個数とする。

重ね合わせの数が1の線である。これによって、これらの不動点はある大きさの引き込み領域を持つアトラクタであるということが実験的に示された。埋め込むパターンの活動度が小さい方が引き込み領域が大きいという傾向があることも確かめられた。

式(5)の結合行列はある種の Hebb rule であるといえる。なぜなら $\sum$ の中の第1項はシナプスの両端の神経細胞が同時に興奮している時にその結合を強めるもので第2項は信号を送り出す側が興奮していて受けとった側が興奮していない場合にその結合を弱める(抑制性の結合を強める)ようなものであるからである。上記の命題から結合行列が式(5)である連想記憶回路網では埋め込まれたパターンに近い初期値からはもとのパターンを復元し、埋め込まれたパターンに無関係な⁸パターンが初期値の場合にはすべての神経細胞が静止状態になる。従ってこれは、Shinomoto が同様の機能を異なったモデルで実現しているが、言わば知らないパターンが入力された場合にはそれが知らないパターンであるということを表現する機能を持つ連想記憶である。

3.2 sparse pattern の重ね合わせ

このモデルでは記憶パターンの活動度が $a < 1$ であるときに、いくつかの記憶パターンの重ね合わせもまたアトラクタになっている。なぜなら sparse pattern は互いの相関が小さいためにいわば力学系において相互作用をせずに独立に振舞うことができる。これを計算機実験によって示したのが図9である。横軸はノイズの量、縦軸はパターンの復元に成功した確率である。このグラフでは記憶パターンから任意に3つのパターンを選んで重ね合わせを作った場合までの結果であるが、重ね合わせの数を4つ以上にするとパターンの復元の成功率は非常に低くなる。重ね合わせ数3つ程度がアトラクタの性質を保つ限界であり、多過ぎるパターンが重ね合わされると、アトラクタとしての性質は失われてしまう。多過ぎる数のパターンが重ね合わされた時には重ね合わされたパターンの内のいくつかが不安定となりそのパターンの興奮状態のビットが0になる。そのような過程を経て初期状態は、不安定にならなかったパターンの重ね合わせのアトラクタに引き込まれる。

記憶パターンをたくさん重ね合わせると出来上がったパターンの活動度は大きくなる。従って、重ね合わせを初期値とした場合その活動度は大きなものとなる。しかしながら状態遷移がある程度進むと回路網の状態の活動度はこれと無関係におよそ0.3の周りの値となった。このことは式(5)によってできるネットワークではその抑制性の結合によって活動度が大きな値がどれかようになっていいると考えられる。従って多くの記憶パターンの重ね合わせが初期値として与えられるとその活動度が大きいため記憶パターン同士の競合が起こりその際に生じるランダムな状態によっていくつかの記憶パターンとの相関が失われてゆく

⁸ 相関は $s(i) \cdot p^i$ で定義する。




図 9: 重ね合わせパターンのノイズ復元特性このグラフから記憶パターンの小数この重ね合わせもアトラクタになっていることがわかる。

というプロセスが起こっていると考えられる。

3.3 automaton のエミュレーション

ここでは前章で議論した sparse pattern の小数の重ね合わせがアトラクタとなっていて多数の重ね合わせでは競合によってそのうちのいくつかの相関のみが残るということを利用した automaton のエミュレーションについて述べる。

ネットワークは式(10)によって動作し、神経回路網の状態が automaton の状態に、神経回路網への外力が automaton の入力にそれぞれ相当する。

この神経回路網の状態が、小数の記憶パターンの重ね合わせであるアトラクタであったとしよう。そこで記憶パターンの一つを外力にすれば、新たに一つのパターンを重ね合わせた初期値として状態遷移が始まるのと同じことになる。アトラクタとなる重ね合わせパターンは記憶パターンの組合せの数よりはるかに少なく、外力として記憶パターンが加わることで状態はアトラクタである記憶パターンの重ね合わせのどれかに引き込まれる。

状態遷移規則はランダムパターンによって結合行列を作ったことによって出来上がったものである今後この規則のデザイン方法が調べられなくてはならない。

4 まとめと議論

本論文では相互結合型神経回路網が自発的に発生する複雑なダイナミクスを情報処理系としてとらえ、これに機能を与えることで複雑で柔軟な情報処理をシンプルな仕組みにより実現するという立場から、そのプロトタイプとなる例を二つ上げて議論した。第2章では神経細胞の状態遷移に非同期性とリークパラメータを導入しその basin の構造、対称結合のネットワークでは起こることのない wandering orbit の軌道について議論した。パラメータの値を変化することによって basin の構造が変化し、記憶パ

ターンの basin、wandering orbit の発生する領域などの質的に異なる性質を持つ部分空間がその構造を変えダイナミクスに影響を及ぼしていた。また wandering orbit の軌道がアトラクタの情報を保持することができることがわかった。これらの事実から構造を持った非決定性を持つもの、あるいは非決定論的ではあるが制約を満たし得るものとしてダイナミクスを利用することによる、新しいタイプの情報処理の可能性が示唆される。

つぎに第 3 章では二つめのプロトタイプでは sparse-pattern を埋め込めるということを利用した automaton のエミュレーションを試みた。生物の脳での情報がスパースなパターンによって表現されているとする考えが提案されている [4]。またこれを実現するモデルも提案されている [5]。第 3 章で議論したモデルは脳での情報表現をモデル化しようとしてできたものではないが、この視点からの議論も行なわれる必要があるだろう。また記憶パターンの重ね合わせがアトラクタになる性質については、周期の異なるリミットサイクルの重ね合わせがどのような振舞いを示すかなどについて調べられなくてはならない。さらに sparse pattern を埋め込むことのできる結合行列は相互結合型神経回路網の自己組織を可能にするものであると思われる。

生物の脳における情報処理、進化、免疫系などの生物の行なう情報処理はダイナミクスを用いた非ノイマン型の情報処理であると我々は考えている。コンピュータサイエンスの発達によってノイマン型情報処理の問題点が明らかになった現在、この新しい情報処理へのアプローチが様々な角度から行なわれていかななくてはいけないであろう。

参考文献

- [1] Fukushima, K. "Neocognitron: A Hierarchical Neural Network Capable of Visual Pattern Recognition", *Neural Networks*, vol. 1, no. 2, 119-130, 1988
- [2] Nakano, K. "Associatron - a model of associative memory", *IEEE Trans. SMC-2*, 380-388, 1972
- [3] 奈良重俊, Davis, P. "非線形道力学と情報処理", 数理科学, 311, 1989
- [4] "記憶のメカニズム", 最新脳の科学, 同文書院, 205-224, 1988
- [5] 森田昌彦 "側頭葉短期記憶力学系の神経回路モデル", 信学論 D II, J74-D-II, 1, 54-63, 1991