

非単調神経回路網による時系列パターンの認識

森田 昌彦[†] 村上 聰^{††}

Recognition of Sequential Patterns by Nonmonotone Neural Networks

Masahiko MORITA[†] and Satoshi MURAKAMI^{††}

あらまし 連続的に入力される時系列パターンを、空間パターンに展開することなく認識する神経回路モデルを提案する。このモデルでは、まず非単調ダイナミックスを用いた学習によって、認識すべき時系列パターンに対応する軌道アトラクタを回路網の状態空間中に形成する。この軌道アトラクタへの引込みを利用して、入力されたパターンの欠損部分を復元すると同時に、それが学習した時系列パターンのどれであるかを識別する。数値実験の結果、時系列パターンの間にかなりの重複があっても正しく認識できる、時間伸縮や誤った入力に対して柔軟に対応可能であるなど、従来の神経回路モデルにない特長を備えていることがわかった。

キーワード 神経回路モデル、時系列パターン、非単調ダイナミックス、非単調神経回路網、軌道アトラクタ

1. まえがき

神経回路網によるパターン認識に関して、これまで多数のモデルや手法が提案されているが、これらは基本的に静的な空間パターンを対象にしている。従って、時系列パターンを扱う場合には、多段の遅延ユニットや種々の遅延フィルタによって空間パターンに展開してから認識する[1], [2]ことになる。しかし、このような時系列パターンの認識方法には、認識可能な系列の時間長が最大の遅延時間以下に制限される、時間的伸縮への対応が困難であるといった問題がある。

また、従来の認識のモデルは、大多数がフィードバックのない層状の神経回路を用いており、回路網のダイナミックス、すなわち多数の細胞間の動的な相互作用を利用してない。Elmanのモデル[3]のように中間層の出力がフィードバックされる場合も、フィードバック結合は部分的なものであるし、クロックに同期した離散時間の動作しかできないので、ダイナミックスを十分に活用しているとは言えない。扱える時系列パターンも、離散時刻においてサンプリングしたものに限られる。

従来型のモデルのもう一つの特徴は、逆伝搬法などかなり複雑な学習アルゴリズムを用い、その改良に重点を置いていることである。特にフィードバック結合がある場合、学習則は更に複雑化する傾向にある。その結果、計算量が増大するだけでなく、学習がうまく収束しないなどの問題が生じている。

一方、人間の脳における時系列パターン認識の仕組みは、以上のような従来型モデルの枠組みから相当に外れている。脳の高次中枢には、長い系列を空間パターンに変換できるような遅延回路は見当たらない。また、ニューロン間には豊富なフィードバック結合があって、回路網のダイナミックスが積極的に利用されていると考えられる。更に、クロックによってニューロンが同期的に動作し入力がサンプリングされているとは思えないし、逆伝搬法などの複雑な学習アルゴリズムが用いられているとも考えがたい。

もちろん、工学的な応用が目的である限り、脳と同じ仕組みを用いる必要はない。しかし、従来のような枠組みでは、脳のように優れた認識能力をもつモデルを実現することは非常に難しいと思われる。本研究の目的は、より脳に近い枠組みの中で時系列パターンの認識を行う神経回路モデルを構成し、その能力と可能性を明らかにすることである。

そのような観点から興味深いものに、二見と星宮のモデル[4]がある。このモデルは、相互結合をもつ神経回路網の状態遷移を用いることによって、遅延回路

[†] 筑波大学電子・情報工学系、つくば市

Institute of Information Sciences and Electronics, University of Tsukuba, Tsukuba-shi, 305-8573 Japan

^{††} 筑波大学大学院工学研究科、つくば市

Doctoral Program in Engineering, University of Tsukuba, Tsukuba-shi, 305-8573 Japan

による空間パターンへの変換を行わずに時系列パターンを認識する。また、Elman のモデルと異なり、回路網は連続時間で動作し、状態の遷移も連続的である。しかし、残念ながら、このモデルは「おばあさん細胞型」の情報表現[5]に基づいている。つまり、状態を保持する細胞は、それぞれある特定の系列の特定の部分を表すためだけに用いられる。また、回路網が実際にとることのできる状態は、全状態のごく一部に限られる。そのため、細胞の利用効率が悪いだけでなく、いまいな情報を中間的な状態によって表現するといった、並列分散型の情報処理の特長を十分に生かすことができない。

実は、こうした問題の根底には、回路網の状態が任意の状態間を連続的かつ安定に遷移するよう制御することは、従来型のダイナミックスを用いる限り極めて困難である[6], [7]という事実がある。そのため、同期的な動作によって離散状態間を不連続的に遷移させるか、おばあさん細胞型の情報表現を用いて回路網がとり得る状態を制限する必要があったわけである。従って、上記の目的を達するには、改良したダイナミックスを用いてモデルを構成しなければならない。

現在知られているダイナミックスの改良法の中で最も簡単で効果的なのは、非単調ダイナミックス、すなわち各細胞の出力を入力の非単調増加関数としたダイナミックスを用いる方法[8], [9]である。最近報告されたように、そのようなダイナミックスをもつ神経回路網(非単調神経回路網)では、コバリアンス則に基づく簡単な学習によって、状態空間中の与えられた軌道をアトラクタにすることができる[6]。これをうまく利用すれば、より脳に近い原理に基づく時系列パターンの認識が実現できると期待される。

しかしながら、これまでの非単調神経回路網による記憶のモデルでは、重複を含まない時系列パターンだけを扱っていた。状態空間における軌道が相互に分離していないと、想起の際に混同してしまうからである。一方、認識のモデルの場合、同じ空間パターンが異なる文脈で現れるような時系列パターンを扱えなければ、単に空間パターンを識別するモデルということになる。従って、時系列パターン認識のモデルを構成するには、交差したり部分的に重なったりする軌道をうまく学習するための工夫が不可欠である。本論文は、その具体的な方法を提示するものである。

ところで、非単調な入出力特性をもつ細胞(非単調素子)自体は脳内に実在するものではなく、本モデ

ルはその点で脳と大きく違うように見える。しかし、単調な特性の細胞を組み合わせて同様なダイナミックスを実現することは可能であり、そのようなモデル[5], [10], [11]を支持する生理学的知見もある。但し、構造の単純さ、記述の簡明さ、解析のしやすさなどの面で、非単調素子を用いることの利点は大きい。本モデルでは、新しい認識原理を示すことが第1の目的なので、回路網の構成要素として非単調素子を用いている。

2. 原 理

2.1 構造とダイナミックス

本モデルは、 n 個の細胞が相互に全結合した単純な構造をしている。これらの細胞は、基本的に同一の動作式と学習則に従うが、機能に応じて入力部・中間部・出力部の 3 群に分けられる。入力部は認識すべき時系列パターンが入力される部分、出力部は認識結果が出力される部分であり、それ以外は中間部である。層状の神経回路と異なり、あらゆる細胞間に双方向の結合がある点に注意されたい。

便宜上、すべての細胞に番号を付け、1 から k 番目までを入力部、 $k+1$ から l 番目を中間部、 $l+1$ から n 番目を出力部とする。各細胞のダイナミックスは、次式によって表される。

$$\tau \frac{du_i}{dt} = -u_i + \sum_{j=1}^n w_{ij} y_j + z_i \quad (1)$$

ここで、 u_i は i 番目の細胞の内部電位、 w_{ij} は j 番目の細胞からの結合荷重、 z_i は外部からの入力信号、 τ は時定数を表す。細胞の出力値 y_i は、 u_i の非単調関数

$$y_i = f(u_i) \quad (2)$$

によって与えられる。ここでは、非単調出力関数として

$$f(u) = \frac{1 - e^{-cu}}{1 + e^{-cu}} \cdot \frac{1 + \kappa e^{c'(|u|-h)}}{1 + e^{c'(|u|-h)}} \quad (3)$$

を用いる(図 1)。 c, c', h, κ はいずれも定数であり、以下の数値実験では $c = 50, c' = 10, h = 0.5, \kappa = -1$ としている。

非単調神経回路網では、内部電位 u_i の符号が重要なので、 $x_i = \text{sgn}(u_i)$ を考え ($\text{sgn}(u)$ は $u > 0$ のとき 1, $u \leq 0$ で -1 をとる関数)、ベクトル $\mathbf{x} = (x_1, \dots, x_n)$ のことを回路網の状態と呼ぶ。ある時刻における回路

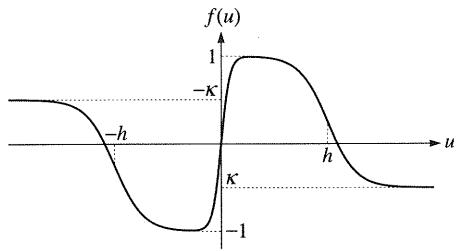


図 1 非単調出力関数
Fig. 1 Nonmonotonic output function.

網の状態 x は、 2^n 個の可能な状態からなる状態空間中の 1 点で表される。また、各 x_i は非同期的に変化するから、 x が別の状態に遷移する際には、ほとんどの場合隣の点（成分が一つだけ違う状態）に移動する。従って、状態空間中には、時間と共に x の連続的な軌跡が描かれることになる。これを x の軌道と呼ぶ。

また、 $x_{\text{in}} = (x_1, \dots, x_k)$, $x_{\text{mid}} = (x_{k+1}, \dots, x_l)$, $x_{\text{out}} = (x_{l+1}, \dots, x_n)$ をそれぞれ入力部、中間部、出力部の状態と呼ぶ。各部の状態空間と、そこでの軌道というのもも同様に考えることができる。

2.2 学習方法

議論を簡単にするため、しばらくの間 $k = l$ 、すなわち中間部がないものとする。中間部がある場合については 4. で扱うが、基本的には同じである。

認識すべき m 個の時系列パターンを $s^1(t), \dots, s^m(t)$ としよう。但し、 s^μ は土 1 を成分とする k 次元のベクトル $(s_1^\mu, \dots, s_k^\mu)$ で、各成分は非同期的に変化するものとする。このとき、 2^k 個の点（静止パターン）からなる空間において、各 s^μ に対応する m 本の連続的な軌道を考えることができる。これらの軌道は交差していてもよいし、部分的に重なっていてもよい。

これらの時系列パターン s^μ を入力部に入力したとき出力部の状態 x_{out} が目標の状態 $S^\mu = (s_{l+1}^\mu, \dots, s_n^\mu)$ になるよう、学習を行う。学習の手順は以下のとおりである。

まず、土 1 を成分とする学習信号 $r = (r_1, \dots, r_n)$ を作成する。入力部に対応する学習信号 r_{in} は s^μ そのもの、すなわち $r_i = s_i^\mu$ ($i \leq k$) である。出力部への学習信号 $r_{\text{out}} = (r_{l+1}, \dots, r_n)$ は、あるベクトル O (μ に依存しない) から S^μ へ徐々に変化していく時系列パターンである。但し、 r_{in} が終点 $s^\mu(T)$ に達した時点で $r_{\text{out}} = S^\mu$ になっていなければならない。なお、 S^μ をランダムに選んだ場合、一般性を失うこと

なく $O = (-1, \dots, -1)$ としてよい。

学習信号 r は、 x と同じ n 次元の 2 値ベクトルであるから、回路網の状態空間において、 $(s^\mu(0), O) \equiv (s_1^\mu(0), \dots, s_k^\mu(0), -1, \dots, -1)$ を始点、 $(s^\mu(T), S^\mu)$ を終点とする軌道上を進むとみなすことができる。

次に、 $x = (s^\mu(0), O)$ を初期状態とし、 $z_i = \lambda_i r_i$ という形で学習信号を入力しながら、式 (1) に従って回路網を動作させる。 λ_i は学習信号の入力強度を表し、入力部 ($i \leq k$) とそれ以外 ($i > k$) でそれぞれ別の値 λ_{in} および λ_{out} をとる。前者は定数であるが、後者は学習の進行と共に減少する変数である。

これと並行して、すべての結合荷重 w_{ij} を

$$\tau' \frac{dw_{ij}}{dt} = -w_{ij} + \alpha r_i y_j \quad (4)$$

に従って修正する。ここで、 τ' は学習の時定数で、 $\tau' \gg \tau$ である。また、 α は学習係数であるが、ここでは $\alpha = \alpha' x_i y_i$ とする (α' は正定数)。これは、 $|u_i|$ の増大と共に α が減るようにすると、 α が定数のときより学習性能が格段によくなる [6] からである。

学習信号 r が状態空間中の軌道を進むと、回路網の状態 x はその少し後を追従しながらほぼ r の軌道に添つて遷移する。 r が終点に達したら、 $r = (s^\mu(T), S^\mu)$ にしたまま、 x が r に十分近づくまで式 (4) の学習を続ける。

以上をすべての μ について行えば、1 回の学習が終了する。これを数回繰り返すが、回を重ねるごとに r_{out} の入力強度 λ_{out} を弱めていく。 λ_{out} を 0 にしても x_{out} が S^μ 付近まで到達できるようになれば、学習は完了である。

2.3 認識方法

上記の学習によって、 x の軌道 (r の軌道とは若干異なる) は、回路網が形成する力学系のアトラクタとなる [5], [6]。従って、状態空間中に m 本の軌道アトラクタが存在することになるが、これをを利用して以下のように認識を行う。

認識しようとするパターン $s' = (s'_1, \dots, s'_k)$ を、学習した時系列パターンの一つ s^1 にノイズが加わったものとしよう (s'_i は 1, 0, -1 のいずれかをとるとする)。一部の区間が欠落したものや、時間伸縮したものであってもよい。

これを $z_i = \lambda_{\text{in}} s'_i$ という形でモデルの入力部に入力する。入力部の初期状態は、 $u_i = \lambda_{\text{in}} s'_i(0)$ とすることによって与える。出力部には、初期状態として O を与えた後、外部から何も入力しない。

このように s' を入力していくと、回路網の状態 x は、入力部の軌道が最も s' の軌道に近いアトラクタ、すなわち s^1 を学習したときに形成された軌道アトラクタに引き込まれると考えられる。その結果、 s' を入力し終えたとき、出力部の状態 x_{out} が S^1 となること、すなわちモデルが入力パターン s' を s^1 と認識することが期待される。

3. モデルの動作

入力部 300 個、出力部 200 個の細胞からなる回路網 ($k = l = 300, n = 500$) を用いて、数値実験を行った [12]。動作原理の確認が目的なので、ここでは $s^1 = \{ABC\}_T, s^2 = \{ABD\}_T, s^3 = \{DAC\}_T, s^4 = \{DBC\}_T$ の 4 通りの時系列パターンを識別するという比較的簡単な課題を扱う。

ここで A, B, C, D はいずれもランダムに選んだ 300 次元の 2 値ベクトルであり、 $\{ABC\}$ は A から B を経由して C に最短距離で達する軌道（経由点の間では、番号の小さい成分から順に変化するものとする）を、 $\{ABC\}_T$ はそのような軌道をもつ時間長 T の時系列パターンをそれぞれ表す。 T はすべて 40τ とした。各入力系列に対応する出力部の目標状態 $S^1 \sim S^4$ については、まず S^2 以外の 3 個をランダムに選び、次いで S^1 との類似度（二つのベクトル間の方向余弦として定義し、1 のとき両者は一致する）が 0.5 であるベクトルの中から一つをランダムに選び、 S^2 とした。 S^1 と S^2 に類似性をもたせる理由は後述する。

各系列について、上述の方法に従って 10 回ずつ学習を行った後、 s^μ を変形したものを入力してモデルの振舞いを調べた。学習のパラメータは、 $\alpha' = 2, \tau' = 5000\tau, \lambda_{\text{in}} = 0.2$ とし、 λ_{out} は 0.2 から 0 まで徐々に減らしていく。

3.1 認識過程

結果の一例を図 2 に示す。これは、入力部の細胞 300 個中ランダムに選んだ 150 個について $s^1 = \{ABC\}_T$ と同じものを $\lambda_{\text{in}} = 0.2$ で入力し、そのほかについて $z_i = 0$ とした場合である。 $t > 40\tau$ では何も入力していない。上側のグラフには出力部の状態 x_{out} と $S^1 \sim S^4$ との類似度 $d_{\text{out}}(S^\mu)$ が、下側のグラフには入力部の状態 x_{in} と $A \sim D$ との類似度 $d_{\text{in}}(A) \sim d_{\text{in}}(D)$ が描かれている。横軸は、時定数 τ を単位とする時間である。

x_{in} と A との類似度 $d_{\text{in}}(A)$ は、初期状態での値 0.5 からすぐに 0.9 以上に増加し、それから徐々に減少す

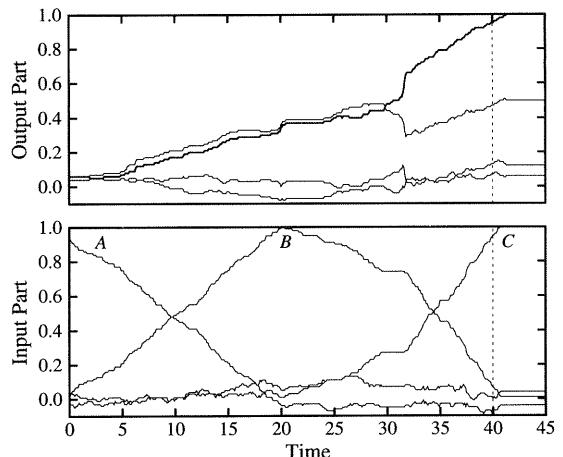


図 2 認識過程の例
Fig. 2 A process of recognition.

る。このとき、 $d_{\text{in}}(A) + d_{\text{in}}(B)$ は 1 に近い一定値に保たれるが、このことは x_{in} がほぼ軌道 $\{AB\}$ の上を移動していることを示す。その後、 $t = 20\tau$ のとき $x_{\text{in}} \simeq B, t = 40\tau$ のとき $x_{\text{in}} \simeq C$ となっており、パターン s^1 の全体が入力部に復元されていることがわかる。

一方、 x_{out} と S^1 との類似度 $d_{\text{out}}(S^1)$ (太線) は、0 付近から次第に増加していく、 $t > 40\tau$ ではほぼ 1 になっている。このことは、入力した時系列パターンを正しく s^1 と認識したことを意味する。ここで、 s^1 は他の s^μ といったところ軌道が重なっているので、ある瞬間に入力された空間パターンによって識別することは不可能であることに注意されたい。

ところで、 $t = 25\tau$ あたりまでは $d_{\text{out}}(S^2)$ が $d_{\text{out}}(S^1)$ と同様に増え、それを過ぎたところで急に両者間に差がついている。このことは、 x_{out} は最初 $\{OS^1\}$ と $\{OS^2\}$ の中間を進み、 x_{in} が B を過ぎてしばらくしてから $\{OS^1\}$ に接近することを示している。

このような認識の過程を模式的に表したのが、図 3 である。これは、 n 次元の状態空間における x の軌道を 3 次元的に描いたもので、(a) では x_1 と x_2 の 2 次元が入力部の状態を、 $x_{3,4}$ の 1 次元が出力部の状態を表している。原点は初期状態 $x_{\text{in}} = A, x_{\text{out}} = O$ (以下、 $x = (A, O)$ と表記する) である。出力部の状態空間を 1 次元では表現しきれないので、出力部に x_3 と x_4 の 2 次元をあてて同じものを描いたのが (b) である。黒

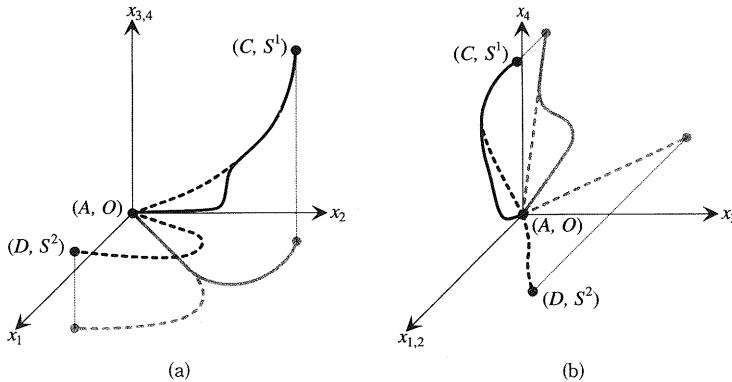


図 3 認識過程の模式図
Fig. 3 Schematic of the recognition process.

の実線は認識時の x の軌道、破線は原点から (C, S^1) および (D, S^2) へ至る学習信号 r の軌道 r^1 および r^2 を表している。また、灰色の線は、各軌道の x_1 - x_2 または x_3 - x_4 平面への射影、すなわち入力部または出力部の状態空間における軌道を表す。

学習信号の軌道 r^1 と r^2 は、入力部だけを取り出すと、前半部で完全に重なり、後半で分離している。一方、出力部では、 O を出発した直後から徐々に離れていく。従って、全体として 2 本の軌道は、重なってはいないものの、前半部でかなり接近している。

非単調神経回路網では、複数のアトラクタが近接して存在するとき、その中間の状態も比較的安定である[6],[7]。別の言い方をするならば、アトラクタに近づくほど吸引力が弱くなるという性質のため、近接したアトラクタの間では、仮想的なエネルギーの地形が平らな谷底をもつ。そのため、認識時に x_{in} が共通の軌道 $\{AB\}$ 上を動いている間、 x_{out} は $\{OS^1\}$ と $\{OS^2\}$ の中間を進む。

x_{in} が B を過ぎて C に近づくにつれ、 x は軌道 r^2 から急速に遠ざかるのに対して、軌道 r^1 からの距離はそれほど増えない。その結果、 x は 2 本の軌道の中間の状態をとることができなくなり、 r^1 に引き込まれて (C, S^1) に到達するわけである。全く同様に、 s^2 を入力すると、 x は途中から r^2 に引き込まれて (D, S^2) に達する。 s^3 や s^4 を入力した場合には、軌道が最初から分離しているので、 x_{out} はかなり早い時点から $\{OS^3\}$ または $\{OS^4\}$ 上を移動し、目標の状態に達する。

ところで、出力部の学習信号 r_{out} として、静止パ

ターン S^μ ではなく O から S^μ に変化するパターンを用いるのは、次のような理由からである。もし r_{out} が静止パターンだとすると、図 3において r_{out} は二つの点 S^1, S^2 となり、 r^1 と r^2 は最初から大きく分離したものになる。そのため、 x は両者の中間の状態をとることができず、原点を出発した直後からどちらかの軌道に引き込まれてしまう。例えば x が r^1 に引き込まれたとすれば、たとえその後 x_{in} が B から D へ向かって進んだとしても、遠く離れている r^2 に x が移ることは非常に困難である。その結果、かなりの確率で誤認識を生じてしまうことになる。

同様に、複数の系列が途中まで一致または非常に類似しているとき、それらに対応する出力部の目標状態（この場合 S^1 と S^2 ）は、ある程度似ている方がよい。そうすれば、 r の軌道がより接近するため、不十分な情報しか入力されていない段階で x が一方の軌道に引き込まれることが少なくなり、また誤った軌道に引き込まれたときにも正しい軌道へ移りやすいからである。

3.2 入力に空白区間がある場合

前節では、学習した時系列パターンの一部の成分を最初から最後まで入力した。しかし、学習によって形成された軌道アトラクタは、そこへ引き込む強い流れを周囲にもつだけでなく、学習信号 r とほぼ同じ速度で進む緩やかな流れを軌道上にもつので、必ずしも外部から入力を与え続けなくてもよい。

図 4 にその例を示す。グラフの見方は図 2 と同じであるが、太線は $d_{out}(S^2)$ を表している。まず、 $0 \leq t \leq 10\tau$ の間、系列 $\{AB\}_{20\tau}$ の前半部 (A から A と B の中間まで) をモデルに入力し、その後しばらく

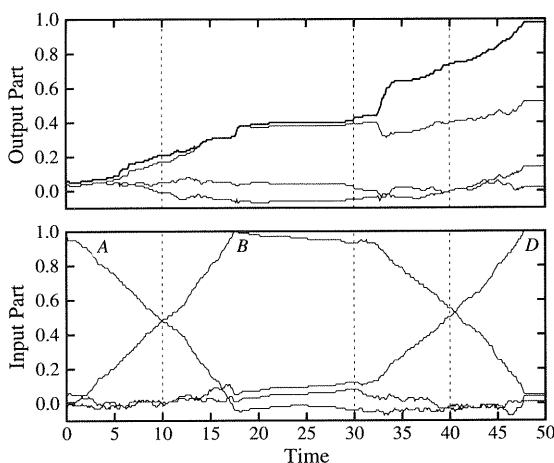


図 4 系列の一部の区間のみを入力したときの動作
Fig. 4 Behavior when the sequence with blank sections was inputted.

く入力を断った。外部入力がなくても、 x は図 2 の場合とほぼ同じ軌跡を描くことがわかる。しかし、 x_{in} が B を過ぎて C と D の中間方向に少し進んだところで、 x はほとんど動かなくなってしまった。これは、複数のアトラクタからの引力がつりあった状態と考えられる。

この状態から、 $30\tau \leq t \leq 40\tau$ の間、系列 $\{BD\}_{20\tau}$ の前半部を入力し、その後再び入力を断ったところ、 x は軌道 r^2 の方へ引き込まれ、最終的に (D, S^2) の付近まで到達した。このように、入力パターンが一部の区間で完全に欠落していても、その近くに他の軌道がなければ、欠けた部分を補って正しく認識することが可能である。

3.3 時間伸縮したパターンの認識

上述のように、基本的に x は軌道アトラクタに引き込まれた後、 r とほぼ同じ速さで進もうとする。しかし、軌道上の流れはあまり強くないので、入力パターン s' が s^μ と同じ軌道上を異なる速さで動いたとき、それが速すぎない限り、 x_{in} は s' を追従する。また、それに伴って x_{out} も遷移し、入力された時系列パターンを s^μ と認識することができる。

例として、学習した時系列パターンを時間軸方向に伸縮して入力したときの様子を図 5 に示す。(a) は $s^3 = \{DAC\}_{40\tau}$ を 5 倍に伸張したものを、(b) は $s^4 = \{DBC\}_{40\tau}$ を半分に短縮したものを入力した場合である。時間スケールを除いて、もとのパターンを入力したときとほとんど同じグラフとなる。

なお、(b) より更に T を小さくしていくと、次第に

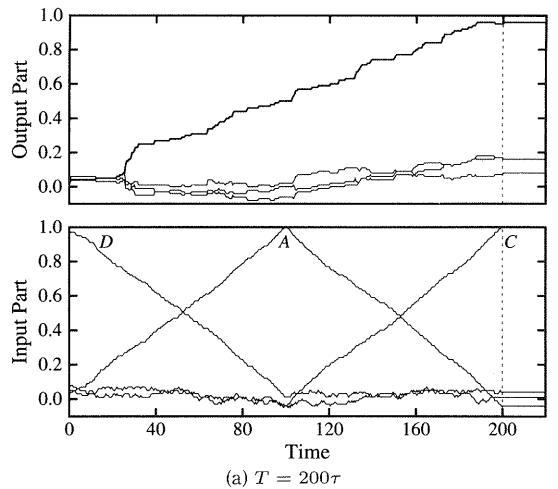


図 5 時間伸縮したパターンを入力したときの動作
Fig. 5 Behavior when the sequences with temporal extension and contraction were inputted.

x の入力に対する遅れが大きくなり、それが限度を越えると正しい認識ができなくなる。また、一般に入力パターンに含まれるノイズが多ければ、それだけ時間伸縮に対する許容範囲は小さい。

4. 中間部の導入

3. では、扱う時系列パターンの軌道が短く、それほど複雑な構造をしていなかったため、 r_{out} の軌道は O から S^μ へまっすぐ向かう短くて単純なものでよかつた。しかし、認識するパターンがもっと長く複雑になると、このようなやり方はうまくいかない。いくら出

力部の細胞数を増やして状態空間の次元を大きくしても、直線的な（両端間を最短距離で結ぶ）軌道ではパターン間の類似性を軌道間の距離にうまく反映させられないからである。

かといって、出力部の軌道を長く複雑なものにすると、認識結果を早い段階で予測することができないという問題がある。つまり、 r_{out} の軌道が直線的ならば、 x_{out} がその直線の近く ($d_{\text{out}}(O) + d_{\text{out}}(S^{\mu}) \simeq 1$ が成り立つ) に達した時点で、どの S^{μ} に向かおうとしているのか識別できるのに、複雑に曲がっていると、 x_{out} が終点近くにくるまでそれがわからない。また、必然的に出力部の次元が増大するため、認識結果を知るためにより多数の細胞の状態を観測することが必要となる。

こうした問題を解決するためには、モデルに中間部を設けるのが有効だと考えられる。すなわち、中間部の状態 x_{mid} に中程度に複雑な軌道を描かせることによって、入力部の複雑な軌道と出力部の単純な軌道との連合を可能にしようというわけである。

4.1 学習信号の生成

中間部がある場合の回路網の構造およびダイナミクスは、2.1 で述べたとおりである。中間部の導入に際して最も重要なポイントは、そこへの学習信号 r_{mid} をどのようにして作成するか、という点である。

このような場合によく用いられるのが、出力部における誤差を中間部へ伝搬させる、いわゆる逆伝搬法である。しかし、1. で述べた理由から、この種の複雑なアルゴリズムを用いるのは適当ではない。また、 r_{mid} をあらかじめ別に求めておき、学習時に読み出して回路網に与える、というのも不自然である。そこで、ここでは、 r_{in} および r_{out} から r_{mid} をリアルタイムに生成する回路をモデルに付け加えることにする。但し、そこで複雑な学習を要するのでは無意味なので、付け加える回路はなるべく単純なものにしたい。

さて、 r_{mid} に求められる性質は、軌道が r_{in} に比べて短く単純であること、 r_{in} の類似性をある程度反映していること、始点が中間部の初期状態 $O' = (-1, \dots, -1)$ に近いこと、の三つである。これらはいずれも r_{in} と r_{out} の中間に位置するものであるから、 r_{mid} を最も簡便に生成する方法として、両者を入力とするランダム変換回路を用いることが考えられる。

このようにして構成したモデルの構造を図 6 に示す。図の下半分は学習信号生成回路であり、学習時にのみ使用する。この回路には $l - k$ 個の細胞があり、その

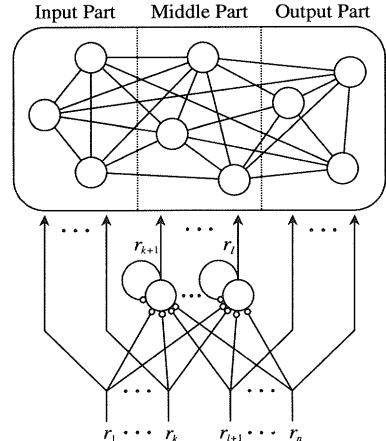


図 6 中間部をもつモデルの構造
Fig. 6 Structure of the model with the middle part.

出力が r_{mid} の成分 $r_i (k+1 \leq i \leq l)$ となる。各細胞には、 r_{in} と r_{out} がそれぞれランダムな結合荷重 a_{ij} および b_{ij} を介して入力される。また、これらの細胞は強度 $\rho (> 0)$ の自己結合をもつが、これには r_i が細かく変動するのを抑えて、 r_{mid} の軌道を短くなだらかにする働きがある。以上を式で表すと、

$$r_i = \text{sgn} \left(\sum_{j=1}^k a_{ij} r_j + \sum_{j=l+1}^n b_{ij} r_j + \rho r_i \right) \quad (5)$$

となる。但し、 $t < 0$ では $r_i = -1$ とする。

結合荷重 a_{ij} と b_{ij} は乱数によって決めるが、 $r_{\text{out}} = O$ が入力されたときに r_{mid} が O' に近くなるよう、 b_{ij} の平均値は正になるようにする。以下の実験では、 b_{ij} を平均 $1/(n-l)$ 、分散 $1/(n-l)$ の正規乱数、 a_{ij} は平均 0、分散 $1/k$ の正規乱数とした。また、自己結合強度 $\rho = 1$ とした。この場合 O' と r_{mid} の始点との類似度の期待値は約 0.84 となる。なお、これらの値は、数回の試行錯誤によって選んだものであり、最適値というわけではない。

4.2 数値実験

入力部、中間部、出力部の細胞数がそれぞれ 400, 600, 200 ($k = 400, l = 1000, n = 1200$) の回路網を用いて、数値実験を行った。

学習させた時系列パターンは、表 1 に示す 21 個である。これらは、7 個の 400 次元 2 値ベクトル $A \sim G$ をランダムに選び、それをランダムな順に結んで作成したものである。従って、 $A \sim G$ はこの中に平均 15 回ずつ出現する。また、 $\{AB\}$ や $\{AC\}$ といった小区

表1 実験に用いた時系列パターン
Table 1 Sequential patterns for the experiment.

$\{ABECD\}_T$	$\{ADACG\}_T$	$\{AEGFA\}_T$
$\{BACAF\}_T$	$\{BEFGF\}_T$	$\{BGCGF\}_T$
$\{CEABD\}_T$	$\{CEACA\}_T$	$\{CGBAB\}_T$
$\{DAFGE\}_T$	$\{DBAFB\}_T$	$\{DCDEC\}_T$
$\{EDGE\}_T$	$\{EGABD\}_T$	$\{EGEFE\}_T$
$\{FBDAE\}_T$	$\{FBGFC\}_T$	$\{FGFCB\}_T$
$\{GCECF\}_T$	$\{GDADE\}_T$	$\{GFAEF\}_T$

間は42通りあるから、これらは全系列中に平均2回現れる計算になる（実際には、どこにも含まれないものから、 $\{GF\}$ のように6箇所に現れるものまで分布している）。 s^μ の時間長 T はすべて 80τ とした。

出力部の目標状態 S^μ は O と直交するベクトルの中からランダムに選んだが、 s^{μ_1} と s^{μ_2} の軌道が先頭から $\nu+1$ 番目の経由点まで一致する場合には、 S^{μ_1} と S^{μ_2} の間に $\nu/4$ の類似度をもたせた。

$r_{in} = s^\mu$ と $r_{out} = \{OS^\mu\}_T$ 、およびこれから上述の方法で生成される r_{mid} を学習信号として、一つの時系列パターンにつき15回ずつ学習を行った。 r_{mid} の入力強度 λ_{mid} は λ_{out} と同じ値とし、0.2から0まで徐々に減少させた。学習のパラメータは、 $\tau' = 40000\tau$ とした以外、すべて3.と同じである。

学習後のモデルにさまざまなパターンを入力し、認識を行わせた。結果の例を図7および図8に示す。図の上と下のグラフは、それぞれ $d_{out}(S^\mu)$ および $d_{in}(A) \sim d_{in}(G)$ の時間変化を表す。中のグラフは中間部の状態を表すが、特定のベクトルとの類似度ではなく、 $x_{mid}(t)$ と各系列を学習するときに用いた $r_{mid}(t)$ との類似度がプロットされている。

図7は、時系列パターン $\{C'E'A'C'A'\}_T$ を入力した場合である。ここで A' , C' , E' はそれぞれ A , C , E に50%相当のノイズを加えた(400個の成分のうち、ランダムに選んだ100個について符号を反転した)ベクトルである。グラフから、入力パターンと A , C , E との類似度は0.5以下であるにもかかわらず、 x_{in} と各ベクトルとの類似度は1近くに達していることがわかる。また、 x_{mid} は $s^8 = \{CEACA\}_T$ を学習したときの r_{mid} の軌道にほぼ沿って移動し、他の系列に対応する軌道からは順次離れていくことがわかる。最終的に、 x_{out} は S^8 まで到達し、この入力パターンは s^8 と認識された。

同様に、すべての系列について50%のノイズを含むベクトル $A' \sim G'$ を用いて実験したところ、14個の系

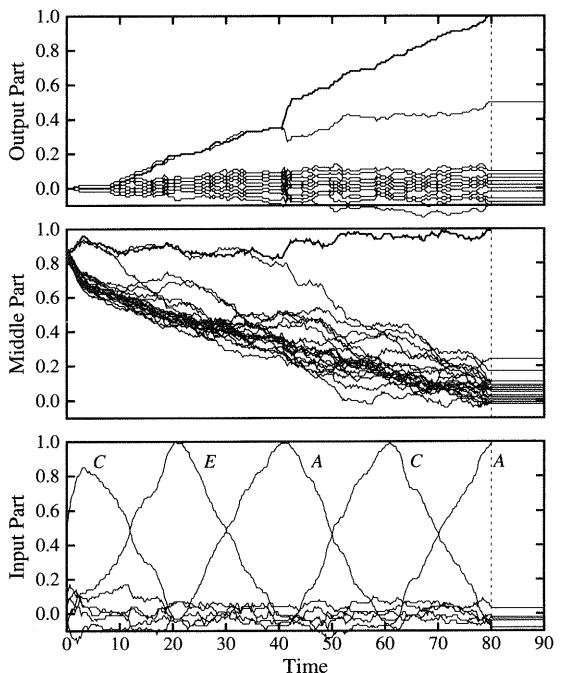


図7 中間部をもつモデルの認識過程
Fig. 7 A recognition process of the model with the middle part.

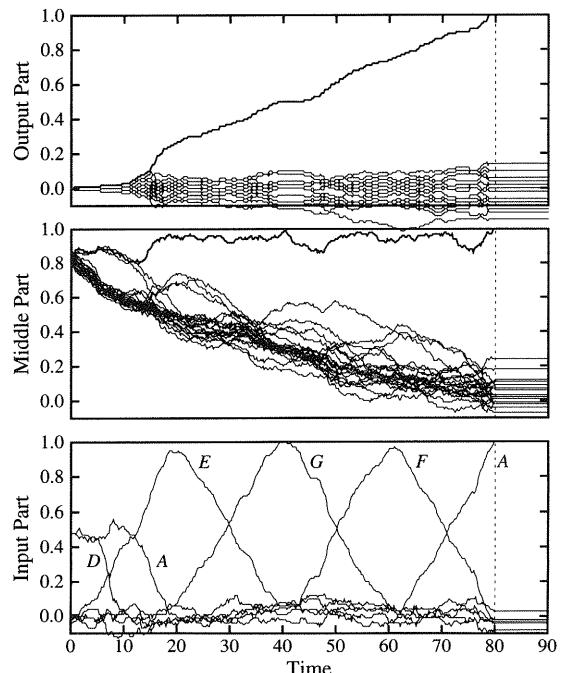


図8 あいまいな部分のあるパターンを入力した場合
Fig. 8 Behavior when the input pattern has vague sections.

列が正しく認識された。また、ノイズ成分が25%以下ならば、21個すべてが正しく認識されることを確認した。

図8は、あいまいな部分を含む時系列パターン $\{(AD)E'(AG)F'(AC)\}_T$ を入力した場合である。ここで、(AD)はAとDのちょうど中間のベクトルの一つをランダムに選んだものを表す(A' や D' との違いに注意)。同様に(AG)はAとGの中間ベクトル、(AC)はAとCの中間ベクトルである。この系列は、部分的にはかなり多数のパターン系列に類似しているが、全体として最も類似している $\{AEGFA\}_T$ と認識された。また、(AD)が入力されたとき x_{in} はAとDの中間の状態にあるが、(AG)および(AC)が入力されたときには、入力部にはそれぞれGおよびAが再生されていることがわかる。

但し、このようなあいまいなパターンは認識が難しく、うまく認識できない(多くの場合、どの S^{μ} にも到達しない)ことも多い。その原因として、この実験ではベクトルAとBとがほぼ直交しているため、(AB)はどちらのベクトルともかなり離れているということが挙げられる。類似した情報をある程度類似したベクトルで表現するようにすれば、あいまいなパターンをよりうまく扱えると思われるが、そのような符号化は今後の検討課題である。

5. む す び

非単調神経回路網に形成した軌道アトラクタを利用して、連続的に入力される時系列パターンを認識する方法について述べた。本モデルの特徴をまとめると、次のようになる。

(1) 空間パターンへの展開を行わない。従って、そのための遅延回路は不要であり、認識可能な系列の長さが制約されることもない。

(2) 内部状態が分散型の情報表現に基づいていて、連続的に遷移する。特定の離散状態間を遷移するモデルとは違って、入力されたパターンに応じて無数の状態をとれることが、柔軟な認識を可能にしている。

(3) 単純な構造をしている。また、簡単な学習アルゴリズムと比較的少ない学習回数で自己組織化される。

(4) 入力したパターンを単に識別するだけでなく、その空間および時間次元の欠損部分を復元することができる。また、時間伸縮したパターンであっても認識可能である。

これらの特徴から、このモデルは従来のものより原理的に脳に近いと考えられ、工学的な応用だけでなく脳のモデル化という面においても大きな可能性をもつと期待している。

今後の課題として、まずモデルの実験的および理論的解析を進めることが挙げられる。例えば、各部の細胞数とモデルが認識できる時系列パターンの長さや数との関係を明らかにする必要があろう。

また、今回のモデルは基本的な原理を示すものであり、これを改良し、発展させる余地は大きい。例えば、中間部を階層化することによって、より複雑な時系列パターンを効率的に扱えるようにすることが考えられる。そのほか、学習信号の生成回路の改良や、音声認識などへの応用も今後の課題である。

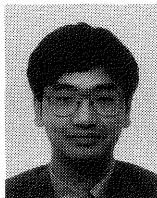
謝辞 修士課程在学中に本研究の予備実験を行ってくれた木村英一氏(現在、NTTデータ通信株式会社)に感謝する。なお、本研究の一部は、文部省科学研究費重点領域研究「高次脳機能のシステム的理諭」(No. 08279105)および奨励研究(A)(No. 08780328, 09780310)の補助を受けて行われた。

文 献

- [1] A. Waibel, "Modular construction of time-delay networks for speech recognition," *Neural Computation*, vol.1, pp.328–339, 1989.
- [2] D.W. Tank and J.J. Hopfield, "Neural computation by concentrating information in time," *Proc. Natl. Acad. Sci. USA*, vol.84, pp.1896–1900, 1987.
- [3] J.L. Elman, "Finding structure in time," *Cognitive Science*, vol.14, pp.179–211, 1990.
- [4] 二見亮弘, 星宮 望, "相互結合型神経回路網の状態遷移に基づきおく時系列パターン認識の神経回路モデル," *信学論(D)*, vol.J71-D, no.10, pp.2181–2190, Oct. 1988.
- [5] 森田昌彦, "学習・記憶の神経回路モデル," *脳と計算論*, 外山敬介・杉江 昇(編), pp.54–69, 朝倉書店, 東京, 1997.
- [6] M. Morita, "Memory and learning of sequential patterns by nonmonotone neural networks," *Neural Networks*, vol.9, no.8, pp.1477–1489, 1996.
- [7] 森田昌彦, "非単調ダイナミクスを用いた時系列パターンの連想記憶," *信学論(D-II)*, vol.J78-D-II, no.4, pp.678–688, April 1995.
- [8] 森田昌彦, 吉澤修治, 中野 鑑, "自己相関連想記憶の想起過程とその改良," *信学論(D-II)*, vol.J73-D-II, no.2, pp.232–242, Feb. 1990.
- [9] M. Morita, "Associative memory with nonmonotone dynamics," *Neural Networks*, vol.6, no.1, pp.115–126, 1993.
- [10] 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)*, vol.J74-D-II, no.1, pp.54–63, Jan. 1991.
- [11] M. Morita, "Computational study on the neural mechanism of sequential pattern memory," *Cognitive Brain Research*, vol.5, pp.137–146, 1996.

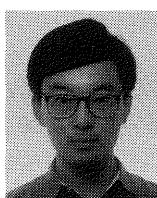
- [12] M. Morita and S. Murakami, "Recognition of spatiotemporal patterns by nonmonotone neural networks," Proc. ICONIP'97, vol.1, pp.6-9, 1997.

(平成 9 年 11 月 14 日受付, 10 年 2 月 18 日再受付)



森田 昌彦 (正員)

昭 61 東大・工・計数卒。平 3 同大大学院博士課程了。平 4 筑波大学電子・情報工学系講師、現在に至る。生体の情報処理機構および神経回路網の研究に従事。平 5 日本神経回路学会研究賞、平 6 同学会論文賞受賞。



村上 聰 (学生員)

平 7 筑波大・工学システム学類卒。現在、同大大学院博士課程工学研究科在学中。神経回路モデルの研究に従事。