クロス結合ホップフィールドネットから導出される 連想記憶モデルとそのノイズ空間ダイナミクスの役割

非会員 小 澤 誠 一 (大阪教育大学)

非会員 堤 一 義 (龍谷大学)

非会員 馬 場 則 夫 (大阪教育大学)

An Associative Memory Model Derived from Cross-Coupled Hopfield Nets and The Roll of Noise-Space Dynamics

Seiichi Ozawa, Non-member (Osaka Kyoiku University),

Kazuyoshi Tsutsumi, Non-member (Ryukoku University),

Norio Baba, Non-member (Osaka Kyoiku University)

In this paper, the association characteristics of Cross-Coupled Hopfield Nets (CCHN) proposed as a modular neural network model are discussed in an analytical way. In the CCHN, an arbitrary number of modules (Hopfield networks) can be mutually connected via feedforward networks called "internetworks", whose outputs generate the interactions among module networks. To evaluate the CCHN as a modular neural network, it has been applied to associative memories so far. Although its excellent association performance is supported by many simulation results, it is still difficult to compute the memory capacity exactly and examine the dynamical properties rigorously, because the information processing of the CCHN includes strong non-linearity. Hence, as the first step to the analytical approach, this paper focuses on a 1-module CCHN whose interaction is realized by a two-layered feedforward internetwork. In this case, the connection matrix of the CCHN degenerates into a single square-matrix like a conventional auto-association type of associative memory. Through the eigenvalue analysis for the connection matrix, we reveal that the essential differences between the association characteristics of the CCHN and a conventional auto-correlation associative memory originate from the dynamics in the noise-space which is the orthogonal complement of the subspace generated from memory patterns.

キーワード：ニューラルネット，モジュール構造，連想記憶，ノイズ空間ダイナミクス，エネルギー関数

1. ま え が き

生物の神経系にみられるように，数々の高度な情報処理は，“モジュール”と呼ばれる比較的小規模なネットワークの情報処理がうまく融合することで実現されている。我々は，このようなモジュール構造をもった人工ニューラルネットモデルとして，クロス結合ホップフィールドネット (CCHN) を提案してきた⁽¹⁾⁽²⁾。CCHNは，対称結合をもつ相互結合型ネットワーク (ホップフィールドネット⁽³⁾) が階層型ネットワークで相互結合されたものであり，情報処理がエネルギー関数として定義される点に特徴をもつ。

これまで，連想記憶に適用したシミュレーション実験により，CCHNの性能や動特性を調べてきた。その結果，CCHNはモジュール構造ニューラルネットモデルとしてだけでな

く，連想記憶モデルとしても優れた性質をもつことが示された。しかし，モデルのもつ非線形性のため，動特性に関しては状態空間におけるエネルギー関数の局所的形状に対する考察にとどまっていた⁽⁴⁾。しかし，この方法でモデルの大局的な動特性を考察するのは効率的でない。

ニューラルネットにおける連想記憶モデルの動特性や記憶容量に関する解析は，スピングラスの理論⁽⁵⁾やS/N解析^{(6)・(8)}などを用いた統計的手法と結合行列の固有値を調べる幾何的方法⁽⁹⁾⁽¹⁰⁾に大別される。前者では，結合荷重を介してフィードバックされた信号のうち，想起すべき記憶パターンと同成分をもつ信号とそれ以外のノイズ信号 (クロストーク) を分離し，それらの統計的性質を調べることで記憶容量が計算される。後者では，記憶パターンから生成されるメモリ空間と，その直交補空間であるノイズ空間

とに分け、それぞれの部分空間におけるネットワークの動特性を幾何的に考察する。

前者の手法では、記憶容量や動特性に関して厳密な考察が行えるが、取り扱いが容易でなく、相互作用を生成するための階層型ネットワークをもった CCHN では解析がかなり複雑になると考えられる。そこで本論文では、後者の幾何的手法を通して、CCHN の動特性に対する考察を行う。この方法を最もシンプルな CCHN モデルに適用したとき、相関行列を結合荷重とするホップフィールドネットとの相違が、ノイズ空間において非常に明確なカタチで表されることを示す。また、このノイズ空間における CCHN のダイナミクスが優れた連想性能につながることを示す。

2. クロス結合ホップフィールドネット (CCHN)

堤によって提案された CCHN は、その後、幾つか点で拡張が行われたが、本論文では、連想記憶能力の解析を容易にするため、構造的にシンプルなオリジナルの CCHN モデル⁽¹⁾を採用する。

オリジナルの CCHN(以下、単に CCHN と呼ぶ)では、モジュールであるホップフィールドネットの安定状態間に、望まれる対応関係が定義されている。これによって、モジュールネットは単に自己に定義された情報処理を行うだけでなく、他のモジュールとの対応関係を同時に満足するよう動作する。CCHN では、このような動作の記述をエネルギー関数として定義する。モジュール数が M であるときのエネルギー関数を以下に示す。

$$\begin{aligned}
 E &= \sum_{m=1}^M \alpha^{(m)} E^{(m)} + \sum_{m=1}^M \sum_{n=1}^M \beta^{(n,m)} E^{(n,m)} \\
 &= \sum_{m=1}^M \alpha^{(m)} \left[-\frac{1}{2} \sum_i \sum_j T_{ij}^{(m)} v_i^{(m)} v_j^{(m)} \right. \\
 &\quad \left. + \sum_i \frac{1}{r_i^{(m)}} \int_0^{v_i^{(m)}} g_i^{(m)-1}(v) dv - \sum_i I_i^{(m)} v_i^{(m)} \right] \\
 &\quad + \sum_{m=1}^M \sum_{n=1}^M \beta^{(n,m)} \left[\frac{1}{2} \sum_i (v_i^{(m)} - f_i^{(n,m)}(v^{(n)}))^2 \right] \quad (1)
 \end{aligned}$$

ここで、 $T_{ij}^{(m)}$ 、 $v_i^{(m)}$ 、 $I_i^{(m)}$ 、 $r_i^{(m)}$ はそれぞれ第 m モジュールの結合荷重、状態、外部入力、エネルギー損失を決定する係数を表す。また、 $g_i^{(m)}(v)$ は微分可能な単調増加関数で、 $\alpha^{(m)}$ 、 $\beta^{(n,m)}$ はそれぞれモジュールネットと相互作用の情報処理の全体に対する重要度を決定する正の定数である。 $f_i^{(n,m)}(v^{(n)})$ は第 n モジュールの状態に対する第 m モジュールの望ましい状態を表しており、両者のモジュールの状態関係を定義する関数である。後述するように、この状態関係からモジュール間の相互作用が生成される。

(1) 式右辺第一項の $E^{(m)}$ は、モジュールの情報処理を定義するエネルギー関数であり、アナログ型ホップフィールドネットのエネルギー関数に等しい。よく知られているように、このエネルギー関数の最小点は結合荷重 $T_{ij}^{(m)}$ によ

図 1 クロス結合ホップフィールドネットの概念図

Fig. 1. Conceptual Diagram of Cross-Coupled Hopfield Nets

て変化する。また、第二項の $E^{(n,m)}$ はモジュールネット間の相互作用を定義するエネルギー関数であり、 $f_i^{(n,m)}(v^{(n)})$ が第 n モジュールの状態に対する第 m モジュールの望ましい状態であることから、 $E^{(n,m)}$ は 0 で最小となる。つまり、CCHN におけるエネルギー関数の定義は、各モジュールが自己に与えられた情報処理を行いながら、同時に他のモジュールとの相互関係を満足するよう動作することを要求している。

相互作用のエネルギー関数に含まれる $f_i^{(n,m)}(v^{(n)})$ は一般に未知であることが多いため、階層型ネットワークとしてインプリメントすれば、ネットワークの持つ優れた学習能力・想像能力・汎化能力によってこの $f_i^{(n,m)}(v^{(n)})$ を精度よく獲得・実現することが可能となる。この階層型ニューラルネットは、モジュールネット間を結合するネットワークという意味で“インターネット”と呼ばれる。インターネットの入出力関係を以下に示す。

$$\begin{aligned}
 o_i^{(n,m)(l+1)} &= g_i^{(n,m)} \left(\sum_j W_{ij}^{(n,m)(l)} o_j^{(n,m)(l)} \right) \\
 &\text{for } l = 1, \dots, L+1 \quad (2)
 \end{aligned}$$

$$o_i^{(n,m)(1)} = v_i^{(n)} \quad (3)$$

ここで、 $o_i^{(n,m)(l)}$ 、 $W_{ij}^{(n,m)(l)}$ はインターネット第 l 層のユニット出力および結合荷重を表す。また、 L は中間層数である。(1)(2) 式において、 $f_i^{(n,m)}(v^{(n)}) = o_i^{(n,m)(L+2)}$ と対応付けられる。

以上より、CCHN は、図 1(a) に示すような複数のホップフィールドネットがインターネット (図 1(b)) により相互に結合されたネットワークモデルである。CCHN のネットワークダイナミクスは、(1) 式のエネルギー関数の定義から明らかのように、これを減少させるよう導出される。そ

ここで、(1) 式を時間 t で微分し、常に $dE/dt \leq 0$ が成り立つようにダイナミクスを決定する⁽¹⁾。

前述したように、本論文では連想記憶能力の解析を容易にするため、なるべくシンプルな CCHN モデルを取り扱う。具体的には、モジュール数が 1 で、インターネットには中間層を含まない 2 層の階層型ネットワークを採用したモデルを取り上げる。このようなモデルは、もはやモジュール構造ニューラルネットとはいえないが、連想記憶モデルとしての CCHN の基本特性を理解するのに役立つと考えられる。また、連想記憶モデルで一般に使われないモジュールの外部入力とエネルギー損失の項は考慮しないことにする。次節では、このような CCHN モデルのダイナミクスを求め、学習が十分収束したときの CCHN を連想記憶モデルとして提案する。

3. 連想記憶モデルの提案

前節で述べたように、本論文ではモジュール数が 1 で、インターネットとして 2 層の階層型ネットワークを採用した CCHN を用いる。また、モジュールの外部入力とエネルギー損失の項は考慮しない。このようなネットワークは、モジュール内の結合とインターネットの結合を一つの結合行列にまとめることができるため、ホップフィールドネットと同じ全結合フィードバック型アーキテクチャをもつと見なせる。ここでは、モジュール及びインターネットに十分学習が行われた後の結合行列を求め、そのネットワークを連想記憶モデルとして提案する。

まず、(1)~(3) 式でモジュール数を 1、中間層数を 0、インターネットの出力関数 $g_i^{(n,m)}$ を線形関数としたときのエネルギー関数を以下に行列表示で表す。

$$E = -\frac{\alpha}{2} \mathbf{v}' \mathbf{T} \mathbf{v} + \frac{\beta}{2} (\mathbf{v} - \mathbf{W} \mathbf{v})' (\mathbf{v} - \mathbf{W} \mathbf{v}) \quad \dots (4)$$

但し、 $\mathbf{v} = (v_1 \dots v_N)'$ はネットワークの状態ベクトルであり、 N はユニット数である。モジュール番号を表す上付き添字は省略している。また、 $\mathbf{T} = \{T_{ij}\}$ 、 $\mathbf{W} = \{W_{ij}\}$ は、それぞれモジュールとインターネットの結合行列で、どちらも $N \times N$ の正方行列になる。 $\mathbf{v}'$ は行列 $\mathbf{v}$ の転置を表す。前述のとおり、(4) 式はホップフィールドネットと同様に $\mathbf{v}$ の二次形式として表すことも可能である。以下では、このエネルギー関数の特徴をネットワークダイナミクスの動特性に置き換えて議論する。

(4) 式からネットワークのダイナミクスを導出するには、まず E を時間 t で微分する。

$$\begin{aligned} \frac{dE}{dt} = & -\alpha \left(\frac{d\mathbf{v}'}{dt} \mathbf{T} \mathbf{v} + \frac{1}{2} \mathbf{v}' \frac{d\mathbf{T}}{dt} \mathbf{v} \right) \\ & + \beta \left[\frac{d\mathbf{v}'}{dt} (\mathbf{I} - \mathbf{W})' (\mathbf{I} - \mathbf{W}) \mathbf{v} - \mathbf{v}' \frac{d\mathbf{W}'}{dt} (\mathbf{I} - \mathbf{W}) \mathbf{v} \right] \quad (5) \end{aligned}$$

E は小さいほど望ましいわけであるから、ネットワーク状態および結合荷重は、 E が単調減少するように更新すればよい。そこで、 $dE/dt \leq 0$ が常に満たされるような状態と結合のダイナミクスとして、以下のものを得る。

$$c \frac{d\mathbf{u}}{dt} = \{\alpha \mathbf{T} - \beta (\mathbf{I} - \mathbf{W})' (\mathbf{I} - \mathbf{W})\} \mathbf{v} \quad \dots (6)$$

$$\varepsilon \frac{d\mathbf{T}}{dt} = \mathbf{v} \mathbf{v}' \quad \dots (7)$$

$$\eta \frac{d\mathbf{W}}{dt} = (\mathbf{I} - \mathbf{W}) \mathbf{v} \mathbf{v}' \quad \dots (8)$$

$$\mathbf{v} = \tanh(\mathbf{u}) \quad \dots (9)$$

ここで、 $\mathbf{I}$ は単位行列、 c, ε, η は正の時定数である。(6) 式はユニットの活性ダイナミクスで、これに従ってユニットの状態は変更されていく。(7)(8) 式は、それぞれ、モジュールネットとインターネットの結合荷重を更新する学習ダイナミクスに相当する。

導出されたネットワークダイナミクスにおいて、時定数に関する制約は特になが、ここでは、連想記憶モデルの導出を容易にするため $c \ll \varepsilon, \eta$ という関係を仮定する。これは、「結合荷重が変更されるスピードは、ユニットの状態が変更されるスピードに比べて十分遅い」ということを意味しており、生物学的にみても不自然なものではない。この仮定が成り立つとき、(6)~(8) 式の連立微分方程式は、(7)(8) 式の解を独立に解き、その解を (6) 式に代入することで近似的に解くことができる。

そこで、 P 個の記憶パターン ξ^μ が与えられたときの (7)(8) 式の解を求める。厳密には記憶パターンを提示するダイナミクスも定義する必要があるが、ここでは ε, η が十分大きいものとして、一回のパターン提示における結合荷重の修正量は十分小さいと考える。この場合、以下のような学習ダイナミクスで近似的に (7)(8) 式を置き換えることができる。

$$\varepsilon \frac{d\mathbf{T}}{dt} = \sum_{\mu=1}^P \xi^\mu \xi^{\mu'} \quad \dots (10)$$

$$\eta \frac{d\mathbf{W}}{dt} = \sum_{\mu=1}^P (\mathbf{I} - \mathbf{W}) \xi^\mu \xi^{\mu'} \quad \dots (11)$$

これは記憶パターンを一度に提示し、結合を修正するバッチ学習に相当する。

(10)(11) 式は線形の微分方程式になり、解は容易に求められる。これらを以下に示す。

$$\mathbf{T}(t) = \mathbf{T}(0) + \frac{\mathbf{S}}{\varepsilon} t \quad \dots (12)$$

$$\mathbf{W}(t) = \mathbf{W}(0) \exp\left(-\frac{\mathbf{S}}{\eta} t\right) + \mathbf{Q} \mathbf{B}(t) \mathbf{Q}^{-1} \quad \dots (13)$$

但し、

$$\mathbf{S} = \sum_{\mu=1}^P \xi^\mu \xi^{\mu'} = \mathbf{Q} \mathbf{A} \mathbf{Q}^{-1} \quad \dots (14)$$

$$\mathbf{A} = \begin{pmatrix} \lambda_1 & & & \\ & \ddots & & \\ & & \lambda_r & \\ & & & 0 & & \\ & & & & \ddots & \\ & & & & & 0 \end{pmatrix} \quad \dots (15)$$

$$B(t) = \begin{pmatrix} 1 - \exp(-\frac{\lambda_1}{\eta} t) & & \\ & \ddots & \\ & & 1 - \exp(-\frac{\lambda_r}{\eta} t) & 0 \\ & & & \ddots & 0 \end{pmatrix} \quad (16)$$

S は記憶パターンの相関行列に相当し、それを対角化した行列を A 、固有ベクトルを並べた行列を Q とする。相関行列の性質から、 S のランクを $r (\leq P)$ とすれば、固有値 λ_i は r 個の正の固有値と $(N - r)$ 個の零固有値で与えられる。また、固有ベクトルは互いに直交し、 Q は直交行列で与えられる。

(12) 式より、 T は S と時間 t を掛け合わせたものとなり、時間とともに行列のノルムが大きくなっていくが、その性質は変わらない。そこで、 W がほぼ収束する適当な時間 $t' = \varepsilon \gg \eta$ を設定し、このときの T, W を (6) 式に代入することで、活性ダイナミクスに対する次の近似を得る。

$$\frac{du}{dt} = Q C Q^{-1} v \quad (17)$$

$$v = \tanh(u) \quad (18)$$

$$C = \begin{pmatrix} \alpha \lambda_1 & & & \\ & \ddots & & \\ & & \alpha \lambda_r & -\beta \\ & & & \ddots & -\beta \end{pmatrix} \quad (19)$$

但し、各結合行列の初期値は 0 とした。

(17) 式は、ここで求めた CCHN が $Q C Q^{-1}$ を結合行列とする自己想起型連想記憶モデル (ホップフィールドモデル) と等価であることを示している。インターネットが線形ネットワークである 1 モジュール CCHN から導出されたという意味で、以下では、このモデルを CCHN-L1 と呼ぶことにする。次節では、この CCHN-L1 の連想性能および動特性について考察する。

4. シミュレーション実験および考察

〈4・1〉 連想記憶能力の評価 本節では、まず、導出した CCHN-L1 の連想性能をシミュレーション実験により調べることとする。記憶パターンとして、各ビットが 1/2 の確率で ± 1 の値をとる 200 次元のランダムベクトルを用いた。この場合、パターンベクトルはほぼ一次独立であると考えるべく、相関行列 S のランクはパターン数 P に等しくなる。なお、ネットワークのユニット数は 200 である。(19) 式の α, β はそれぞれ 1, 0.3 とした。また比較のため、相関行列 S および次式の行列 D を結合荷重とするホップフィールドモデルについても連想性能を調べる。

$$D = X(X'X)^{-1}X' \quad (20)$$

$$X = (\xi^1 \ \xi^2 \ \dots \ \xi^P) \quad (21)$$

図 2 連想性能の比較

Fig. 2. Comparison of Association Performance

(20) 式を結合行列とする連想記憶モデルは、擬似一般化逆行行列を用いた最適連想写像モデル⁽¹¹⁾と呼ばれる。以下では、(14) 式の S を結合行列とするホップフィールドネットを HN-COR、(20) 式の D を結合行列とするものを HN-OPT と呼ぶ。

シミュレーション結果を図 2 に示す。ここで、横軸の記憶率 r はユニット数 N に対する記憶パターン数 P の割合、縦軸の限界方向余弦 d_c は 98% の確率で正しい想起が行なわれる初期状態 v_0 と想起すべき記憶パターン ξ^* との方向余弦の最小値を表す。方向余弦 d は以下の式で求められる。

$$d = \frac{1}{N} v_0' \xi^* \quad (22)$$

一般に、 d_c が小さいほど平均的な引き込み領域が大きいといえる。

図 2 から分かるように、HN-COR は $r > 0.1$ で引き込み領域を失っている。それに対し、HN-OPT と CCHN-L1 では、 r が大きくなるにつれて引き込み領域が小さくなるものの、 $r < 1.0$ であれば連想記憶モデルとして十分に機能しているといえる。また、CCHN-L1 の性能は全般的に HN-OPT より優れていることがわかる。

(14) 式の S と (17) 式の $Q C Q^{-1}$ から明らかのように、HN-COR と CCHN-L1 の結合行列の大きな違いは、 S の零固有値が $Q C Q^{-1}$ では負の定数になっている点である。これだけでも関わらず、図 2 の連想性能が大きく異なるのはなぜだろうか。これについて、次節で議論を試みる。

〈4・2〉 連想特性に関する考察 (14) 式の相関行列では、大きく非零固有値に属する空間と零固有値に属する空間とに分けられる。非零固有値に属する空間は記憶パターンから生成された空間であり、これを以下では“メモリ空間”と呼ぶことにする。それに対し、零固有値に属する空間はメモリ空間と直交した空間であり、これを“ノイズ空間”と呼ぶことにする。CCHN-L1 では、メモリ空間に対する固有値は HN-COR と同じであるが、ノイズ空間に対する固有値は負の定数となる。つまり、HN-COR と CCHN-L1

の特徴的差異は、ノイズ空間におけるダイナミクスに明瞭に現れるはずである。そこで本節では、これら2つのモデルにおける連想特性を、大きくメモリ空間とノイズ空間に分けて考察する。

ホップフィールドネットワークを用いた連想記憶モデルの場合、そのダイナミクスは大きく2つの要素に分けられる。一つは結合行列による線形変換であり、もう一つは内部状態からユニットの出力に変換される非線形変換である。金道らは、HN-CORの状態変化は主に前者の線形変換により駆動されるが、これだけでは記憶パターン上における状態の安定性が確保されないことを示した⁽¹⁰⁾。これは、HN-CORにおいて信号が繰返しフィードバックされると、線形変換は結合行列の最大固有値に属する固有ベクトルの方向に状態を収束させる性質をもっているからである。但し、これはユニット出力での非線形変換を無視した場合であって、実際には、非線形変換による状態の引き込み(量子化)が伴う。この引き込まれた状態が記憶パターンに等しければ、正しく想起されたことになる。しかし、記憶パターン数が多くなると、一般に結合行列の最大固有値が他の固有値に比べ相対的に大きくなり、記憶パターン付近での線形変換による不安定化作用が非線形変換による安定化作用に比べて強まる傾向をもつ。このため、HN-CORの連想性能はパターン数の増加とともに悪化する⁽¹⁰⁾。

またHN-CORでは、ノイズ空間に属する状態成分は線形変換によってほとんど影響を受けない。つまり、想起の開始時点において、ネットワークの状態がノイズ空間に成分をもつとき、HN-CORの線形変換によるダイナミクスだけではこの成分を取り除くことはできない。このことは、たとえ記憶パターン数が少なくても、HN-CORが記憶パターン付近であまり大きな引き込み領域をもてない一因となっている。このため、相関行列の対角要素を零にしたものが結合行列としてよく使われる。この場合、固有値の和が零となることから、ノイズ空間の固有値は負の定数となる。つまり、ノイズ空間成分を減少させるようなダイナミクスが発生する。しかし、その固有値の絶対値はメモリ空間の最大固有値より大きくならないため、メモリ空間におけるダイナミクスが主流であることには変わりはない。なお本論文では、CCHNにおけるモジュールネット内の学習則は通常の相関行列を導くものとしているため、対角要素を零とする相関行列は扱わないことにする。

一方、CCHN-L1の結合行列は QCQ^{-1} であるので、ノイズ空間の固有値を定数 β によって任意に設定できる。いま、この β の絶対値がメモリ空間における最大固有値より十分大きいと仮定する。状態のノイズ空間成分が大きい場合、(17)式のダイナミクスで主流となるのは、明らかに状態のノイズ空間成分を減少させるダイナミクスである。つまり、ノイズ空間成分はほぼ単調に減少する。しかし、この空間成分の減少に伴ってノイズ空間における状態変化量も減少するため、やがてダイナミクスの主流はメモリ空間へ移っていく。この結果として、ネットワークの状態はあ

図3 固有空間成分の時間変化
Fig. 3. Time Courses of Eigenspace Component

る記憶パターンで安定化されることになる。また、ノイズ空間成分が大きい間は、メモリ空間における状態変化量が相対的に小さくなるため、相関行列の場合に問題となった、過度に最大固有値の空間成分が増大される現象は起こりにくくなる。つまり、ノイズ空間における固有値の絶対値がメモリ空間の最大固有値より十分大きいことが偽記憶の想起を防止し、CCHN-L1の優れた連想性能へつながると考えられる。

以上のことを確認するため、ネットワークに適当な初期状態から想起させたときの、メモリ空間成分とノイズ空間成分の時間変化を調べることにする。なお、メモリ空間においては、上位 $P/2$ 個の大きい固有値に属する固有ベクトルで張られる部分空間と下位 $P/2$ 個の小さい固有値で表される部分空間に分けることとし、前者をメモリ空間(大)、後者をメモリ空間(小)と呼ぶ。これら2つのメモリ空間とノイズ空間における固有空間成分の2乗平均値を数値計算で求めた。但し、HN-CORおよびCCHN-L1におけるユニット数、 α, β の値は $\langle 4, 1 \rangle$ で用いたものと同じとする。記憶率を0.2、初期状態の方向余弦を0.3としたときの計算結果を図3に示す。なお、この条件においては、HN-CORは想起に失敗し、CCHN-L1は想起に成功する。

図3において、メモリ空間成分は左縦軸、ノイズ空間成分は右縦軸で表されている。また、固有空間成分の絶対値は状態変化量に相当する。

図3(a)で分かるようにHN-CORでは、固有値の大きいメモリ空間のダイナミクスが時間とともに優勢になっていく様子がわかる。つまり、メモリ空間(大)における状態変

化量の増加に比べ、メモリ空間(小)における状態変化量はあまり変化しない。記憶パターンの固有空間成分は固有値の大小に関わらず広く分布していることから、このことは、明らかに偽記憶を想起する原因となっている。

一方、図3(b)でわかるようにCCHN-L1では、まずノイズ空間成分の減少が起こり、30ステップ程度で、メモリ空間成分の変化量が増加している。このとき、大小どちらの固有値に属するメモリ空間において同程度の比率で状態変化量が増加しており、メモリ空間(大)だけでなく、メモリ空間(小)のダイナミクスもうまく機能していることがわかる。このことは、想起の初期段階で優勢となるノイズ空間ダイナミクスが、最大固有値の空間成分の過大な増大を防止する役割も果たしていることを示している。

5. あとがき

モジュール間を結合する階層型ネットワークが2層である1モジュールCCHNモデルから、自己想起型連想記憶モデル(CCHN-L1)を導出した。ランダムパターンを記憶とする連想記憶の問題に適用したところ、相関行列を結合荷重とする自己相関連想記憶モデルだけでなく、一般化逆行列を用いた最適連想画像モデルと比較しても、CCHN-L1は優れた連想性能をもっていることが示された。さらに、記憶パターンから生成されたメモリ空間とそれ以外のノイズ空間に分離して、CCHN-L1のダイナミクスを固有値解析を通して考察した。その結果、CCHN-L1におけるノイズ空間固有値の絶対値をメモリ空間の最大固有値に比べて十分大きくすることで、連想性能が向上することを示した。さらに、これが主にノイズ空間ダイナミクスの寄与によるものであることを明らかにした。

ノイズ空間固有値の絶対値が小さくなれば、CCHN-L1はHN-CORに近づくことになる。つまり、この固有値の大きさがCCHN-L1の記憶容量に大きな影響を与えることは容易に想像される。本論文では、ノイズ空間固有値の絶対値が十分大きい場合における動的特性の考察にとどまったが、今後、統計的手法などを用いて厳密な記憶容量や動的特性の考察を行っていく必要がある。また、モジュール数が増加したときのCCHNの動特性の変化は、モジュール構造ニューラルネットモデルの観点から非常に興味深い課題であると思われる。これらは今後の課題としたい。

(平成8年6月10日受付、同8年11月22日再受付)

文 献

- (1) K.Tsutsumi: "Cross-Coupled Hopfield Nets via generalized-delta-rule-based internetworks", Proc. of International Joint Conference on Neural Networks '90 San Diego, II, pp.259-265 (1990)
- (2) 小澤・堤:「モジュール化ニューラルネットモデルの提案とその連想記憶能力の評価」, 電子情報通信学会論文誌D-II, Vol.J77-D-II, No.6, pp.1135-1145 (1994)
- (3) J.J.Hopfield: "Neural networks and physical systems with emergent collective computational abilities", Proc. Natl. Sci. USA, Vol. 79, pp.2254-2258 (1982)

- (4) S.Ozawa, K.Tsutsumi and N.Baba: "A modular neural network with local and global interactions", Proc. of World Congress on Neural Network 95 Washington DC, Vol.I, pp.471-476 (1995)
- (5) D.J.Amit, H.Gutfreund, and H.Sompolinsky: "Storing infinite numbers of patterns in a spin-glass model of neural networks", Phys. Rev. Lett. Vol.55, pp.1530-1533 (1985)
- (6) R.J.McEliece et al: "The capacity of the Hopfield associative memory", IEEE Trans. On Information Theory, Vol.33, pp.461-482 (1987)
- (7) S.Amari and K.Maginu: "Statistical neurodynamics of associative memory", Neural Networks, Vol.1, pp.63-73 (1988)
- (8) M.Shiino and T.Fukui: "Self-consistent signal-to-noise analysis and its application to analogue neural network with asymmetric connections", J. Phys. A: Math. Gen., Vol.25, pp.L375-L381 (1992)
- (9) S.V.B.Aiyer, M.Niranjan, and F.Fallside: "A theoretical investigation into the performance of the Hopfield model", IEEE Trans. on Neural Networks, Vol.1, pp.204-215 (1990)
- (10) 金道:「連想記憶のダイナミクスの幾何的解析」, 電子情報通信学会論文誌D-II, Vol.J78-D-II, No.12, pp.1877-1889 (1995)
- (11) T.Kohonen: "Self-organization and associative memory", 3rd. ed., Springer-Verlag (1989)

小澤 誠 (非会員) 昭和40年1月8日生。平成元年神戸大学大学院工学研究科計測工学専攻修士課程修了。同年奈良工業高等専門学校情報工学科助手、平成5年より大阪教育大学教育学部教養学科情報科学専攻助手となり、現在に至る。主として、人工神経回路網、遺伝的アルゴリズム、さらにそれらの融合モデルなどの研究に従事。電子情報通信学会、システム制御情報学会、日本神経回路学会会員。

堤 一 義 (非会員) 昭和29年7月22日生。昭和60年神戸大学大学院自然科学研究科システム科学専攻博士課程修了。学術博士。同大学院文部教官助手を経て、平成2年より龍谷大学理工学部講師。平成5年より同助教授となり、現在に至る。その間平成6年10月より平成7年9月まで米国メリーランド大学客員助教授。主として、人工神経ネットワーク、知能ロボットなど、脳の情報処理機能の解明とその応用に関する研究に従事。電子情報通信学会、システム制御情報学会、日本神経回路学会、IEEE、INNS 会員。

馬場 則 夫 (非会員) 1974年、京都大学大学院博士課程修了。同年徳島大学工学部情報工学科助手、75年同講師、81年同助教授、88年知能情報工学科教授、90年大阪教育大学教育学部教授、現在に至る。この間約2年間、フランスINRIA研究所及びオーストリアIIASA研究所客員研究員。学習オートマトン、ゲーミング、数理計画法、環境工学、ロボット工学、ニューラルネット等の研究に従事。

工学博士。著書: New Topics in Learning Automata Theory and Applications (Springer-Verlag), ニューラルネットの基礎と応用(共立出版), PC-9801パソコンゲーミング手法(日刊工業新聞), 数理計画法入門(共立出版)。IEEE, 計測自動制御学会, システム制御情報学会, 日本ロボット学会, 日本オペレーションズ・リサーチ学会会員。