非単調活性化関数を用いたカオスニューラルネットワークと メモリサーチシステムへの適用

学生員 伊藤 一成* 非会員 高倉 康弘*
正員 斎藤 博昭*

Chaotic Neural Networks with Non-monotonic Functions and its Adaptation to Memory Search Systems

Kazunari Ito*, Student Member, Yasuhiro Takakura*, Non-member, Hiroaki Saito*, Member

In past studies, neurons in chaotic neural networks have sigmoid function as an activated function. This paper proposes a new chaotic neural networks using a non-monotonic activated function. This network generate chaotic dynamics by transforming a shape of the function. We apply this network to the memory search systems. In that case, we introduce an original control term to the networks. It leads neurons to give stronger signal outputs with characteristic condition agreements, and weaker signal for disagreements. Adding constraints to the state transitions of the network, the output of network becomes more changeable to the state where the condition is satisfied. Due to its effect, recalling on a target pattern in fewer steps is achieved on average. Performance of the memory search system has been also greatly improved with the number of memory patterns where the conventional methods with sigmoid functions hardly recalled. Furthermore, our memory search system shows a great improvement in the case that each stored pattern has high degree of correlation.

キーワード：カオスニューラルネットワーク，活性化関数，メモリサーチシステム

Keywords: chaotic neural networks, activated function, memory search systems

1. はじめに

生体の脳や神経回路網にカオスの存在が示唆されるデータが発表され⁽¹⁾，人間の脳が持つ高度な情報処理機能に，カオスが重要な役割をはたしているのではないかと，盛んに研究されている⁽²⁾。合原らは，ニューロン単体に対してもカオス現象が観測されることを，ヤリイカ巨大軸索を用いた電気生理実験によって明らかにし⁽³⁾，カオスのダイナミクスを有するカオスニューロンとしてモデル化した。カオスニューロンは，従来のニューロンモデルに，実際の神経細胞に見られる時空間加算・不応性・連続値出力を取り入れたモデルである。さらにカオスニューロンを構成素子とする相互結合型ネットワークであるカオスニューラルネットワークを提案した⁽⁴⁾。ダイナミクスの解析は数多く行わ

れており，カオスニューラルネットワークが豊富なダイナミクスを有することが示されている。

カオスニューラルネットワークを用いた自己想起型連想記憶モデルの特徴の一つとして，ネットワークに記憶された複数のパターンを動的に想起可能なことが知られている。これは従来の Hopfield の自己想起型連想記憶モデル⁽⁵⁾にはない特徴である。その仕組みは，カオスニューロンの不応性の影響により，局所安定点から状態を突発的に変化させることで実現される。その特徴を利用した応用事例として，記憶の検索を行うメモリサーチシステムが提案されている^{(6)~(9)}。

ところで，合原らのカオスニューラルネットワークは，活性化関数として単調なシグモイド関数を用いている。静的な自己想起型連想記憶モデルにおいては，活性化関数としてシグモイド関数ではなく非単調な活性化関数を用いることで，記憶容量が大きくなることが知られている^{(10)~(11)}。具体的には，ニューロン数を N とするとシグモイド関数による連想記憶モデルでは最大記憶容量が約 $0.15N$ なのに対し，森田らは非単調な活性化関数を用いることにより最大約 $0.4N$ 程度までの向上を実現した⁽¹⁰⁾。そこで，本稿

* 慶應義塾大学大学院理工学研究科
〒 223-8522 神奈川県横浜市港北区日吉 3-14-1
Department of Information and Computer Science, Keio University
Hiyoshi 3-14-1, Kouhoku-ku, Yokohama, Kanagawa, 223-8522 Japan

では非単調な活性化関数を用い、さらにそれを動的に変化させることによってカオスのダイナミクスを導入した新しいカオスニューラルネットワークを提案する。また、そのネットワークをメモリサーチシステムに応用し、記憶容量や検索成功率の向上が実現できることを示す。

2. 非単調活性化関数を用いたカオスニューラルネットワーク

本章では、提案するカオスニューラルネットワークのモデル式を示す。 i 番目のニューロンの出力は次式で定義する。

$$x_i(t+1) = f(u_i, a_i(t)) \dots \dots \dots (1)$$

ここで、 $x(t+1)$ は離散時間 $t+1$ におけるニューロンの出力、 f は非単調な活性化関数であり、次式で表される。

$$f(y, a_i(t)) = \begin{cases} y \exp[-\varepsilon(y^2 - 1)/2] & \text{if } a_i(t) = 0 \\ \frac{1 - \exp[-cy]}{1 + \exp[-cy]} \frac{1 - \exp[c'y] - (\alpha + a_i(t)*\beta)}{1 + \exp[c'y] - (\alpha + a_i(t)*\beta)} & \text{otherwise} \end{cases} \dots \dots \dots (2)$$

式 (2) において、 ε, c, c' は正の定数、 α, β はパラメータを示す。また、 $a_i(t)$ は活性化関数の形状を変化させるためのパラメータであり、次式で定義する。

$$a_i(t) = \begin{cases} 0 & \text{if } (a_i(t-1) = 0) \cap (|u_i| \leq b) \\ \gamma & \text{if } (a_i(t-1) = 0) \cap (|u_i| > b) \\ a_i(t-1) - 1 & \text{otherwise.} \end{cases} \dots \dots \dots (3)$$

ここで b, γ はパラメータである。式 (1) の u_i はニューロンの内部状態であり、次式で定義する。

$$u_i = \sum_{j=1}^N w_{ij} x_j(t) \dots \dots \dots (4)$$

式 (4) において、 N はニューロンの総数、 w_{ij} は j 番目のニューロンから i 番目のニューロンへのシナプス結合の強さで、次式により決定される。

$$w_{ij} = \frac{1}{N} \sum_{k=1}^M p_i^k p_j^k \dots \dots \dots (5)$$

式 (5) 中の $p^1, \dots, p^M$ は記憶するパターンベクトルで、全ての要素は 1 または -1 をとる。

本手法では活性化関数について、 $a_i(t) = 0$ の場合は想起能力の点から最適な形状を求めた Crespi の方式を採用した⁽¹¹⁾。一方、 $a_i(t) \neq 0$ の場合は、Morita の非単調活性化関数⁽¹⁰⁾を基に、従来は固定値であったパラメータの一部を、 $a_i(t)$ の値に応じて変動させるようにした。その際、カオスダイナミクスの発生には u_i が収束しにくくなるようにすることが必要で、そのように $a_i(t)$ を定めた。

これにより、提案するネットワークはカオスの動作になり、学習した複数のパターンの動的想起が可能になった。

図 1 活性化関数の変化

Fig. 1. Change of our activated function.

図 2 提案するネットワークの状態遷移の例

Fig. 2. An example of the associative process in the proposed networks.

$\alpha = 0.6, \beta = 0.5, \gamma = 4$ としたときの活性化関数の形状の変化の例を図 1 に示す。このように、活性化関数は通常は $a(t) = 0$ の形状となるが、内部状態 u が閾値 b よりも大きくなった場合に $a(t) = 4$ となり、図 1 に示すような形状に変化する。その後は 1 ステップ毎に $a(t)$ が減るため、

図3 最大リアプノフ指数

Fig. 3. Maximum lyapunov exponent.

$a(t) = 3, a(t) = 2, a(t) = 1$ の場合の形状へと変化する, $a(t) = 0$ となった場合に元の形状に戻る。

提案手法によるネットワークでの動的連想記憶の例を図2に示す。ここで、図2の最上段に示す4種類のパターン (Pattern0~3) が記憶パターンである。また、Whiteは-1, Blackは1の値を表している。つまり各記憶パターンは-1か1の値を要素に持つベクトル表現である。また、 t はステップ数を表す。この図2の状態遷移図から分かるとおり、ネットワークに記憶したパターン、もしくは反転パターンを非周期的に想起していく。つまり、提案するネットワークは学習した複数のパターンの動的想起が可能である。また、全ての i について $a_i(t) = 0$ と固定すると、このネットワークは静的な連想記憶モデルとして機能する。

さらに、本ネットワークのカオス性の判定のために、佐野と沢田による計算方法⁽¹²⁾によって、ニューロンの出力列についてリアプノフスペクトルを求めた。提案手法のモデル式で、 $\alpha = 0.6, \beta = 0.5, \gamma = 4.0$ に固定し、 b だけを1.0から2.0まで変化させた場合の最大リアプノフ指数を図3に示す。図3からわかるように、 b の値が変化しても最大リアプノフ指数は常に正となっている。このことから提案するネットワークは、カオスの大きな特徴の一つである軌道不安定性を有しているといえる。

3. 提案手法のメモリサーチシステムへの応用

本章では、提案するネットワークをメモリサーチシステムへ応用する際に加える制御について説明する。

3.1 メモリサーチシステム ニューラルネットワークによるメモリサーチシステムとは、検索者が検索したい対象の特徴を特徴条件 (characteristic condition) として与え、ネットワークの出力をその特徴情報を満たすパターンに収束させ、検索者に対して提示するシステムのことをいう (図4参照)⁽¹³⁾。現在のネットワークの出力から抽出した特徴 (characteristic extract) と特徴条件の相違度を基にネットワークに対し何らかの制御を行うことにより、特徴条件を満たすパターンを想起させる。出口からはニューロン間の結合重みを相対的に変化させることによって、合原

図4 メモリサーチシステム

Fig. 4. Memory search systems.

らのシグモイド関数を用いたカオスニューラルネットワークの状態を制御し、メモリサーチを実現している⁽⁹⁾。

3.2 制御の仕組み 連想記憶モデルにおいて、カオスニューラルネットワークがサンプリングしている空間には偏りができることが知られている⁽⁹⁾⁽¹⁴⁾。そのため条件次第では検索失敗、あるいは検索成功までに非常に多くのステップ数を必要とする場合が生ずる。このような問題に対して、我々は以前にシグモイド関数を用いたカオスニューラルネットワークにおいて、特徴条件の情報を外部入力として入力することで特徴条件を満たす解空間を優先的に探索するような制御項を提案した。それによって、従来手法よりも検索成功率を向上させられることを発見した⁽¹⁵⁾。本稿でもこの手法を基にして、以下に示す制御項を提案する。

具体的に i 番目のニューロンの出力は、式(1)に制御項 F を加えた次式によって定義する。

$$x_i(t+1) = f(u_i + F_i(t), a_i(t)) \dots \dots \dots (6)$$

式(6)において、制御項 $F_i(t)$ は次のとおりである。

$$F_i(t) = \begin{cases} -q_i d & \text{if } (|u_i| > \zeta) \cap (|u_i - q_i d| \geq \zeta) \\ -u_i + q_i \zeta & \text{if } (|u_i| > \zeta) \cap (|u_i - q_i d| < \zeta) \\ -u_i + q_i \zeta & \text{if } (|u_i| \leq \zeta) \cap (|u_i + q_i d| > \zeta) \\ q_i d & \text{if } (|u_i| \leq \zeta) \cap (|u_i + q_i d| \leq \zeta) \end{cases} \dots \dots \dots (7)$$

ここで d は正のパラメータ、 q は与えられた特徴条件を表すベクトルで、条件を設定するニューロンに対応する要素は1, -1をとり、設定しない場合は0をとる。 ζ は $a(t)$ の値によって以下のように変化する。

$$\zeta = \begin{cases} f_{max} & \text{if } a_i(t) = 0 \\ \gamma + a_i(t) - d & \text{otherwise} \end{cases} \dots \dots \dots (8)$$

f_{max} は $f(y) = y \exp[-\varepsilon(y^2 - 1)/2]$ の最大値を示している。

この制御項 F は、ニューロンの出力が特徴条件と一致する場合はその出力をより強く、特徴条件と異なる場合は出力を弱くするような制御を加える。これによって、特徴条件を満たす解空間を優先的に探索させ、より少ないステップ数で目的のパターンを想起できると考える。この制御項を導入することにより、従来手法より高い性能を有するメモリサーチシステムの実現を試みる。

図 5 パターン 3 をサーチする過程の例

Fig. 5. An example of search process for Pattern3.

3.3 カオス制御 提案するネットワークはカオスのダイナミクスを有するので、1 ステップ毎に状態が非周期的に変化してしまう。そのため、目的のパターンを想起させるために、このカオスのダイナミクスを制御しなければならない。

ここで、特徴ベクトル q と出力の相関度 $\mu(t)$ を次のように定義する。

$$\mu(t) = \frac{x(t) \cdot q}{|q|} \dots \dots \dots (9)$$

この相関度 $\mu(t)$ がある閾値以上になり、目的のパターン近くに達したとみなせるとき、以後 $\mu(t)$ がその閾値以上の間は全ての i に対して $a_i(t) = 0$ とし、ネットワークがカオスの動作ではなく、静的連想記憶モデルの動作になるように制御する。この制御により、突発的な状態変化をなくし、速やかに目的のパターンを想起させるようにする。

図 5 は、最上段 (Pattern0 ~ 3) に示した 4 つのパターンを記憶させ、特徴条件として右上 (Input) に示されているパターン 3 の 5% が設定された場合のメモリサーチの例

表 1 実験 1 における提案するネットワークのパラメータ

Table 1. Parameters of proposed network in Experiment 1.

The number of patterns	b	α	β	γ
5 patterns	1.5	0.1	0.5	4.0
10 patterns	1.6	0.6	0.5	4.0
15 patterns	1.5	0.2	0.5	4.0
20 patterns	1.4	0.8	0.5	4.0
25 patterns	1.6	1.0	0.5	4.0

図 6 記憶パターンの例

Fig. 6. Stored patterns.

である。ここで、Input の White と Black 以外の要素は全て 0 としている。ネットワークの状態が非周期的に変化することで、記憶パターンを検索し、44 ステップで目的のパターン 3 をサーチしているのが見て取れる。

4. 実験

本章では、計算機シミュレーション実験の結果を基に、本手法の性能評価及び他の手法との性能比較を行う。

4.1 実験 1 何種類かのランダムパターンを記憶させたネットワークを用い、いずれかのパターンを想起させる実験を次の 4 種類の手法について行った。

- (1) 提案手法
- (2) 出口らの手法
- (3) 非単調な活性化関数を用いた静的な連想記憶
- (4) 単調な活性化関数を用いた静的な連想記憶

記憶パターンについては、記憶パターン間の相関度 s_{ij} を

$$s_{ij} = \frac{p^i \cdot p^j}{N} \dots \dots \dots (10)$$

と定義したとき、全てのパターンの組 i, j に対して、 $s_{ij} \leq 0.24$ となるように定めた。ここで、 N はユニット数、 p^i 、 p^j はそれぞれ i 番目と j 番目の記憶パターンである。

この規則により定めた記憶パターン群の例を図 6 に示す。特徴条件はある特定の記憶パターンの一部とし、その比率を変えて複数の実験を行った。ただし特徴条件は、それを満たす記憶パターンが 1 種類のみになるように定めた。ネットワークのユニット数は 100、初期状態は提案手法と出口の手法はランダム、その他については特徴条件そのものとする。

図 7 記憶パターン 5 個の場合の実験結果

Fig.7. Simulation results in the case of 5 memorized patterns.

図 8 記憶パターン 10 個の場合の実験結果

Fig.8. Simulation results in the case of 10 memorized patterns.

求めるパターンを 200 ステップ以内に想起できた場合、検索成功とする。記憶パターン群と特徴条件を変えて、1000 回の試行を行い、検索成功率を求めた。各手法のパラメータは、予備実験から経験的に求めた。提案手法については、活性化関数における定数 $\varepsilon = 3.2$, $c = 50.0$, $c' = 15.0$, 制御項 F のパラメータ $d = 0.2$ とした。ネットワークのパラメータについては表 1 のように定めた。カオス制御は、 $\mu(t) \geq 0.8$ の場合に静的連想記憶モデルの動作になるように制御した。

5 種類及び 10 種類のパターンを記憶させた場合の実験結果を図 7, 図 8 に示す。グラフの横軸は与えた特徴の比率、縦軸は検索成功率である。記憶パターン数が比較的小さい場合には、従来手法でもそれなりの成功率を達成できるが、提案手法はそれを上回る成功率であり、最大で約 26% の向上が見られた。次に、15 種類のパターンを記憶させた場合の実験結果を図 9 に示す。記憶パターン数が 15 種類の場合、従来手法では記憶容量の限界付近となるため、検索成功率の低下が顕著に見られる。さらに、20 種類のパターンを記憶させた場合の実験結果を図 10 に示す。ただし、提案手法について性能比較のために、成功条件のステップ数を 200 ステップから 1000 ステップに変更した場合につい

図 9 記憶パターン 15 個の場合の実験結果

Fig.9. Simulation results in the case of 15 memorized patterns.

図 10 記憶パターン 20 個の場合の実験結果

Fig.10. Simulation results in the case of 20 memorized patterns.

ても実験を行った。図 10 が示すように、従来の手法ではほぼ想起不可能な記憶パターン数においても、特徴条件の比率に関わらず 2 倍以上の検索成功率が本手法では得られた。また、制御項 F によって特徴条件を満たす解空間を優先的に探索できていることが、非単調な活性化関数を用いた連想記憶モデルの結果 (図 10 の $\times$) との比較からわかる。さらに、サーチ許容ステップ数を 1000 ステップにして、実験を行った場合に、最大で 15% 以上検索成功率が向上した (図 10 の $+$)。これはカオスニューラルネットワークが有するカオスの影響によるものである。

以上において、出口の手法の結果が他の手法に比べ全体を通じて悪いのは、以下の 2 つの要因によると考えられる。第 1 に、出口の手法では、特徴条件は相関度の算出だけに用いており、ネットワークの状態遷移はカオスニューラルネットワークの挙動だけに依存している。よって、目的のパターンにほぼ一致する出力状態になる必要があるが、本手法のような特徴条件に基づいた制御をおこなっていないので、有限回のステップではそれに至らないケースが多く存在する。第 2 に、活性化関数として単調なシグモイド関数を用いていることである。これは、特に図 9 及び図 10 において、非単調活性化関数を用いている 2 手法と単調な活

図 11 記憶パターン 25 個の場合の実験結果

Fig. 11. Simulation results in the case of 25 memorized patterns.

表 2 実験 2 における提案するネットワークのパラメータ

Table 2. Parameters of proposed networks in Experiment 2.

correlation	b	α	β	γ
0.32	1.5	0.1	0.5	4.0
0.4	1.6	0.6	0.5	4.0

図 12 相関度が 0.32 の場合における実験結果

Fig. 12. Simulation results when correlation is 0.32.

活性化関数を用いている 2 手法とのサーチ成功率の大幅な差異から明らかである。

結果の比較から、本稿において独自に提案したカオスニューラルネットワークが有するカオスの影響と、制御項 F が検索性能に大きく起因していることがわかる。

最後に、25 種類のパターンを記憶させた場合の実験結果を図 11 に示す。記憶パターンが 25 種類になると検索成功率の低下が顕著になり、検索成功率 90% 以上を得るためには、特徴条件が 50% 以上必要となる。これは、非単調な活性化関数を用いた静的連想記憶モデルの最大記憶容量に近くなってきたことが大きな原因と考えられる。しかし、従来手法と比べると、大幅な検索成功率の向上が得られている。

4.2 実験 2 次に、相互に相関の高い 4 種類のパターンを記憶させたネットワークを用い、いずれかのパ

図 13 相関度が 0.4 の場合における実験結果

Fig. 13. Simulation results when correlation is 0.4.

ターンを想起させる実験を行った。ネットワークに記憶させるパターンは Morita⁽¹⁰⁾ が用いた方法で生成する。これにより相互に一定の相関を持つランダムパターンが生成できる。実験の条件は実験 1 と同様である。そして実験 1 と同様に 4 種類の手法について実験を行った。各手法のパラメータ設定は、予備実験から経験的に求めた。提案手法については、活性化関数における定数を $\varepsilon = 3.2$, $c = 50.0$, $c' = 15.0$ に、制御項 F のパラメータを $d = 0.1$ に設定した。また提案するカオスニューラルネットワークのパラメータについては表 2 のように定めた。カオス制御については、 $\mu(t) \geq 0.8$ の場合に静的連想記憶モデルの動作になるように制御した。相互の相関度が 0.32 の場合の実験結果を図 12 に示す。グラフの横軸は与えた特徴の比率、縦軸は検索成功率である。従来手法では検索成功率が最大でも 50% に達しないが、本手法では特徴条件の比率に関わらず、従来手法に比べて 2 倍以上の検索成功率が得られた。さらに、相互の相関度が 0.4 の場合の実験結果を図 13 に示す。従来手法で検索成功率が著しく低下している原因は、連想記憶モデルでは記憶パターン間の相関度が高い場合、記憶パターン以外の安定状態が多数存在するからである。本手法が従来手法と比べて検索成功率が高いのは、そのような記憶パターン以外の安定状態から状態を突発的に変化させるカオスニューラルネットワークのカオスの影響が大きく起因していることがわかる。出口の手法でも、記憶パターン間の相関度が 0.4 の場合において、静的な連想記憶モデルの検索成功率よりも向上している部分が多いことからカオスによる影響が起因していることがわかる。また、記憶パターン数が多い場合と同様に、静的な連想記憶の実験結果との比較により、本手法ではカオスニューラルネットワークが有するカオスの影響と、本手法の制御項 F が検索性能に大きく起因していることがわかる。

5. 結 論

非単調な活性化関数を用いたニューラルネットワークにおいて活性化関数を動的に変化させることによって、カオスのダイナミクスを導入したモデルを提案した。また、そ

のモデルをメモリサーチシステムに応用した。本手法では次の点が特徴として挙げられる。

- 従来の手法ではほとんど想起できないような記憶パターン数でも、動的想起が可能である
- 制御項を導入することより特徴条件を満たす解空間を優先的に探索するメモリサーチシステムを構築することが可能である

計算機シミュレーション実験の結果より、記憶パターン数が多い場合、従来手法ではほとんど検索できなかったが、本手法では大幅な検索成功率の向上が果たせることを示した。さらに、従来手法では検索成功率が大幅に低下するような、相互の相関が高い記憶パターンの場合でも、大幅な検索成功率の向上を果たした。

今後の課題として、特徴条件を与えるニューロンの比率が低い場合や、記憶パターン間の相関度が高い場合でも検索成功率の低下を極力抑えることができる制御項の考案が望まれる。

(平成 15 年 5 月 26 日受付, 平成 15 年 9 月 29 日再受付)

文 献

- (1) W.J. Freeman: "Strange attractors that govern mammalian brain dynamics shown by trajectories of electroencephalographic (EEG) potential", *IEEE Trans. Circuit & Syst.*, CAS-35, Vol.7, pp.781-783 (1988)
- (2) A. Babloyants and J.M. Salazar: "Evidence of chaotic dynamics of brain activity during the sleep cycle", *Physics Letters A*, Vol.111, pp.152-156 (1985)
- (3) K. Aihara, G. Matsumoto, and M. Ichikawa: "An alternating periodic-chaotic sequence observed in neural oscillations", *Physics Letters A*, Vol.111, No.5, pp.251-255 (1990)
- (4) K. Aihara, T. Takabe, and M. Toyoda: "Chaotic neural networks", *Physical Letters A*, Vol.144, pp.333-340 (1990)
- (5) J.J. Hopfield: "Neural networks and physical systems with emergent collective computational abilities", *Proc. of the National Academy of Sciences of the United States of America*, Vol.79, pp.2554-2558 (1982)
- (6) S. Nara, P. Davis, and H. Totsuji: "Memory Search Using Complex Dynamics in a Recurrent Neural Network Model", *Neural Networks*, Vol.6, pp.963-973 (1993)
- (7) I. Tsuda, E. Koerner, and H. Shimizu: "Memory Dynamics in Asynchronous Neural Networks", *Progress of Theoretical Physics*, Vol.78, No.1, pp.51-71 (1987)
- (8) M. Kushibe, Y. Liu, and J. Ohtsubo: "Associative memory with spatiotemporal chaos control", *Physical Review E*, Vol.53, No.5, pp.4502-4508 (1996)
- (9) T. Deguchi and N. Ishii: "Search of Cyclic Patterns of Chaotic Neural Network", *IEICE Japan*, Vol.J81-D-II, No.4, pp.752-758 (1998-4) (in Japanese)

出口利憲・石井直宏:「カオスニューラルネットワークによる周期パターンの検索」, 信学論誌, J81-D-II, 4, pp.752-758 (1998-4)

- (10) M. Morita: "Associative Memory With Nonmonotone Dynamics", *Neural Networks*, 6(1), pp.115-126 (1993)
- (11) B. Crespi: "Storage capacity of non-monotonic neurons", *Neural Networks*, Vol.12, No.10, pp.1377-1389 (1999)
- (12) M. Sano and Y. Sawada: "Measurement of the Lyapunov Spectrum from a Chaotic Time Series", *Physical Review Letters*, Vol.55, pp.1082-1085 (1985)
- (13) 奈良重俊・ピーター デイビス:「カオスと記憶」, 数理科学, 373 pp.27-34 (1994)
- (14) L. Chen and K. Aihara: "Globally Searching Ability of Chaotic Neural Networks", *IEEE Transact. Circuit and Systems*, Vol.46, No.8, pp.974-993 (1999)
- (15) K. Ito, S. Kikuchi, and M. Nakanashi: "Memory search system using chaotic neural networks", *Proc. of IASTED International Conference on Modelling, Identification and Control*, pp.455-459 (2001)

伊 藤 一 成 (学 生 員) 1974 年 7 月 18 日 生。1999 年 3 月 慶

應義塾大学理工学部数理科学科卒業。2001 年 3 月慶應義塾大学大学院理工学研究科計算機科学専攻前期博士課程修了。現在、慶應義塾大学大学院理工学研究科開放環境科学専攻後期博士課程在学中。ニューラルネットワーク及びマルチメディア情報処理に関する研究に従事。情報処理学会、電子情報通信学会、各学生会員

高 倉 康 弘 (非 会 員) 1975 年 9 月 17 日 生。1998 年 3 月 慶

應義塾大学理工学部数理科学科卒業。2003 年 3 月慶應義塾大学大学院理工学研究科開放環境科学専攻前期博士課程修了。現在、神奈川県川崎市カリタス女子中学高等学校教員。ニューラルネットワークの基礎理論に興味を持つ。

斎 藤 博 昭 (正 員) 慶應義塾大学工学部数理工学科卒業。現

在、同大理工学部情報工学科専任講師。工学博士。ニューラルネットワーク、自然言語処理、音声言語理解などに興味を持つ。情報処理学会、言語処理学会、日本音響学会、電子情報通信学会、ACL 各会員。