

短期記憶を用いたシンプルリカレントネットワークによる カオス時系列の短期予測

菊地進一[†] 中西正和[†]

決定論的カオスの短期予測という概念は、実世界の時系列データに対する工学的なアプローチの幅を広げた。そのような時系列の非線形予測手法の1つとして Elman のリカレントニューラルネットワークがある。筆者らは、この構造の入力に過去の履歴を直接与えることで、学習が高速化されることを確認している。ただし、これまでは周期的なデータに対する適用であったため、過去の履歴が重要であった。本研究は、カオス的なデータに対しても、提案手法が有効であることを示すものである。学習アルゴリズムにはクロスエントロピー法を用いる。本論文では、カオス時系列の例として、Hénon 写像、Lorenz 方程式、はしかの患者数、母音のゆらぎの4つを扱う。これらの実験により、従来の Elman の手法と比較して、予測誤差（テストデータに対する出力自乗誤差）を変化させずに、学習が数倍から100倍程度まで高速化された。さらに、数ステップ先の予測においては、バッファの効果により、予測精度が向上することが確認された。

Short-term Forecasting of Chaotic Time Series by Simple Recurrent Network with Short-term Memory

SHINICHI KIKUCHI[†] and MASAKAZU NAKANISHI[†]

The concept of short-term forecasting of deterministic chaos makes an impact on the engineering science for real-world time series. Elman's recurrent neural network is such a nonlinear forecasting method. Recently, we have proposed a structure which uses directly past histories in Elman's network. It is shown that learning is accelerated using the structure. Data in the previous work is periodic, so past histories are important for learning time series. In this work, it is shown that the structure is also useful for chaotic data. Moreover, we employ the cross entropy method for fast learning. In this paper, Hénon map, Lorenz equation, the number of measles and fluctuation of Japanese vowel are treated as examples of chaotic time series. Using our method, it is shown that learning speed attains about 100 times faster without making generalization error worse compared with Elman's method. Moreover, generalization ability of multi-step forecasting is improved by introducing the buffer.

1. はじめに

決定論的カオス時系列の短期予測という概念は、複雑な様相を呈する実世界の時系列に対しても、工学的アプローチが有効であるという新たなカオス工学の分野を開いた。

歴史的には、これらの時系列には統計的手法である ARMA モデル¹⁾などが用いられ、複雑な要素は確率的なノイズが重畳されているものであるとされてきた。ところが、近年、決定論的カオスを意識した、より精度の高い非線形予測手法が提案されるようになってきた。

カオス時系列の短期予測の手法としては、局所的に多項式をあてはめる方法²⁾、動径基底関数 (RBF) を用いる方法³⁾、シンプレクス投影法⁴⁾、テセレーション法⁵⁾、ウェーブレットを用いる方法⁶⁾、KM₂O-Lagevin 方程式を用いる方法⁷⁾、ARMA モデルを非線形に拡張した NARMAX モデルによる方法⁸⁾、改良 Lorenz 法⁹⁾、ニューラルネットワークを用いる方法^{10)~19)} など種々の方法が提案されている。

局所近似法²⁾は、アトラクタ上のある点の将来の値をその近傍点の推移をもとに近似するため、近傍点の数が少ないと精度が低下する。そのために、データの点数を多く必要とするという欠点がある。Sugihara ら⁴⁾は、実世界のデータを扱う際には、限られたデータ数しか得られない場合があることを主張し、実問題であるはしかの患者数予測において、267点という少

[†] 慶應義塾大学大学院理工学研究科開放環境科学専攻
Department of Science for Open and Environmental
Systems, Keio University

ないデータ数から時系列予測を行っている。また、カオス時系列の長期予測不可能性を利用して、非線形予測手法により、ホワイトノイズと決定論的カオスとを区別できることを示している⁴⁾。さらに最近、近傍点の数にロバストな局所近似法の予測精度向上法も提案されている²⁰⁾。また、ウェーブレットを用いた手法⁶⁾は、比較的長期予測に強いという特長がある²¹⁾。

中でも、ニューラルネットワークは、最もよく研究されている分野の1つであり²²⁾、任意の写像を近似できることが保証されている^{23),24)}のために、そこで得られた新たな見解がカオス時系列に対してどのように働くのかを調べるのは非常に重要なことである。

しかし、従来のニューラルネットワークを用いた時系列の研究ではカオス時系列を意識した研究というものは少なかった。また、カオス工学の研究でも、ニューラルネットワークの研究で得られた最新の知見を応用していこうとするものが少なかった。実際、そのほとんどが時間的なパターンを空間的なパターンに変換して問題を解くバッファモデルやTDNNを用いた手法である^{10)~17)}。バッファモデルは入力履歴の保持に制限があり、与えられた視野の外はまったく考慮していないことから、時系列予測のモデルとしては不十分であるという指摘がなされている²⁵⁾。

ただし、カオス時系列の学習においては、バッファモデルを利用する理由もある。観測された時系列から時間遅れ座標系を用いると、元の力学系のアトラクタを再構成することができるという埋め込みの定理^{26),27)}がある。適切な長さのバッファを用いた場合、バッファモデルではこの埋め込みの定理が成立すると考えられる^{11),16)}。このため、古典的なバッファモデルが多用されてきたのではないかと考えられる。

そこで、本研究では、最近、筆者らの提案したりカレントニューラルネットワークである短期記憶を用いたシンプルリカレントネットワーク(Simple Recurrent Network with Short-term Memory, SRNSM)^{28),29)}の適用を試みる。これまでの研究^{28),29)}では、周期的なデータに対する適用であったため、確かに過去の入力が重要であった。しかし、データの特長性を利用した手法ではないため、データの周期性には依存しないと考えられる。そこで、本研究では、カオス時系列の学習に対しても提案手法が有効な手法であることを示す。すなわち、本研究の目的は従来法のカオス時系列に対する効果的な適用にある。

SRNSMはElmanのネットワーク³⁰⁾の入力に、数時刻分の過去の履歴を直接与えるネットワークである。このネットワークを用いることにより、予測誤差(テ

ストデータに対する出力自乗誤差)を変化させずに、Elmanの手法と比較して、学習時間が短くなる、収束率が向上するなどの有効性が示されている^{28),29)}。ここで、Elmanのネットワークは、その構造と学習アルゴリズムが簡単であるうえに、学習能力が比較的高いことから、言語学習³⁰⁾、オートマトンの学習³¹⁾、音声認識³²⁾、メロディーの認識³³⁾など、いろいろな分野に応用されている手法である。また、有限状態機械と等価な計算能力を持つということも示されている³⁴⁾。SRNSMはこれらの利点を保存したまま、学習速度や収束率を上げる手法である。Elmanのネットワークと違い、SRNSMにはバッファが存在するために、埋め込みの定理が直接的に成立すると考えられる。また、SRNSMはcontext層を持っているので、文脈情報の保持能力があり、バッファモデルでは学習できないような短いバッファでも学習が可能である。この点において、SRNSMはバッファモデルとは異なる。

SRNSMでは学習アルゴリズムとして、従来の誤差逆伝搬学習ではなく、誤差逆伝搬学習の高速化手法の1つであるクロスエントロピー法^{35),36)}を用いる。クロスエントロピー法は、従来、静的な問題に適用されていた手法であり、時系列の学習の問題において、あまり用いられてこなかった。本研究では、SRNSMに対しても、クロスエントロピー法を用いることができる点に注目し、学習アルゴリズムとして採用する。

カオス時系列の学習に際し、これらを用いると、Elmanの手法と比較して、予測誤差を変化させずに、学習速度を数倍から100倍程度まで高速化することが可能であることを示す。さらに数ステップ先の予測では、バッファの導入により、予測精度が向上することを示す。本論文では、カオス時系列の例として、Hénon写像、Lorenz方程式、はしかの患者数、母音のゆらぎの問題を取り扱っている。

以下、本論文では、2章で本研究において用いる構造であるSRNSM、3章で本研究において用いる学習アルゴリズムであるクロスエントロピー法について概説し、4章から7章で計算機シミュレーションにより本手法の有効性を示し、8章で考察を行い、9章でまとめを述べる。

2. 短期記憶を用いたシンプルリカレントネットワーク

Elmanの手法では、学習時間が比較的に長く、収束率も十分なわけではない。そこで、筆者らは、入力にバッファを持たせた図1のような短期記憶を用いたシンプルリカレントネットワーク(Simple Recurrent




図1 短期記憶を用いたシンプルリカレントネットワーク
Fig.1 Simple Recurrent Network with Short-term Memory (SRNSM).

Network with Short-term Memory, SRNSM) を提案した^{28),29)}。この構造により、時間的に近いデータに対する学習が明確になり、学習速度が向上する。実際に、非常にシンプルな改良であるにもかかわらず、周期的な時系列に対して、予測誤差を変化させずに、学習が数十倍も高速化されることが示されている^{28),29)}。

3. クロスエントロピー法

本研究では、学習速度と収束率の向上のために、クロスエントロピー法^{35),36)}を用いる。クロスエントロピー法では、誤差評価関数として、通常平均出力自乗誤差項ではなく、次の評価関数 C を用いる。

$$C = - \sum_i \{ t_i \ln o_i + (1 - t_i) \ln(1 - o_i) \} \quad (1)$$

ここで、 o_i は出力ユニット i の出力値、 t_i はその目標出力値である。リンク重みの更新には、この評価関数 C をリンク重みで偏微分した値を用いる。これにより、逆伝搬誤差量の計算において、ロジスティック関数の微分の項が打ち消され、実際の誤差が逆伝搬されるため、実際の誤差のみに依存したリンク重みの修正が行われ、学習が高速化されると同時に収束率も改善される^{28),29)}。

4. ノイズを付加された Hénon 写像列

以下、4章から7章では、コンピュータシミュレーションによる実験結果を示す。順に、4章を実験1、5章を実験2、6章を実験3、7章を実験4と呼ぶことにする。

問題の設定は、ある時刻 t の値を入力とし、次の時刻 $t+1$ の値を出力として学習するものとする。SRNSMでは、入力としてバッファを持たせるので、バッファの長さを l とすると、入力に $x(t), x(t-1), x(t-2), \dots, x(t-l+1)$ を与えればよい。また、比較対象として、Elmanのネットワークだけでなく、バッファモデルと NARMA リカレントネットワーク³⁸⁾を取り扱う。NARMA リカレントネットワークは ARMA モ

デルの非線形への拡張であり、それをニューラルネットワークで実現したものである。ここで、バッファモデルの入力は SRNSM と同じである。NARMA リカレントネットワークの入力は $x(t), x(t-1), \dots, x(t-p+1), \hat{e}(t), \hat{e}(t-1), \dots, \hat{e}(t-q+1)$ である。ここで、 $\hat{e}(t)$ は、 $\hat{x}(t)$ を時刻 t の予測値とすると、 $\hat{e}(t) = x(t) - \hat{x}(t)$ で表される時刻 t での誤差である。これを NARMA(p, q) と表す。NARMA リカレントネットワークでは、出力ユニットに線形ユニットを用いている。

本章では、簡単な差分方程式により表されるカオス時系列の例として、次式の Hénon 写像³⁷⁾により生成された時系列 $x(t)$ にノイズ $\varepsilon(t)$ を付加した時系列 $x'(t)$ を取り扱う。

$$x(t) = 1 - ax(t-1)^2 + bx(t-2) \quad (2)$$

$$x'(t) = x(t) + \varepsilon(t) \quad (3)$$

本研究では、 $a = 1.4, b = 0.3, x(0) = 0.046, x(1) = -1.04$ を用いた。ノイズには観測誤差として知られる正規乱数を用いた。 $\varepsilon(t)$ は平均0、分散 0.1^2 の正規乱数列である。本実験では、学習用データに200点、テスト用データに200点を用いた。すなわち、本章は少ないデータによる学習例である。

表1に、バッファの長さを変化させたときの誤差逆伝搬学習(BP)とクロスエントロピー法(CE)の学習回数を示す。また、以降、本論文では、汎化能力の基準として、0から1に正規化されたテストデータに対する平均出力自乗誤差(予測誤差と呼ぶ)とテストデータに対する実測値と予測値の間の相関係数の2つの評価基準を用いる。ここで、 $l = 1$ でBPの欄が、従来のElmanの手法である。また、表2に、バッファモデルのバッファの長さ l を変化させたときの結果を、表3に、NARMA(p, q)モデルの p と q を変化させたときの結果を示す。

各パラメータの値は、学習係数 $\eta = 0.01$ 、慣性係数 $\alpha = 0.9$ とした。学習回数は平均出力自乗誤差が0.0040になるまでの100回の試行の平均エポック数である。収束しなかったものは平均の計算から除外した。ここでは、200回を1エポック、学習打ち切り回数を50000エポックとした。“—”は収束しなかったことを示す。特に明記していないものに関しては、収束率は100%である。

隠れユニット数については、リンク重みに学習内容が記憶されることを考慮し、モデルではなくリンク数で差が生じないように、すべての構造で、リンク数がほぼ同じになるように設定した。Elmanのネットワークの隠れユニット数が30個(リンク数960本)である。

表 1 実験 1 における SRNSM の結果
Table 1 Results using SRNSM in Exp. 1.

l	学習回数		予測誤差		相関係数	
	BP	CE	BP	CE	BP	CE
1	8524	3428	0.0029	0.0031	0.971	0.968
2	7658	2707	0.0027	0.0029	0.973	0.971
3	6745	2536	0.0030	0.0031	0.971	0.969
4	6445	1246	0.0035	0.0033	0.967	0.967
5	6417	2727	0.0036	0.0039	0.967	0.965

表 2 実験 1 におけるバッファモデルの結果
Table 2 Results using buffer model in Exp. 1.

l	学習回数	予測誤差	相関係数
4	—	—	—
5	39669	0.0038	0.961
6	22645	0.0042	0.955
7	25168	0.0049	0.950
8	22765	0.0054	0.945

表 3 実験 1 における NARMA リカレントネットワークの結果
Table 3 Results using NARMA recurrent network in Exp. 1.

p	q	学習回数	予測誤差	相関係数	収束率
1	4	—	—	—	0%
2	4	29882	0.0039	0.960	86%
3	4	5523	0.0038	0.962	97%
5	4	3890	0.0038	0.963	100%
7	4	1594	0.0037	0.961	100%
9	4	1439	0.0046	0.950	100%
7	4	1594	0.0037	0.961	100%
7	6	1655	0.0041	0.957	100%
7	8	1449	0.0043	0.954	100%

この値を基準として、各構造で隠れユニット数を調節したものを用意した。たとえば、 $l = 3$ の SRNSM では、隠れユニット数を 29 個にすることによって、リンク数が 957 本の構造で実験している。同様に、バッファの長さ l により、リンク数が Elman のネットワークの 960 本に最も近くなるように、隠れユニット数を計算し、リンク数一定の条件を満たすようにしている。

また、バッファモデルにおいても同様で、 $l = 5$ の構造ならば、隠れユニット数を 160 個にすることによって、リンク数が 960 本の構造で実験している。 $l = 11$ ならば、隠れユニット数は 80 個である。NARMA リカレントネットワークにおいても同様で、 $p = 5$ 、 $q = 2$ の構造ならば、隠れユニット数を 120 個にすることによって、リンク数が 960 本の構造で実験している。 $p = 11$ 、 $q = 6$ ならば、隠れユニット数は 53 個である。

このように、バッファモデルや NARMA リカレントネットワークにおいても、入力長の長さの変化により、




図 2 実験 1 におけるマルチステップ予測に対する相関係数
Fig. 2 Correlation coefficients for multi-step forecasting in Exp. 1.




図 3 実験 1 における学習曲線
Fig. 3 Learning curves in Exp. 1.




図 4 実験 1 における学習結果と予測結果
Fig. 4 Result of learning and forecasting in Exp. 1.

隠れユニット数を調節して、リンク数が 960 本に最も近くなるように、隠れユニット数を計算し、リンク数一定の条件を満たすようにしている。これらの設定により、本実験の構造はすべてほぼ同じリンク数のもとで実験を行った。すなわち、リンク数の違いからではなく、モデルの違いから結果の違いが生じることが期待される。ここで、リンク数を固定して、モデル間の違いを議論することに関しては、後の考察の章で述べたい。

表 1 より、バッファの概念を導入すると、汎化能力を低下させずに、学習が高速化されることが分かる。

具体的には, $l = 4$ の SRNSM に CE を適用した本手法の結果と Elman の手法の結果を比較すると, 学習速度は 6.8 倍高速になった.

図 2 に, 自らの予測値を次の入力に使用したマルチステップ予測を行ったときの相関係数の推移を示す. “Elman” は Elman の手法の結果, “SRNSM” は $l = 4$ のものに CE を適用した結果である.

図 3 に, 2 つの学習曲線を示す. “Elman” は Elman の手法の結果, “SRNSM” は $l = 4$ のものに CE を適用した結果である.

図 4 に, $l = 4$ の SRNSM に CE を適用したときの学習結果と予測結果をグラフにしたものを示す. 実線が正解で, 破線がネットワークの出力である. ちなみに, このときの予測誤差は 0.0033, 相関係数は 0.967 である.

実験結果に対する総合的な考察に関しては, 実験 1 から実験 4 での結果を示した後に, 考察の章で述べる.

5. Lorenz 方程式

本章では, 微分方程式により表されるカオス時系列の例として, 次式の Lorenz 方程式³⁹⁾を取り扱う.

$$\frac{dx}{dt} = -\sigma x + \sigma y \quad (4)$$

$$\frac{dy}{dt} = -xz + rx - y \quad (5)$$

$$\frac{dz}{dt} = xy - bz \quad (6)$$

本研究では, $\sigma = 10$, $b = 8/3$, $r = 28$, $x(0) = 10$, $y(0) = 20$, $z(0) = 30$ を用い, 4 次の Runge-Kutta 法により近似した. 時間間隔 Δt は 0.01 である. 本実験では, 学習用データに 500 点, テスト用データに 1000 点を用いた. すなわち, データ数は実験 1 より少し多い.

本実験では, 特に力学変数の一部のみが観測される場合を取り扱う. すなわち, 得られる離散化時系列のうち, 変数 $x(t)$ のみを使って学習を行う. その結果から, 時間遅れ座標系による埋め込みによりアトラクタの再構成を行うことを試みる. そのために, テストデータを少し多めに発生させてある.

表 4 に, バッファの長さを変化させたときの学習回数, 予測誤差, 相関係数を示す. ここで, $l = 1$ で BP の欄が, 従来の Elman の手法である. また, 表 5 に, バッファモデルのバッファの長さ l を変化させたときの結果を, 表 6 に, NARMA(p, q) モデルの p と q を変化させたときの結果を示す.

各パラメータの値は, 学習係数 $\eta = 0.01$, 慣性係数 $\alpha = 0.9$ とした. 学習回数は平均出力自乗誤差が

表 4 実験 2 における SRNSM の結果
Table 4 Results using SRNSM in Exp. 2.

l	学習回数		予測誤差		相関係数	
	BP	CE	BP	CE	BP	CE
1	—	3001	—	0.00029	—	0.998
3	842	2002	0.00034	0.00025	0.997	0.999
5	542	118	0.00030	0.00034	0.997	0.998
7	576	52	0.00023	0.00023	0.998	0.998
9	1415	301	0.00022	0.00031	0.998	0.998

表 5 実験 2 におけるバッファモデルの結果
Table 5 Results using buffer model in Exp. 2.

l	学習回数	予測誤差	相関係数
1	—	—	—
3	603	0.00027	0.998
5	220	0.00026	0.999
7	125	0.00019	0.999
9	88	0.00017	0.998
11	197	0.00021	0.998
13	349	0.00023	0.996

表 6 実験 2 における NARMA リカレントネットワークの結果
Table 6 Results using NARMA recurrent network in Exp. 2.

p	q	学習回数	予測誤差	相関係数	収束率
3	4	—	—	—	0%
5	4	91	0.00245	0.992	26%
7	4	58	0.00134	0.994	83%
9	4	46	0.00165	0.995	98%
11	4	36	0.00201	0.993	100%
13	4	44	0.00173	0.990	100%
15	4	37	0.00123	0.992	100%
15	4	37	0.00123	0.992	100%
15	6	30	0.00095	0.991	100%
15	8	26	0.00104	0.993	100%
15	10	24	0.00136	0.994	100%

0.00040 になるまでの 100 回の試行の平均エポック数である. 収束しなかったものは平均の計算から除外した. ここでは, 500 回を 1 エポック, 学習打ち切り回数を 10000 エポックとした. “—” は収束しなかったことを示す. 特に明記していないものに関しては, 収束率は 100% である. 隠れユニット数の設定については, 実験 1 と同様である.

表 4 より, バッファの概念を導入すると, 学習が高速化されることが分かる. また, 適切な長さのバッファでは汎化能力も向上している. また, 本実験では Elman の手法は収束しなかった. ただし, これをクロスエントロピー法で学習させると収束していることから, クロスエントロピー法が収束率を上げる学習法であることが確認できる.

図 5 に, マルチステップ予測を行ったときの相関係数の推移を示す. “Elman” は Elman の手法の結果,




図5 実験2におけるマルチステップ予測に対する相関係数
Fig. 5 Correlation coefficients for multi-step forecasting in Exp. 2.




図6 実験2における学習曲線
Fig. 6 Learning curves in Exp. 2.




図7 実験2における学習結果と予測結果
Fig. 7 Result of learning and forecasting in Exp. 2.




図8 実験2における時間遅れ座標空間に埋め込まれたアトラクタ
Fig. 8 Attractor embedded to delay coordinate in Exp. 2.

“SRNSM”は $l=7$ のものにCEを適用した結果である。

図6に、2つの学習曲線を示す。“Elman”はElmanの手法の結果，“SRNSM”は $l=7$ のものにCEを適用した結果である。

図7に、 $l=7$ のSRNSMにCEを適用したときの学習結果と予測結果をグラフにしたものを示す。実線が正解で、破線がネットワークの出力である。ちなみに、このときの予測誤差は0.00023、相関係数は0.998である。

図8に、図7の予測時系列を3次元位相空間に埋め込んだときの軌道を示す。3変数すべてを与えないで、1変数で学習して得られた軌道からでも、きちんと蝶の形をしたLorenzアトラクタが出現している。

本実験では1変数のみから学習を行ったが、適切な埋め込みにより、アトラクタの再構成に成功した。これより、本手法は1変数しか観測されないようなシステムのカオス時系列の学習にも有効であることが分かる。

6. はしかの患者数

本章では、現実的なカオス時系列データの例として、1928年1月から1972年6月までのNew York Cityの毎月のはしかの患者数のデータ⁴⁰⁾を取り扱う。このデータに関する研究としては、文献4)、41)、42)などがある。本実験では、1928年1月から1947年12月までの値を学習用データ(240点)に、1948年1月から1972年6月までの値を予測用データ(294点)に用いた。すなわち、少ない実データでの実験例である。

表7に、バッファの長さを変化させたときの学習回数、予測誤差、相関係数を示す。ここで、 $l=1$ でBPの欄が、従来のElmanの手法である。また、表8に、バッファモデルのバッファの長さ l を変化させたときの結果を、表9に、NARMA(p, q)モデルの p と q を変化させたときの結果を示す。

各パラメータの値は、学習係数 $\eta=0.01$ 、慣性係数 $\alpha=0.9$ とした。学習回数は平均出力自乗誤差が0.0030になるまでの100回の試行の平均エポック数である。収束しなかったものは平均の計算から除外した。ここでは、240回を1エポック、学習打ち切り回数を50000エポックとした。“—”は収束しなかったことを示す。特に明記していないものに関しては、収束率は100%である。隠れユニット数の設定については、実験1と同様である。

表7より、バッファの概念を導入すると、汎化能力を低下させずに、学習が高速化されることが分かる。

表 7 実験 3 における SRNSM の結果

Table 7 Results using SRNSM in Exp. 3.

l	学習回数		予測誤差		相関係数	
	BP	CE	BP	CE	BP	CE
1	16992	4676	0.0029	0.0029	0.961	0.961
3	6446	1656	0.0029	0.0028	0.966	0.968
5	5968	1372	0.0031	0.0030	0.966	0.968
7	2040	437	0.0031	0.0031	0.966	0.965
9	864	166	0.0029	0.0029	0.971	0.971
11	641	133	0.0028	0.0029	0.971	0.970
13	530	113	0.0027	0.0031	0.965	0.963
15	520	104	0.0031	0.0036	0.963	0.955

表 8 実験 3 におけるバッファモデルの結果

Table 8 Results using buffer model in Exp. 3.

l	学習回数	予測誤差	相関係数
1	—	—	—
3	25103	0.0027	0.965
5	19764	0.0031	0.965
7	5598	0.0030	0.959
9	1936	0.0028	0.963
11	1064	0.0027	0.966
13	677	0.0027	0.963
15	674	0.0030	0.961

表 9 実験 3 における NARMA リカレントネットワークの結果

Table 9 Results using NARMA recurrent network in Exp. 3.

p	q	学習回数	予測誤差	相関係数
1	2	—	—	—
3	2	7157	0.0030	0.958
5	2	3640	0.0031	0.959
7	2	2039	0.0039	0.950
9	2	1509	0.0030	0.948
11	2	1370	0.0034	0.961
13	2	677	0.0034	0.961
15	2	470	0.0031	0.954
13	2	677	0.0034	0.961
13	4	676	0.0034	0.968
13	6	605	0.0035	0.970
13	8	545	0.0037	0.973
13	10	434	0.0039	0.966

具体的には、 $l = 11$ の SRNSM に CE を適用した本手法の結果と Elman の手法の結果を比較すると、学習速度は 128 倍も高速になった。

図 9 に、マルチステップ予測を行ったときの相関係数の推移を示す。“Elman” は Elman の手法の結果、“SRNSM” は $l = 11$ のものに CE を適用した結果である。

図 10 に、2 つの学習曲線を示す。“Elman” は Elman の手法の結果、“SRNSM” は $l = 11$ のものに CE を適用した結果である。

図 11 に、 $l = 11$ の SRNSM に CE を適用したときの学習結果と予測結果をグラフにしたものを示す。




図 9 実験 3 におけるマルチステップ予測に対する相関係数
Fig. 9 Correlation coefficients for multi-step forecasting in Exp. 3.




図 10 実験 3 における学習曲線
Fig. 10 Learning curves in Exp. 3.




図 11 実験 3 における学習結果と予測結果
Fig. 11 Result of learning and forecasting in Exp. 3.

実線が正解で、破線がネットワークの出力である。ちなみに、このときの予測誤差は 0.0029、相関係数は 0.970 である。

7. 母音のゆらぎ

本章では、もう 1 つの現実的なカオス時系列データの例として、日本語母音のゆらぎにおけるカオスを取り扱う。日本語の定常な母音は、ほぼ一樣な波形がピッチ周期ごとに繰り返された時間構造を持っている。しかし、まったく同じ形の波形が繰り返されているわけではなく、その形は時間とともに微妙に変化してい

る。この母音に含まれるゆらぎが、自然性の高い音声として聞こえるための条件となることが示されている⁴³⁾。また、そのゆらぎがカオス的である可能性が示され、それを積極的に応用しようという動きが始めている^{44)~46)}。Satoら⁴⁷⁾は、LPCフィルタの逆フィルタをかけて得られる残差波形を用いて、そのゆらぎをニューラルネットワークで学習できることをいち早く示している。

本研究では、Satoらの研究⁴⁷⁾とは違い、音声波形そのものを使って波形の学習を行う。音声データには、サンプリングレート 16 kHz、16 ビット量子化により得られた男性の日本語母音/a/を用いた。そこから、ほぼ定常部分の 1500 点(約 0.1 秒)のデータを切り出し、最初の 500 点(約 3 ピッチ分)を学習用データに、残りの 1000 点(約 6 ピッチ分)をテスト用データに用いた。すなわち、実験 3 より、少し多い実データの例である。

表 10 に、バッファの長さを変化させたときの学習回数、予測誤差、相関係数を示す。ここで、 $l = 1$ で BP の欄が、従来の Elman の手法である。また、表 11 に、バッファモデルのバッファの長さ l を変化させたときの結果を、表 12 に、NARMA(p, q) モデルの p と q を変化させたときの結果を示す。

各パラメータの値は、学習係数 $\eta = 0.01$ 、慣性係数 $\alpha = 0.9$ とした。学習回数は平均出力自乗誤差が 0.00035 になるまでの 100 回の試行の平均エポック数である。収束しなかったものは平均の計算から除外した。ここでは、500 回を 1 エポック、学習打ち切り回数を 50000 エポックとした。“—” は収束しなかったことを示す。特に明記していないものに関しては、収束率は 100% である。隠れユニット数の設定については、実験 1 と同様である。

表 10 より、バッファの概念を導入すると、汎化能力を低下させずに、学習が高速化されることが分かる。具体的には、 $l = 11$ の SRNSM に CE を適用した本手法の結果と Elman の手法の結果を比較すると、学習速度は 102 倍高速になった。

図 12 に、マルチステップ予測を行ったときの相関係数の推移を示す。“Elman” は Elman の手法の結果、“SRNSM” は $l = 11$ のものに CE を適用した結果である。このグラフより、カオスの特徴である長期予測不可能性が見られ、本実験でも母音ゆらぎがカオス的であるという結果を支持する結果が得られた。

図 13 に、2 つの学習曲線を示す。“Elman” は Elman の手法の結果、“SRNSM” は $l = 11$ のものに CE を適用した結果である。

表 10 実験 4 における SRNSM の結果
Table 10 Results using SRNSM in Exp. 4.

l	学習回数		予測誤差		相関係数	
	BP	CE	BP	CE	BP	CE
1	25191	5501	0.00042	0.00040	0.988	0.988
3	12606	3253	0.00044	0.00044	0.987	0.987
5	5244	2332	0.00044	0.00044	0.987	0.987
7	1988	922	0.00043	0.00042	0.987	0.988
9	1349	276	0.00042	0.00041	0.988	0.988
11	1178	248	0.00043	0.00042	0.988	0.988
13	1171	264	0.00045	0.00044	0.987	0.988

表 11 実験 4 におけるバッファモデルの結果
Table 11 Results using buffer model in Exp. 4.

l	学習回数	予測誤差	相関係数
5	—	—	—
7	6996	0.00045	0.987
9	3968	0.00044	0.987
11	2231	0.00047	0.986
13	2247	0.00046	0.987
15	2217	0.00047	0.987

表 12 実験 4 における NARMA リカレントネットワークの結果
Table 12 Results using NARMA recurrent network in Exp. 4.

p	q	学習回数	予測誤差	相関係数
5	2	—	—	—
7	2	7460	0.00043	0.988
9	2	1416	0.00040	0.989
11	2	1725	0.00043	0.988
13	2	2258	0.00042	0.989
9	2	1416	0.00040	0.989
9	4	991	0.00040	0.989
9	6	890	0.00040	0.989
9	8	829	0.00039	0.989
9	10	631	0.00039	0.989

図 14 に、 $l = 11$ の SRNSM に CE を適用したときの学習結果と予測結果をグラフにしたものを示す。実線が正解で、破線がネットワークの出力である。ちなみに、このときの予測誤差は 0.00042、相関係数は 0.988 である。

データ数が多いので、図 15 に、図 14 の予測時系列を 3 次元位相空間に埋め込んだときの軌道を示す。これより、ストレンジアトラクタが出現していることが分かる。ここで、母音ゆらぎの時系列が 3 次元位相空間で埋め込めることは、文献 44) に示されている。本実験でも、そのことが確認された。

実際の音声合成への応用を考えた場合、波形を学習できるだけでなく、発話長を自由に変えられるようになると音声合成として魅力の高い手法となる。これには、発話長に合わせて学習できるように、入力層に、発話の始まりから終わりまでを示すように 0 から 1 へ




図 12 実験 4 におけるマルチステップ予測に対する相関係数
Fig. 12 Correlation coefficients for multi-step forecasting in Exp. 4.




図 13 実験 4 における学習曲線
Fig. 13 Learning curves in Exp. 4.




図 14 実験 4 における学習結果と予測結果
Fig. 14 Result of learning and forecasting in Exp. 4.




図 15 実験 4 における時間遅れ座標空間に埋め込まれたアトラクタ
Fig. 15 Attractor embedded to delay coordinate in Exp. 4.

と時間変化するようなユニットを設けるなどすると、本手法を応用できるのではないかと考えている。現在、これに関しては、研究中である。

8. 考 察

8.1 実験結果

本節では、実験結果について総括する。

実験 2, 3, 4 より、ダイナミクスの学習が難しいほど、SRNSM の高速化能力が非常に機能していることが分かる。特に、100 倍程度も学習が高速化しているにもかかわらず、汎化能力が低下していないという点は非常に有用な性質であるといえる。

Elman の手法のほかに、バッファモデルや NARMA リカレントネットワークの最適な構造と比較しても、本手法の学習速度と汎化能力は遜色ない。さらに、バッファモデルや NARMA リカレントネットワークでは、入力長さにより、収束しないケースがある。それに対して、SRNSM では、 $l=1$ から収束している。これは、時系列学習のモデルとして、重要な性質である。

また、既知のダイナミクスやアトラクタの埋め込み次元を考えると、その数よりも長いバッファを必要としている。これより、ダイナミクスやアトラクタの次元から、最適なバッファ数の関係を推定することが難しいことが分かる。また、SRNSM とバッファモデルや NARMA リカレントネットワークとでは、最適な入力長さが異なることから、モデルにも依存する数であることが分かる。最適なバッファ数の決定に関しては、まだ試行錯誤を要するといえよう。

相関係数の推移のグラフより、カオス的な特徴である長期予測不可能性、すなわち予測ステップ数の増加にともなって、相関係数が 0 へと変化していく様子が見られる。しかし、SRNSM はバッファを利用している分、Elman の手法よりもマルチステップ予測に強いことが示されている。

また、学習曲線のグラフより、SRNSM と CE による学習が振動などしない安定した高速化手法であることが分かる。

8.2 本実験の位置付け

本節では、本実験の持つ意味について考察する。

まず、本実験におけるリンク数固定によるモデル比較について考える。本実験と同様に、リンク数を固定して、Elman のネットワークを含む、10 個のリカレントニューラルネットワークの性能比較を行った実験がある⁴⁸⁾。この論文でも、リンク数の固定により、モデル間の差が生じるとしている。すでに、このように認められた研究があり、本論文におけるリンク数固定

による比較実験もある程度の妥当性が認められると考えている。

また、リンク数が異なると、学習1回あたりのCPU timeが異なってくる。このため、結果として、学習回数は少なくとも、学習に要するCPU timeは実際には多くなるという現象が生じることがある。すなわち、1回の学習で複雑な操作を行って、学習回数を減らすという手法もある。本実験では、CPU timeで比較しても早くなることを示すために、リンク数を固定して実験を行った。本手法ではクロスエントロピー法を用いているので、学習1回に対するCPU timeは、どの手法でも同等である。

また、学習回数に関するパラメータには、リンク数のほかに、学習係数、慣性係数、リンク重みの初期値の分布など、様々なものがある。また、解く問題によっても結果が異なってくるであろう。ここで、本論文誌における実験中心の論文として、本実験の意義と限界を述べたい。

学習回数が焦点になっていても、結局何かを固定して実験することになる。しかし、いろいろな複雑な要素がある中、ある点に注目して、それを切り口として見たときに、興味深い結果が得られるということが重要である。本実験では、SRNSMにおいてバッファ数に注目し、それを変化させたときに、カオス時系列においても学習を高速化する能力があることを明らかにした。本実験で明らかになっていないことは、他の高速化手法とハイブリッドした場合や学習速度に関する他のパラメータを動かしたときに、結果がどう変化してくるかである。当然、予備実験で、学習係数、慣性係数、リンク重みの初期値の分布を変えても、結果が大きく変わることはないことは確かめている。ただし、それを明確に主張するまでには、さらなる実験が必要である。

また、筆者らの他の論文で、ネットワークの性能比較において、学習係数を変化させた実験がある^{49),50)}。この論文での結果を簡潔にまとめると、それぞれの構造に適切な学習係数があるが、学習係数を変化させても、SRNSMは高速化能力を持つ。そこで、それぞれの構造で適切な学習係数を用いて比較しても、SRNSMが学習速度、収束率の点で一番優れていた。比較したネットワークは、Elmanのネットワーク、複素リカレントネットワーク⁵¹⁾である。複素リカレントネットワークは、SRNSMのように、Elmanのネットワークよりも高速で、収束率も向上するということが示されている手法である。

このように、他の実験条件を変化させても、SRNSM

の有用性が変化しないことを示す実験が今後必要であると考えている。

9. おわりに

カオス時系列の学習に際し、構造としてSRNSM、学習アルゴリズムとしてCEを用いることにより、汎化能力を低下させずに学習速度が向上することが示された。ここで、汎化能力とは、テストデータに対する出力自乗誤差(予測誤差)と実測値と予測値の間の相関係数の2つの評価基準からなるものであった。特に、現実的なカオス時系列であるはしかの患者数や母音のゆらぎの時系列データにおいては、従来のElmanの手法と比較して、汎化能力を低下させずに100倍程度も学習が高速化されるという結果が得られた。また、数ステップ先の予測では、バッファの導入により、予測精度が向上するということが確認された。これらの特長は、ニューラルネットワークを用いたカオス時系列の学習に際して、非常に重要な性質であると考えられる。

今後の課題としては、最適なバッファ数に対する定性的な考察が残されている。これに関しては、リアブノフ次元^{52),53)}、相関次元⁵⁴⁾、フラクタル次元⁵⁵⁾などによるカオス時系列により再構成されたアトラクタの次元推定の指標を用いた理論的な解析が有効であると考えている。

参考文献

- 1) Box, G.E.P. and Jenkins, F.M.: *Time Series Analysis: Forecasting and Control*, 2nd ed., Holden-Day, CA (1976).
- 2) Farmer, J.D. and Sidorowich, J.J.: Predicting Chaotic Time Series, *Physical Review Letters*, Vol.59, No.8, pp.845-848 (1987).
- 3) Casdagli, M.: Nonlinear Prediction of Chaotic Time Series, *Physica D*, Vol.35, No.3, pp.335-356 (1989).
- 4) Sugihara, G. and May, R.M.: Nonlinear Forecasting as a Way of Distinguishing Chaos from Measurement Error in Time Series, *Nature*, Vol.344, pp.734-741 (1990).
- 5) Mees, A.I.: Dynamical Systems and Tesselations: Detecting Determinism in Data, *International Journal of Bifurcation and Chaos*, Vol.1, No.4, pp.777-794 (1991).
- 6) Cao, L., Hong, Y., Fang, H. and He, G.: Predicting Chaotic Time Series with Wavelet Networks, *Physica D*, Vol.85, Nos.1&2, pp.225-238 (1995).
- 7) Okabe, Y. and Ootsuka, T.: The Theory of

- KM₂O-Lagevin Equations and its Applications to the Nonlinear Prediction Problem for the One-dimensional Strictly Stationary Time Series, *Journal of Mathematical Society of Japan*, Vol.47, No.2, pp.349–367 (1995).
- 8) Aguirre, L.A. and Billings, S.A.: Retrieving Dynamical Invariants from Chaotic Data using NARMAX Models, *International Journal of Bifurcation and Chaos*, Vol.5, No.2, pp.449–474 (1995).
 - 9) Ikeguchi, T. and Aihara, K.: Prediction of Chaotic Time Series with Noise, *IEICE Trans. Fundamentals of Electronics, Communications and Computer Sciences*, Vol.E78-A, No.10, pp.1291–1298 (1995).
 - 10) Lapedes, A.S. and Farber, R.M.: Nonlinear Signal Processing using Neural Networks: Prediction and System Modelling, Technical Report of Los Alamos National Laboratory, LA-UR-87-2662 (1987).
 - 11) Weigend, A.S., Huberman, B.A. and Rumelhart, D.E.: Predicting the Future: A Connectionist Approach, *International Journal of Neural Systems*, Vol.1, No.3, pp.193–209 (1990).
 - 12) Deppisch, J., Bauer, H.-U. and Geisel, T.: Hierarchical Training of Neural Networks and Prediction of Chaotic Time Series, *Physics Letters A*, Vol.158, Nos.1&2, pp.57–62 (1991).
 - 13) Elsner, J.B.: Predicting Time Series using a Neural Network as a Method of Distinguishing Chaos from Noise, *Journal of Physics A*, Vol.25, pp.843–850 (1992).
 - 14) Frison, T.W.: Predicting Nonlinear and Chaotic Systems Behavior using Neural Networks, *Journal of Neural Network Computing*, Vol.2, No.2, pp.31–39 (1992).
 - 15) Albano, A.M.: Using Neural Nets to Look for Chaos, *Physica D*, Vol.58, pp.1–9 (1992).
 - 16) Principe, J.C., Rathie, A. and Kuo, J.-Y.: Prediction of Chaotic Time Series with Neural Networks and the Issue of Dynamic Modeling, *International Journal of Bifurcation and Chaos*, Vol.2, No.4, pp.989–996 (1992).
 - 17) Principe, J.C. and Kuo, J.-Y.: Dynamic Modelling of Chaotic Time Series with Neural Networks, *Advances in Neural Information Processing Systems*, Vol.7, pp.311–318 (1995).
 - 18) Nagayama, I. and Akamatsu, N.: Approximation of Chaotic Behavior by Using Neural Network, *IEICE Trans. Information and Systems*, Vol.E77-D, No.4, pp.450–458 (1994).
 - 19) Sato, M., Murakami, Y. and Joe, K.: Learning Chaotic Dynamics by Recurrent Neural Networks, *Proc. Int. Conf. on Fuzzy Logic and Neural Networks*, pp.601–604 (1990).
 - 20) 伊藤憲一：カオス時系列データの予測精度向上手法，電子情報通信学会論文誌（A），Vol.J80-A, No.6, pp.986–993 (1997).
 - 21) 増田直紀，合原一幸：ウェーブレット係数列を用いたカオス時系列の予測，電子情報通信学会論文誌（A），Vol.J82-A, No.11, pp.1710–1718 (1999).
 - 22) Pearlmutter, B.A.: Gradient Calculations for Dynamic Recurrent Neural Networks: A Survey, *IEEE Trans. Neural Networks*, Vol.6, No.5, pp.1212–1228 (1995).
 - 23) Funahashi, K.: On the Approximate Realization of Continuous Mappings by Neural Networks, *Neural Networks*, Vol.2, No.3, pp.183–191 (1989).
 - 24) Funahashi, K. and Nakamura, Y.: Approximation of Dynamical Systems by Continuous Time Recurrent Neural Networks, *Neural Networks*, Vol.6, pp.801–806 (1993).
 - 25) Mozer, M.C.: A Focused Backpropagation Algorithm for Temporal Pattern Recognition, *Complex Systems*, Vol.3, pp.349–381 (1989).
 - 26) Takens, F.: Detecting Strange Attractors in Turbulence, *Lecture Notes in Mathematics*, Vol.898, pp.366–381 (1981).
 - 27) Sauer, T., Yorke, J.A. and Casdagli, M.: Embedology, *Journal of Statistical Physics*, Vol.65, Nos.3&4, pp.579–616 (1991).
 - 28) 菊地進一，中西正和：短期記憶を用いたリカレントニューラルネットワークと高速な構造学習法，電子情報通信学会論文誌（D-II），Vol.J84-D-II, No.1, pp.159–169 (2001).
 - 29) Kikuchi, S. and Nakanishi, M.: Learning Time Series by Simple Recurrent Network with Short-term Memory, *Proc. IASTED Int. Conf. on Modelling, Identification and Control*, pp.44–48 (2000).
 - 30) Elman, J.L.: Finding Structure in Time, *Cognitive Science*, Vol.14, pp.179–211 (1990).
 - 31) Cleeremans, A., Servan-Schreiber, D. and McClelland, J.L.: Finite State Automata and Simple Recurrent Networks, *Neural Computation*, Vol.1, pp.372–381 (1989).
 - 32) Hanes, M.D., Ahalt, S.C. and Krishnamurthy, A.K.: Acoustic-to-phonetic Mapping using Recurrent Neural Networks, *IEEE Trans. Neural Networks*, Vol.5, No.4, pp.659–662 (1994).
 - 33) Port, R.F.: Representation and Recognition of Temporal Patterns, *Connection Science*, Vol.2, Nos.1&2, pp.151–176 (1990).
 - 34) Kremer, S.C.: On the Computational Power of Elman-style Recurrent Networks, *IEEE Trans. Neural Networks*, Vol.6, No.4, pp.1000–1004

- (1995).
- 35) Hinton, G.E.: Connectionist Learning Procedures, *Artificial Intelligence*, Vol.40, pp.185–234 (1989).
 - 36) van Ooyen, A. and Nienhuis, B.: Improving the Convergence of the Back-propagation Algorithm, *Neural Networks*, Vol.5, No.3, pp.465–471 (1992).
 - 37) Hénon, M.: A Two-dimensional Mapping with a Strange Attractor, *Communications in Mathematical Physics*, Vol.50, pp.69–77 (1986).
 - 38) Connor, J.T., Martin, R.D. and Atlas, L.E.: Recurrent Neural Networks and Robust Time Series Prediction, *IEEE Trans. Neural Networks*, Vol.5, No.2, pp.240–254 (1994).
 - 39) Lorenz, E.N.: Deterministic Nonperiodic Flow, *Journal of Atmospheric Sciences*, Vol.20, pp.130–141 (1963).
 - 40) Yorke, J.A. and London, W.P.: Recurrent Outbreaks of Measles, Chickenpox and Mumps II. Systematic Differences in Contact Rates and Stochastic Effects, *American Journal of Epidemiology*, Vol.98, No.6, pp.469–482 (1973).
 - 41) Schaffer, W.M. and Kot, M.: Nearly One Dimensional Dynamics in an Epidemic, *Journal of Theoretical Biology*, Vol.112, pp.403–427 (1985).
 - 42) Olsen, L.F. and Schaffer, W.M.: Chaos Versus Noisy Periodicity: Alternative Hypotheses for Childhood Epidemics, *Science*, Vol.249, pp.499–504 (1990).
 - 43) 伊福部達, 橋場参生, 松島純一: 母音の自然性における「波形ゆらぎ」の役割, *日本音響学会誌*, Vol.47, No.12, pp.903–910 (1991).
 - 44) Tokuda, I., Tokunaga, R. and Aihara, K.: A Simple Geometrical Structure Underlying Speech Signals of the Japanese vowel /a/, *International Journal of Bifurcation and Chaos*, Vol.6, No.1, pp.149–160 (1996).
 - 45) Tokuda, I., Miyano, T. and Aihara, K.: Are Normal Vowels Really Chaotic?, *Proc. Int. Sym. on Nonlinear Theory and its Applications*, pp.1173–1176 (1997).
 - 46) Tokuda, I., Miyano, T. and Aihara, K.: Spike-and-wave Surrogate Analysis of Japanese Vowels, *Proc. Int. Sym. on Nonlinear Theory and its Applications*, pp.719–722 (1998).
 - 47) Sato, M., Joe, K. and Hirahara, T.: APOLONN Brings Us to the Real World: Learning Nonlinear Dynamics and Fluctuations in Nature, *Proc. IEEE Int. Conf. on Neural Networks*, pp.581–587 (1990).
 - 48) Horne, B.G. and Giles, C.L.: An Experimental Comparison of Recurrent Neural Networks, *Advances in Neural Information Processing Systems*, Vol.7, pp.697–704 (1995).
 - 49) 西田正洋, 菊地進一, 中西正和: リカレントニューラルネットワークを用いたコード進行の自動生成, *情報処理学会研究報告*, MUS-36-12 (2000).
 - 50) Nishida, M., Kikuchi, S. and Nakanishi, M.: Generating a Chord Progression Corresponding to a Single Melody using Recurrent Neural Networks, *Proc. IASTED Int. Conf. on Modelling, Identification and Control*, pp.988–992 (2001).
 - 51) 木ノ内誠, 萩原将文: 複素ニューロンによる時系列の学習, *電気学会論文誌(C)*, Vol.116-C, No.7, pp.748–754 (1996).
 - 52) Sano, M. and Sawada, Y.: Measurement of the Lyapunov Spectrum from a Chaotic Time Series, *Physical Review Letters*, Vol.55, No.10, pp.1082–1085 (1985).
 - 53) Kaplan, J.L. and Yorke, J.A.: Chaotic Behavior of Multidimensional Difference Equations, *Lecture Notes in Mathematics*, Vol.730, pp.204–227 (1978).
 - 54) Grassberger, P. and Procaccia, I.: Characterization of Strange Attractor, *Physical Review Letters*, Vol.50, No.5, pp.1082–1085 (1983).
 - 55) Higuchi, T.: Approach to an Irregular Time Series on the Basis of the Fractal Theory, *Physica D*, Vol.31, pp.277–283 (1988).

(平成 12 年 4 月 3 日受付)

(平成 12 年 8 月 3 日再受付)

(平成 12 年 11 月 7 日採録)

菊地 進一 (学生会員)



平成 10 年慶應義塾大学理工学部数
理科学科卒業。現在, 同大学大学院
理工学研究科開放環境科学専攻博士
課程在学中。ニューラルネットワ
ーク, カオス, それらの応用の研究に
従事。また, 情報教育にも興味を持つ。電子情報通信
学会, 電気学会, 日本神経回路学会各会員。

中西 正和 (正会員)



昭和 41 年慶應義塾大学工学部卒
業。昭和 44 年同大学工学部助手。平
成元年同大学理工学部教授。工学博
士。昭和 42 年日本初の実用 Lisp 処
理系を作成。以後, 記号処理言語,
人工知能言語等の研究に従事。昭和 57 年 Lisp マ
シン SYNAPSE の開発等。また, 早い段階から, 初
等・中等情報教育に力を注いでいる。電子情報通信学
会会員。