

# LSM モデルを用いた非線形時系列の予測

## Prediction of nonlinear time series by LSM model

城 真範 (PY)<sup>†‡</sup>, 牧野 貴樹<sup>\*</sup>, 合原 一幸<sup>‡\*\*</sup>

Masanori SHIRO(PY), Takaki MAKINO, and Kazuyuki AIHARA

<sup>†</sup> 産業技術総合研究所

<sup>‡</sup> 東京大学生産技術研究所

<sup>\*</sup> 東京大学総括プロジェクト機構

<sup>\*\*</sup>JST・ERATO 合原複雑数理モデルプロジェクト

shiro@ni.aist.go.jp

**Abstract**— A neural network model that can respond quickly for given chaos time series was proposed. The model consist of the liquid state machine and leaky integrate-and-fire model neurons. We showed that the near future is predictable by the model.

**Keywords**— Liquid State Machine, Nonlinear, Time Series, Neural Network

### 1 はじめに

人間は外界から入力される時系列情報を瞬時に認識し、適切な応答をする。しかしながら、外界からの情報には、しばしばカオス的な振る舞いを示すものがある。例えば音声言語の波形がそれである。脳のネットワークモデルとして、カオス時系列のもつ情報を短時間で分解し、有効な情報を選別できるものが必要である。

カオス時系列は、その長期的な振る舞いを予測することが困難であるが、決定論的カオスであれば、時系列の短期的な未来を予測できる。ゆえに、何らかのカオス的な信号に対して、短期的な未来を予測できれば、それはカオス認識を可能とするモデルの一步となるだろう。

本研究では、入力とするカオス時系列として、よく知られたローレンツの方程式を利用し、Leaky な積分発火ニューロンモデル (LIF) を結合したネットワークを用い、時系列の再構成をすることで短期的未来の予想ができることを示す。

### 2 カオス時系列の再構成

時刻  $t$  における離散力学系の内部状態が  $d$  次元のベクトル  $\mathbf{x}_t$  で表されているとする。内部状態は遷移関数  $\mathbf{f}$  にしたがって変化するが、外部からは直接  $\mathbf{x}_t$  が観測できず、観測関数  $\mathbf{g}$  を通した  $m < d$  次元の観測ベクトル  $\mathbf{y}_t$  しか観測できない状況を考える。

$$\mathbf{x}_{t+1} = \mathbf{f}(\mathbf{x}_t) + \eta_t \quad (1)$$

$$\mathbf{y}_t = \mathbf{g}(\mathbf{x}_t) + \xi_t \quad (2)$$

ここで、 $\eta$  はダイナミカルノイズ、 $\xi$  は観測ノイズである。時系列の予測とは、過去の観測系列  $(\mathbf{y}_t, \mathbf{y}_{t-1}, \dots)$

だけにもとづいて、次ステップに与えられる観測  $\mathbf{y}_{t+1}$  を予測することをいう。内部状態  $\mathbf{x}_t$  に関する状態が得られない場合でも、遅れ時間系  $\hat{\mathbf{x}}_t = (\mathbf{y}_t, \mathbf{y}_{t-1}, \dots, \mathbf{y}_{t-l+1})$  を使って内部状態の構造を再構成する手法が知られている。 $\hat{\mathbf{x}}$  の次元が  $2d + 1$  次元以上であれば、遅れ時間系  $\hat{\mathbf{x}}$  への変換が埋め込みとなり、元の構造が再構成されることが証明されている [2]。

$$\hat{\mathbf{y}}_{t+1} = \hat{\mathbf{f}}_0(\hat{\mathbf{x}}_t) + \hat{\eta}_t \quad (3)$$

### 3 ニューロンとネットワークのモデル

本研究では、スパイクのタイミングを考慮できるニューロンモデルとして、Leaky な積分発火ニューロン (LIF) モデルを利用した。LIF モデルは、次式で定義される。

$$\frac{du_i}{dt} = -k \cdot u_i + S_i(t) + c \quad (4)$$

ここで  $i$  はニューロンのインデックスであり、 $k > 0$  は時定数、 $c$  は自発発火の度合いを与える定数 ( $c > k$ )、 $S_i(t)$  は、ニューロン  $i$  が時刻  $t$  に受ける入力の和である。 $u_i = \theta$  に達したとき、ニューロンは発火し、 $u_i = 0$  にリセットされるとともに、結合している他のニューロン  $u_j$  に結合強度  $s_{ji}$  の入力を与える。 $w_{ji}$  は学習を通じて変化しない。

情報を短時間で取り出すために、あらかじめ入力された過去の情報を多数保持しておくネットワークを考える。この要請を満たすネットワークモデルとして、Liquid State Machine (LSM) が提案されている。LSM のネットワークは、状態層と出力層の 2 層から構成される (Fig. 1)。状態層の各 LIF は相互に結合しており、出力層は状態層の各 LIF からのみ投射を受ける。




Fig. 1: Network consist of state layer and output layer.

ここで、状態層を構成するいくつかの LIF に対し、カオス的にタイミングが時間変化するスパイク列  $S(t)$  を与えると、各 LIF はスパイク頻度に応じて発火する。ネットワーク上にランダムな結合がある場合、ネットワークの全状態は、過去の入力を反映したものになっている。

状態層の LIF 数が十分に多ければ、各 LIF の出力を、適切な重みベクトル  $\mathbf{w}$  で足しあわせて出力層内のニューロンへ投射入力することで、入力時系列を引数とする任意の関数を作ることができる [1]。ここで、出力 LIF ニューロンが、式 3 で与えられるような、再構成空間上の予測関数となるような重みベクトル  $\mathbf{w}$  を見つけることができれば、非線形入力の次の値の予測となる出力が得られ、入力のダイナミクスが再構成できることになる。

既に LSM によって、非線形関数に乱数を乗せたデータから元の関数の過去の値を類推できることが示されている (W.Maass, 2002)。我々は、これをすすめ、過去だけでなく未来の値を類推できることを示した。

#### 4 結果

10x10x10 のサイズの格子点上にニューロンを置き、ネットワークの端面から入力を与えた場合の結果を Fig. 2 に示す。Fig. 2 の横軸は学習における教師データと入力時系列との時間的な差であり、縦軸は学習後の予測結果と入力時系列との二乗平均誤差である。短期未来予測が可能であることがわかる。




Fig. 2: Mean squared errors versus output delay.

この結果は LSM のネットワークによってカオスのダイナミクスの再構成が可能であることを意味する。我々は今後、より現実的な学習方法として STDP を利用することを検討している。入力から出力層への直接投射をつなぐことにより、STDP によって、状態層からの投射の信号到達順序によって  $\mathbf{v}$  を調節されるかどうかを調べたい。

#### 謝辞

本研究は文部科学省科学研究費補助金特定領域研究「脳の高次機能システム」領域 (No.17022012) の助成をうけて行われた。

#### 参考文献

- [1] Maass, W., Natschlaeger, T., and Markram, H. (2004) “Computational Models for Generic Cortical Microcircuits, in Feng, J. ed.” *Computational Neuroscience; A Comprehensive approach*, pp. 575–605, Chapman & Hall/CRC, Boca Raton, Florida
- [2] Takens, F. (1981) “Detecting strange attractors in turbulence, in Rand, D. A. and Young, B. S. eds.” *Dynamical Systems of Turbulence*, pp. 366–381, Springer-Verlag, Berlin, Vol. 898 of Lecture Notes in Mathematics
- [3] M. Shiro, T. Makino and K. Aihara (2008) “積分発火ニューロンモデルを利用した情報分離の検討” 第 22 回 人工知能学会全国大会論文集