

## リザーバーコンピューティングのための LSTM を用いた再帰学習

清水 能理†

八戸工業大学†

## 1. はじめに

人間が知能を使って自然に行うタスクをコンピュータに学習させ機械にさせようとするディープラーニング（深層学習）は、AI の機械学習の一手法で、ニューラルネットワーク（NN）の最新技術である。近年では、従来のニューラルネットワークを改良して作られたディープラーニングの登場により、AI やパターンマッチングの研究が盛んにおこなわれている。また、時系列データに対するディープラーニングが注目されている。今回はディープラーニングをカオスマデリングに使用することで、従来のニューロモデルと精度や安定性向上の点を比較し、ディープラーニングの時系列データへの応用可能性を考察する[1-4]。

## 2. 問題の記述

再帰型ニューラルネットワーク（リカレントニューラルネットワーク：RNN）は、時系列データを学習させるのに適したニューラルネットワークである。一つ前の時刻の隠れ層の出力を、次の時刻の隠れ層の入力としてフィードバックする時系列情報を保持したネットワークである。一方、最近新たな機械学習方式として注目されているのがリザーバーコンピューティングである。リザーバー

（Reservoir）は RNN(Recurrent Neural Network) の一種である。入力層、中間層（リザーバー層）、出力層（リードアウトニューロン層）の 3 層で構成される教師あり学習の RNN である。自己回帰を含む再帰型ネットワーク（Recursive Neural Network）で構成されることが多い。中間層（リザーバー層）はカオス性を有するダイナミカルモデルで構成し、学習は出力層（リードアウトニューロン層）のみで行う。高速学習、リアルタイム学習、実装の容易さが特徴である。今回は、リザーバー層を再帰型ネットワークで設計し、ディープラーニングによるカオスマデリングを行う。従来のニューロモデルとの比較では、ブーストラップ法に基づくサロゲートアルゴリズムを適用した定量評価を行う。

## 3. LSTM

LSTM(Long-Short Term Memory)は、RNN の欠点を改善している。RNN は、ある特定時刻の入力データ

を保持することが難しく長い時系列データに不向きであるが、LSTM は長い時系列データに対応でき再帰学習に向いている。隠れ層をデータの記憶に特化したユニットに置き換えている点が特徴で、「入力層からの入力」および「前の時刻の隠れ層からの入力」の他、3 ゲートを制御するパラメータがある。その 3 ゲートは、それぞれ「入力層からの入力値」「隠れ層内のフィードバック(記憶)」「出力層への出力値」の大きさを制御する。任意時刻だけ離れたデータを記憶でき、時系列の相関を得ることができる。図 1 は LSTM におけるネットワークモデルの例である。

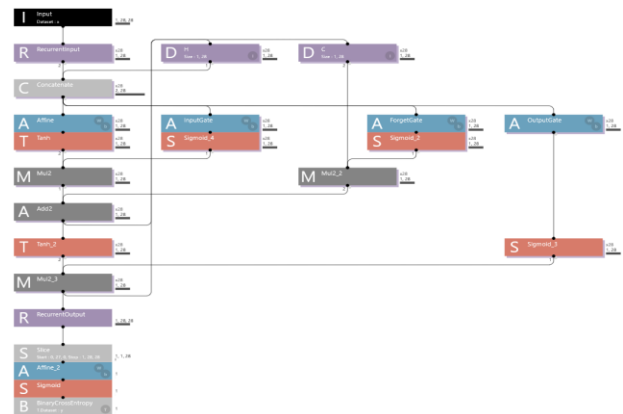


図 1 LSTM におけるモデルの例

## 4. 研究方法

深層学習の実装環境構築では、Python 言語でコーディングするオープンソースソフトウェア（OSS）が主流となっている。今回は、SONY 製品に実装されている AI（NNL：Neural Network Libraries）の Windows 開発環境（NNC：Neural Network Console）を用いて実装する。学習プログラムは、NNC を用いて作成する。システム構築は、Windows 版と Cloud 版のフレームワーク（NNCC：Neural Network Console Cloud）を用いて特徴を考察する。同じプログラムおよび同じデータセットを用いた深層学習の比較を行う。

## 5. 実験方法

暗号化および秘匿通信系などで利用されるカオスは、数値計算により観測される複雑な振る舞いを利用する。用いられるモデルは様々あるが、自然界の多様なカオスに対し、人工的に作り出されるカオスは限定的である。カオスが生じ得るための十分条件を示すリー・ヨークの定理に基づいた

カオスモデルの構築は事実上困難である。よって、ディープラーニングを用いて非線形システムを構築する。今回は階層型ネットワークモデルを基本に、改良型の再帰モデルを用いる。学習に使用する時系列は、カオス発生時の MG 常微分方程式の出力データを用いる。構築したカオスモデルがカオス性を有しているか検証するため、出力データに対してサロゲート法を応用する。サロゲートアルゴリズムを用いてサロゲートデータを作成し、そのリアプロフ指数を計算して、カオス性を定量評価する。手順は以下の通りである。

- ①サロゲートデータ法を用いて時系列データを作成し、入力行列に読み込む。
- ②埋め込みを行い、3次元データ化する。
- ③リカレンスプロット、N近傍プロットを解析後、リアプロフスペクトラムを算出する。
- ④各リアプロフ指数を求め、カオス性を判定する。

### 6. 実験結果

ディープニューラルネット (DNN)、RNN、LSTM では、アトラクタ解析、リアプロフ指数、サロゲートデータ法のいずれの場合も、高いカオス性が得られた。図2は実験に用いた LSTM 構築モデルである。畳込みニューラルネットワーク (CNN) で学習を行った出力データから、複雑なストレンジアトラクタを再現でき、定性的観点からはカオス性を有したモデリングができたと推察した。出力データのリアプロフ指数から準カオス性を確認でき、評価データとの誤差も全体で1%であった。しかし、サロゲート法ではカオス性が十分認められなかった。LSTM における各サロゲートデータ法の検定結果を以下の表1、2に示す。検定統計量 S の評価には、リアプロフ指数の平均値および標準偏差を用いた。表の○は帰無仮説の棄却を、×は帰無仮説に従うことを示す。

Table 1 LSTM 出力データにおける非線形統計量と非線形統計量標準偏差

	リアプロフ指数 平均	リアプロフ指数 標準偏差
オリジナルデータ	1.835464795	0.570210165
R S サロゲート	9.679284314	0.435770405
F S サロゲート	5.001018035	0.447001083
F T サロゲート	6.328532584	0.342104805
AAFT サロゲート	9.601050307	0.302102037
IAAFT サロゲート	12.94510607	0.174001029

Table 2 LSTM における各サロゲートデータ法に対する検定統計量 S およびカオス性

	検定統計量 S	カオス性の有無
R S サロゲート	7.680094914	○
F S サロゲート	5.001010106	○
F T サロゲート	6.410102801	○
AAFT サロゲート	8.400670108	○
IAAFT サロゲート	12.102500104	○

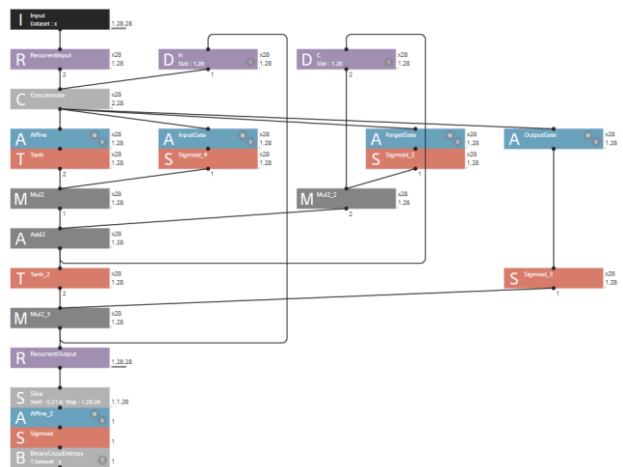


図2 実験に用いた LSTM 構築モデル

### 7. おわりに

カオスダイナミクスを学習したニューラルネットワークを構築できた。パターンマッチングが主な用途の CNN では、時系列データの定量評価は RS サロゲート以外、帰無仮説に従った。DNN は、一般の NN と比べ出力データ誤差が減少した。RNN は、モデルのダイナミクスを学習でき、時系列の予測に有効である。LSTM は、任意時刻だけ離れたデータが記憶でき、時系列の相関を得ることができた。

OSS の NNL を用いたディープラーニングでは、カオスモデリングの精度が高かった。そのフレームワークは、NNC(Windows 版)および NNCC(クラウド版)ともに利便性が良かった。NNL はパラメータだけでなく、ネットワーク構成も学習可能であった。その機能ではランダムなネット構築が容易で、構築ネット毎の評価値も得られた。一方、設計仕様の通りに作成する場合、学習で設定すべきパラメータ数が多く手法が一気に複雑になるため、変数チューニングの予備知識や高い経験値が必要である。

今後、ネットワークの設計変更が動的に可能な Chainer や、深層強化学習ライブラリが豊富な PyTorch をフレームワークとして試み、その効果を定量的に比較する。一方、RNN を改良し精度の高いカオスモデリングが可能な LSTM を、時系列予測に活用し有効性を確認する。

### 参考文献

- 1) 足立 悠：ソニー開発の Neural Network Console 入門, リックテレコム(2018)
- 2) Neural Network Libraries: <https://nnabla.org/>
- 3) Neural Network Console: <https://dl.sony.com/ja/>
- 4) 合原一幸, 池口徹, 山田泰司, 小室元政：カオス時系列解析の基礎と応用, 産業図書(2000)