

Deep Learning による時系列予測の精度の検証

河崎 光毅[†] 吉川 大弘[†] 古橋 武[†]

[†] 名古屋大学 大学院工学研究科

1. はじめに

昨今では、情報通信の技術の進歩により、大量の時系列データを容易に入手できる。しかしこの大量のデータを人手で解析することは、コストがかかりすぎるという点で現実的ではない。そこで、機械学習を用いた時系列解析が盛んに行われている。2000年代後半から注目を集めている機械学習手法に Deep Learning がある。Deep Learning は自然画像処理の分野で著しい識別精度向上を達成して注目を集めるようになった[1]。Deep Learning は、データから特徴量を自動で抽出することで、精度の良い識別を可能にしていると考えられている。本稿では、Deep Learning による時系列データの予測を行い、その精度を検証することで、Deep Learning の時系列予測に対する有効性を検証する。

2. Deep Learning を用いた時系列予測

本稿では、Restricted Boltzmann Machine (RBM)を用いた Deep Learning を実装した。RBMとは、ニューラルネットワークを生成モデルとして学習する手法である。RBM は、生成モデルという特性上、データの潜在的な特徴をとらえやすいと考えられる[2]。その点に注目して、RBM の出力を用いた時系列予測の研究が報告されている。呉本らは RBM を用いた時系列予測の手法を提案した[3]。[3]では、前の時間点との差分データを入力することで、より精度の高い識別を可能にしている。Hraskoらは、連続値入力を可能にした RBMを用いて、時系列予測の精度を向上させている[4]。本稿では、上述の先行研究とは異なる方法での時系列予測を行う。具体的には、RBM における“再構成データ”を用いる。再構成データを求めるには、まず入力層から出力層までデータを伝搬させる。得られた出力層の値を、次は入力層まで逆伝搬させて、入力層の値を再構成する。こうして得られたデータを再構成データと呼ぶ。入力するデータに欠損があっても、再構成データでは、その欠損 5 補完されている。本稿では、この特徴を利用し、再構成により補完された値を予測値として用いる。

3. 実験及び結果

まず、実験に使用したデータについて説明する。でんき予報[5]から、1時間ごとの電力需要のデータが得られる。このデータに対して、1週間を1単位データとして、計 416 データを得た。このうち、300 データを Deep

Learning によって教師なし学習をさせた。テストデータには残りの 116 データを用いた。テストデータについて、1 週間のうち、 α 日目以降のデータを意図的に欠損させた。その状態で、再構成データを計算して、時系列予測を行う。すなわち、例えばデータが(月)～(日)の1週間、 $\alpha=2$ であれば、月曜日の電力需要がわかった時点での火曜日以降の電力需要を予測することになる。

学習の結果、学習データにおける RMSE (Root Mean Squared Error)の平均は 5.436、最大は 63.605、最小は 0.417 となった。学習データの中には、電力需要が大きく増加するデータがあり、それらは発生頻度が少なく、うまく学習されなかった。しかし、RMSE の中央値は 3.679 と低かったことから、学習自体は高い精度で実現できていると考えられる。表 1 に、テストデータにおける予測値の RMSE を示す。テストデータの結果から、 α が大きくなると、RMSE が小さくなることが確認できた。また、学習データと比べても低い RMSE を実現できた。

表 1. テストデータにおける予測値の RMSE

α	2	3	4	5	6	7
平均	3.206	2.822	2.758	2.486	2.028	1.871
最大	9.661	8.959	9.300	8.322	6.797	5.168
最小	1.037	0.745	0.691	0.691	0.421	0.485

4. まとめ

本稿では、Deep Learning による時系列予測の精度について検討した。実験結果から、Deep Learning の再構成データを利用することの有効性が示唆された。今後の課題として、他の手法との比較が挙げられる。

参考文献

- [1] Q. V. Le, *et al*, “Building High-Level Features using Large Scale Unsupervised Learning,” 29th International Conference on Machine Learning, pages 81-88, 2012
- [2] M. Langkvist, L. Karlsson, A. Loutfi, “A Review of Unsupervised Feature Learning and Deep Learning for Time-Series Modeling,” Pattern Recognition Letters vol.42, pp.11-24, 2012
- [3] T. Kuremoto, S. Kimura, K. Kobayashi, M. Obayashi, “Time Series Forecasting using a Deep Belief Network with Restricted Boltzmann Machines,” Neurocomputing vol.137 pp.47-56, 2014
- [4] R. Hrasko, A. G. C. Pacheco, R. A. Krohling, “Time Series Prediction using Restricted Boltzmann Machines and Backpropagation,” Procedia Computer Science vol.55 pp.990-999, 2015
- [5] でんき予報, 東京電力, <http://www.tepco.co.jp/forecast/index-j.html>