

RBM を用いた電力需要予測に関する検討 A Study on Power Demand Prediction using Restricted Boltzmann Machine

河崎 光毅[†] 吉川 大弘[†] 古橋 武[†]
Koki Kawasaki Tomohiro Yoshikawa Takeshi Furuhashi

1. はじめに

電力は貯めることが難しいエネルギーであるため、需要と供給を均衡させる必要がある。それにより、その日の電力供給量を決定する上で、電力需要の予測は極めて重要となる。そのため、精度の高い電力需要予測は不可欠な技術であるといえる。本稿では、電力需要の予測精度向上を目的として、深層学習を用いた電力需要予測を行う。深層学習は、データの特徴を自動で抽出できることで、昨今非常に注目を集めている手法である。特に画像処理の分野では、著しい精度向上の実現[1]や、抽出された特徴量の可視化[2]により、深層学習の高いパフォーマンスが示され、盛んに研究が行われている。本稿では、RBM (Restricted Boltzmann Machine) を用いて深層学習を実装する。RBM は、生成モデルという特性から、データに潜在する特徴を抽出しやすいと考えられている[3]。

2. 手法

2.1 Restricted Boltzmann Machine

RBM (Restricted Boltzmann Machine) は生成モデルの一種であり、トレーニングデータ集合のデータ分布を推定することでモデリングを行う。RBM は、図1のような3層(入力層、隠れ層、出力層)から成るネットワークを学習する。出力層と入力層はノードの数が等しい。また、入力層と隠れ層の間の重みが W のとき、隠れ層と出力層の間の重みを W^T で表現することが多い。隠れ層と出力層のバイアスをそれぞれ b , c とすると、出力 z は入力 x から以下のように求められる。ここで、 $f(x)$ は活性化関数と呼ばれ、本稿ではシグモイド関数を用いる。

$$z = f(W^T f(Wx + b) + c) \quad (1)$$




図1 3層RBMの例

学習が進むにつれて、入力層と出力層の値が等しくなることが期待される(ただし実際には近似計算を用いているので、厳密に等しい値にはならない[4])。出力層の値と入力層の値とが十分に近ければ、隠れ層から入力層を再現する重みを得ることができたと解釈できる。つまり、隠れ層が入力層を表現できる特徴量を抽出したと考えることができる。RBM は通常、二値入力、二値出力を想定している。これを拡張したものにGB-RBM (Gaussian Bernoulli-RBM) と呼ばれるモデルがある。GB-RBM は RBM の簡単な変更

[†]名古屋大学 大学院 工学研究科 計算理工学専攻
Department of Computational Science and Engineering,
Graduate School of Engineering, Nagoya University

で実装可能であり[4]、連続値入力、二値出力を実現したモデルである。

2.2 深層学習

RBM を用いた深層学習を実装するには、RBM を層状に重ねればよい。つまり、RBM の隠れ層を次の RBM の入力層と捉え、次の隠れ層を学習する。図2に、深層学習を用いた学習の流れを示す。この例では、3層のネットワークを深層学習により学習している。こうして得られた最終的な特徴量(最終層)は、特徴量の特徴量を抽出していくことで、より抽象的な特徴を抽出すると考えられている[5]。

一方、抽出された特徴量を入力として、所望の値を出力するように学習することで、様々な問題を解決するのが DBN (Deep Belief Network) である。例えば、カテゴリカル変数を出力とすることで判別問題に、予測値を出力することで予測問題に適用可能である。この部分の学習には BP (Back Propagation) を用いる方法が有名であるが、他にも SVM や LDA などの種々の判別器を用いることもできる。




図2 深層学習の例

3. RBM を用いた時系列データ予測

3.1 従来手法

呉本らは、RBM を用いた深層学習 (DBN) により、人工データである CATS データ[6]の予測値を出力する方法を提案した[7]。この予測方法は、Kalman Filter を用いた予測の精度には及ばなかったものの、比較的高い精度を示すことができた。更に Hrasko らは、連続値入力を許容した GB-RBM が、より高い予測精度を実現できることを示した[8]。これらの方法では、RBM による学習の後、予測値を出力するように Back Propagation を用いて学習している。

3.2 提案手法

本稿では、DBN を用いず、“再構成データ”を予測値として用いる方法を提案する。再構成データを用いることで、RBM による学習後、予測値の出力に対しての学習を行う必要がなく、RBM により抽出された特徴をそのまま用いて予測することが可能となる。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(抽出された特徴量)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、その欠損が補完される。提案手法では、この特徴を利用し、予測したいデータを欠損させて入力して、得られた再構成データにおいて補完された値を予測値として用いる。

4. 実験

4.1 実験条件

東京電力と気象庁のホームページ上で公開されている電力需要データと気温データを用いて実験を行った[9][10]。電力需要の予測に気温データも用いるのは、電力需要が気温の影響を大きく受けるためである。2008/1/1 から2015/12/31 の1時間ごとのデータを取得し、暦の影響を消す目的で、土日祝日・年末年始のデータを削除した。窓の長さを48時間として、1時間ずつ窓をずらしながらデータを作成した。1つのデータには、電力需要データ48時間と気温データ48時間を連結させたものを用いた。2008年から2014年の計40,824データをトレーニングデータ、2015年の計5,736データをテストデータとした。RBMの学習における最大反復回数と学習率は、それぞれ2000と0.01に設定した。また各層におけるノード数は、入力層から96, 96, 48, 20とした。なおこれらのパラメータはすべて任意に決めた値であり、最適値を探索したわけではない。

実験では、提案手法として、再構成データを用いた予測と、従来手法として、DBNを用いた予測について比較した。DBNに関しては、予測値出力のための学習にLDAを用いた。これはBPを用いるより、LDAを用いた方が高い精度を実現したためである。評価指標にはRMSEを用いた。RMSEは、予測値と実測値との平均二乗誤差の平方根であり、値が小さいほど予測性能が高いことを示す。RMSEは、 y を予測値、 t を実測値とすると、式(2)のように求められる。本実験では、与えられたデータの直後24時間の予測を行い評価したため、式(2)において $n=24$ である。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2} \quad (2)$$

4.2 結果

テストデータにおける平均RMSEの値は、提案手法が2.39、従来手法が3.47であった。提案手法である再構成データによる予測の方が、DBNによる予測よりRMSEが低く、高い予測性能を示していることがわかる。

この精度の差を生み出した要因の検証として、それぞれの特徴量をどのように予測値に変換したのか、すなわち、各手法において、抽出特徴量をどのような重みで予測値に変換したかについて考察する。ただし、再構成データによる重みに関しては、各層における重みの積を計算しても、特徴量から予測値への正確な変換にはならないが、近似値を取得できるため、参考値として比較を行う。

図3に、再構成データによる重みとDBNによる重みを示す。重み行列は、行が予測次元数(24)、列が抽出特徴量の次元数(20)であり、青色が低い値を、赤色が高い値を示している。左右で比較すると、色の傾向が似ていることがわかる。しかし、一部の特徴量に関して、重みの傾向が異なっている。例えば、1列目の10~16行に関しては、再構成データによる重みでは高い値(赤)だが、DBNによる重みでは低い値(青)である。図3の重み行列の1列目におい

て、出力値が高い入力データ例を図4に示す。このような波形が入力されると、10~16時間後の電力需要が、再構成データによる予測では増加、DBNによる予測では減少するように寄与する。このように、二手法で予測値への影響が異なる特徴量を可視化することで、精度の差が生じた要因を、より正確に理解できると考えられる。




図3 重み行列の差

(左：再構成データによる重み、右：DBNによる重み)




図4 1列目で高い値を出力した入力データ例

5. おわりに

本稿では、RBMにおける再構成データを予測値として用いる時系列データ予測手法を提案した。電力需要予測の実験を行い、再構成データに基づく予測により、DBNによる予測よりも予測精度を向上させられることを示した。

今後の課題として、予測精度の差に寄与した特徴量の可視化・解析を行うことが挙げられる。これにより、深層学習を用いた時系列データ予測過程の理解につながり、層構造の最適化や現象の理解に応用できると考えられる。

参考文献

- [1] A. Krizhevsky, I. Sutskever, G. E. Hinton, "Imagenet Classification with Deep Convolutional Neural Networks," Neural Information Processing Systems 25 (NIPS 2012), pp.1106-1114 (2012).
- [2] Q. V. Le, et al., "Building High-Level Features Using Large Scale Unsupervised Learning," 29th International Conference on Machine Learning (2012).
- [3] 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 (2014).
- [4] G. E. Hinton, "A Practical Guide to Training Restricted Boltzmann Machines," Technical report, University of Toronto (2010).
- [5] H. Lee, et al., "Convolutional Deep Belief Networks for Scalable Unsupervised Learning of Hierarchical Representations," 26th International Conference on Machine Learning (2009).
- [6] A. Lendasse, et al., "Time Series Prediction Competition: The CATS Benchmark," International Joint Conference on Neural Networks, pp.1615-1620 (2004).
- [7] T. Kuremoto, et al., "Time Series Forecasting using a Deep Belief Network with Restricted Boltzmann Machines," Neurocomputing, Vol.137, pp.47-56 (2014).
- [8] 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).
- [9] <http://www.tepcoco.jp/forecast/index=j.html>.
- [10] <http://www.data.jma.go.jp/gmd/risk/obsdl/index.php>.