

ニューラルネットワークを用いた電力需要予測における 最適な入力データ構成の探索

Study to Exploration of the Optimal Input Data Configuration for Electricity Demand Forecasting using Neural Network

2241028 大塚 祐輝

Yuki OTSUKA

指導教員 秋葉 知昭

The purpose of this study is to clarify the conditions for input data configuration that contribute to improving the accuracy of neural network models. Multiple datasets were created based on four criteria: data duration, data types, weather elements, and the number of weather observation points. Prediction accuracy was evaluated using the Root Mean Squared Error (RMSE). It was confirmed in this study that while longer data durations improved prediction accuracy, the rate of improvement diminished. Next, regarding data types, the addition of weather data and lag features resulted in a significant improvement in prediction accuracy. Learning curves also confirmed that lag features had the effect of stabilizing the training process. Finally, regarding weather elements and the number of observation points, temperature data from two locations yielded the highest accuracy on an annual basis. However, detailed monthly evaluations revealed that the optimal combination varied by season.

1. 緒言

近年の情報化の発展は著しく、政府において電力需要の見通しの方向性を修正しており[1]、その不確実性が高まっている。また、日本のエネルギー自給率は2023年度で15.3%であり、G7各国で一番低い水準になっている[2]。こういった状況から、電力需要予測を高精度に行う必要がある。

人工知能(AI)の出現により、ニューラルネットワーク(以下 NN)に基づく学習モデルが予測精度の点で注目を集めている。電力需要予測の研究でも、予測手法として様々な深層学習モデルで予測が行われてきた[3]。しかしながら、入力データに焦点を当てた研究は十分とはいえない[4][5]。

本研究では、NN モデルを使用し、予測精度の向上に寄与する最適な入力データ構成の条件を明らかにすることを目的とする。データセットを年数や種類、気象要素と気象地点数の観点で複数作成し、最も高い予測精度を記録したデータセットから最適な条件を探索する。

2. 先行研究

柴田らの研究[4]と大谷らの研究[5]からデータ期間の拡充、入力データの種類の増加、気象データの追加、気象特性を考慮した気象地点の数の増加を新たに求めることで、最適なデータ構成を明らかにする。

3. 研究方法

3.1 予測対象エリア

多地域を対象に予測を行った研究[3]の結果から予測精度が低い傾向にある東京電力エリアを対象に予測を行った。

3.2 収集データと期間

データの収集期間は2016年4月1日から2024年12月31日の約9年間であり、24時間単位でデータを収集した。収集データを表1に示す。

ここで、不快指数とは夏の蒸し暑さを数量的に表した指標であり、乾球温度を $T_d(^{\circ}\text{C})$ 、 $H(\%)$ とすると、以下の式で示される。

不快指数=

$$0.81T_d + 0.01H(0.99T_d - 14.3) + 46.3$$

また、ラグ特徴量はある時点のデータに対し、過去データを意味する。1時間前、2時間前、3時間前、24時間前、48時間前、168時間前を現在の時点で参照できるようにした。

表1 収集データ

収集データ	具体的な内容
電力需要実績値	
暦データ	年、月、時間、曜日、お盆(8月13日～16日)、年末年始(12月29日～1月3日)
気象データ	気温、天気、降水量、風速、風向、相対湿度、猛暑
不快指数	
昼間・夜間人口データ	
ラグ特徴量(過去データ)	電力需要実績値、気象データ、不快指数

3.3 データセットの作成

データの年数・種類・気象要素と気象地点数による予測精度の違いを明らかにするためのデータ

セットをそれぞれ3個、5個、36個作成した。

気象地点は、気象庁の最高気温に関するランキングを参考に、東京、前橋、熊谷の3地点を選定した。

3.4 評価方法

予測精度を評価する指標として、二乗平均平方誤差(Root Mean Squared Error : RMSE)と RMSE の改善率を用いる。

4. 結果及び考察

4.1 データセットごとの予測結果

項目ごとに予測精度を算出した中で、最も高い精度の結果を表2に示す。精度が高い条件としてデータ年数が最長となる9年間の場合・種類が最も多い6種類・気象要素が1つ・地点数が2つであることが最適であるといえる。

表2 最適な入力データセットの探索結果(通年)

項目	比較条件	最適条件	RMSE (万 kW)
年数	5, 6, 9 年	9 年	44.6093
種類	2~6 種類	6 種類	47.8224
気象要素	1~7 つ	気温	33.6758
地点数	1~3 地点	東京・前橋	

4.2 考察

電力需要予測に用いる NN も入力データの量が多いほど、予測精度は向上する。年数を5年間から6年間の1年間では改善率は10%で大きい改善であったが、6年間から9年間の3年間では11%程度で1年間では3.3%程度の改善となった。5年間では電力需要の変動の学習には不十分であり、6年目のデータを学習することで予測精度に大きく貢献したと考える。ある程度の変動を捉えてくると、さらなる追加データによる改善は緩やかになり、いずれ改善の限界に達することも考えられる。

気象データだけでは、学習曲線を見ると NN の学習はうまくいかなかった。ラグ特微量も追加することで、学習が順調に進むようになった。その結果、電力需要実績値と暦データの2種類を入力した際の RMSE の9割近くの改善が見られた。

気象要素と地点数に関しては、2地点の気温データを入力データにするのが精度向上に最も効果的であった。そのため、全ての気象要素を用いるのではなく厳選することが重要であり、気象地点は複数設定する方が精度向上に寄与すると考えられる。

気象データを全て含めた場合は予測精度が悪かったため、風向と天気データを排除し、地点数を1から3つに変化させて追加の予測を行った。

その結果、1地点の5つの気象データを入力した際の RMSE が最も低かった(34.4425)。地点数が少ない場合は、複数の気象要素が必要だと考える。

最後に、通年の気象要素の条件は把握できたが、月ごとに適した気象要素は把握できていない。そこで、精度が高い7モデルを使用し、月ごとの予測精度を比較した。概して、冬は1地点の気温、春は2地点の気温、夏は3地点の気温、秋は1地点の5つの気象データが入力データに適していることが示された。月ごとに最適な入力データ構成が異なるといえる。

4. 結 言

本研究によって、予測精度向上に寄与する最適な入力データ構成の条件を探索することを達成できた。データ量の確保、ラグ特微量の追加、複数地点の気温の入力が入力データ構成の条件として重要であると示された。データ量の増加は精度向上に繋がるが、徐々に改善率が下がったため、限界があると考えられる。ラグ特微量は、学習の安定化をもたらした。気象要素と地点数に関しては、月ごとで最適な組み合わせが異なることが明らかになった。季節に応じてモデルを切り替えて運用することが求められる。

今後の展望として、データ量の更なる拡充とそれによる改善が続くかを検証する必要がある。それは、データ量の増加により精度向上はみられたものの、その改善幅は縮小傾向にあり、精度が収束する点を明らかにできていないためである。ラグ特微量の時間指定の範囲は固定で行ったため、さらなる工夫が可能である。本研究で得られたデータ構成の地見を活かして、最新の深層学習モデルや記憶機能を持つ高度なモデルを使用することで、精度向上を目指すことも考えられる。

文 献

- [1] 一般財団法人日本エネルギー経済研究所: エネルギー安定供給確保の指針としてのエネルギー長期見通し(2025), <https://eneken.iecej.or.jp/data/12677.pdf>
- [2] 経済産業省資源エネルギー庁: エネルギー白書 2025
- [3] 近藤海夏斗: 深層学習による翌日電力需要予測手法の検討, 電子情報通信学会, 2022 年情報科学技術フォーラム, (2022)
- [4] 柴田智文: 人工ニューラルネットワークによる電力需要予測の影響要因評価(1)学習条件による影響, エネルギー・資源学会論文誌, (2019)
- [5] 大谷公哉: 人工ニューラルネットワークによる電力需要予測の影響要因評価(2)地域特性による影響, 第 35 回エネルギーシステム・経済・環境コンファレンス, (2019)