

気象データを用いた電力消費量予測精度の改善 Improvement of power-consumption-prediction accuracy by using weather data

猪股 海夏斗[†] 内保 光太郎[‡] 西山 英治[†] 新谷 洋人[†]
Minato Inomata Kotaro Uchiho Eiji Nishiyama Hirohito Shintani

1. はじめに

パリ協定により可決された CO₂ 削減目標の達成に向けて、近年太陽光パネルの導入が増加している。太陽光パネルは、出力が不安定な電源に該当しており、エリアの電力需要は、太陽光の出力により変動するため、電力システムの同時同量の達成に大きな影響を与えることになる。

また、現在発電事業者及び小売電気事業者は、毎日翌日の発電・需要の計画を電力広域的運用推進機関 (OCCTO) へ提出している。これらの計画と実績の差をインバランスといい、インバランスに比例した金額を精算している。このことから太陽光発電の出力を含めたエリアの電力需要予測が確立されると、需給管理が容易となり、電力システムの安定と収益の増加に寄与する。

本研究では、QRNN (Quasi-Recurrent Neural Network) [1] の手法を使い、データセットとして電力消費量及び気象データを用いることで、電力需要予測の精度向上を図った。

2. 研究方法

2.1 予測手法

2.1.1 QRNN

本研究では、QRNN モデルを利用した時系列データ予測を実施した。従来の時系列データに用いられていたモデルの一つである RNN (Recurrent Neural Network) は、性質上、1 データずつ処理しなくてはならない。そのため、並列演算に不向きであるというデメリットが存在する。QRNN では、時系列データを複数時刻分同時入力し、CNN (Convolutional Neural Network) を用いて疑似的に時間軸方向に関係性を持たせプーリングを行うことで、各ユニットの独立性を担保する。これにより RNN に比べ学習を高速化することを可能とし、RNN と同等もしくはそれ以上の精度を示す事例が報告されている [2]。

2.2 検証データ

2.2.1 電力消費データ

今回の検証では QRNN を用いて、関西電力の供給エリアにおける電力需要の予測を行った。予測するにあたり関西電力が公開している電力需要データを用いた。データの期間は 2013 年 1 月 1 日から 2020 年 12 月 31 日までのデータを 30 分ごとで抽出してデータセットを作成し、学習を行った。

2.2.2 気象データ

気象データは、関西電力が電力を供給している 6 府県 (京都府、大阪府、滋賀県、兵庫県、奈良県及び和歌山県) の県庁所在地のデータを用いた。なお、気象データについては 1 地点 (大阪府) のみ加えた場合と、6 地点全て加える場合の 2 通りで学習を行った。

[†] 熊本高等専門学校 National Institute of Technology, Kumamoto College

[‡] 日本経済大学 Japan University of Economics

2.2.3 曜日・時間帯データ

以下図 1 は、今回使用した電力消費データの各曜日及び日中 (6 時~18 時)・夜間 (18 時~翌 6 時) の平均をグラフにしたものである。図 1 から、平日と休日及び、日中と夜間で需要に差が生じていることが読み取ることができる。また、祝日や年末年始においても休日と同様の需要の低下が起きており、平日を 1、休日・祝日を 0 とするフラグデータ及び、日中を 1、夜間を 0 とするフラグデータをデータセットに追加した。




図 1 曜日及び時間帯における平均値

3. 検証方法

3.1 データセット

今回は検証として、1 点先 (30 分後) の予測を行った。また、データの前処理は、電力消費データ及び気温データを標準正規分布にて標準化、日照時間は、最小値を 0、最大値を 1 になるよう正規化を行った。

今回の検証では、2013 年から 2019 年の 7 年分を学習データ、2020 年をバリデーションデータとして用いた。

QRNN には、連続した 48 点分 (1 日) のデータを入力し、30 分後の電力需要を出力するよう学習を行った。また、電力消費データのみを加えた場合と各種データを加えた場合の予測結果を比較するため、以下表 1 のようにデータセットを設定した。

表 1 比較に用いたデータセット

No.	入力データ
1	電力データのみ
2	電力データ及び気温データ (1 地点)
3	電力データ及び気温データ (6 地点)
4	電力データ及び日照時間データ (1 地点)
5	電力データ及び日照時間データ (6 地点)
6	電力データ及び曜日データ
7	電力データ及び時間帯データ

3.2 評価指標

予測結果の評価指標として誤差を百分率で考慮する MAPE (Mean Absolute Percentage Error) を用いた。

$$MAPE = 100/N \sum_{i=1}^N |y_i - \hat{y}_i / y_i| \quad (1)$$

(y : 実績値、 \hat{y} : 予測値、 N : データ数)

4. 検証結果及び考察

4.1 検証結果

以下の表 2 に各データセットによる予測結果を示す。

表 2 予測結果

データセット	MAPE[%]	誤差最大[%]
電力のみ	1.32	10.23
電力+気温 (1 地点)	1.33	8.93
電力+気温 (6 地点)	1.69	9.95
電力+日照時間 (1 地点)	1.28	11.92
電力+日照時間 (6 地点)	1.35	10.87
電力+曜日	1.19	10.64
電力+時間帯	1.06	8.22

表 2 より時間帯データを加えた場合が最も精度が高くなった。また、気温、日照時間データを加えた場合は電力消費データのみの場合と大きな変化はなく、地点数を増やすと精度の悪化が見られた。このことから、地点数の多さが精度向上につながるわけではないことがわかった。

4.2 考察

4.2.1 気象データを加えた場合

以下の図 2 に 2020 年度における電力消費データと大阪市の気象データの散布図を示す。

図 2 (a) は電力消費と気温データの散布図であり、図中に示す黒の破線を境にデータ間の傾向が変化している。この境界がおよそ 18°C になっており、気温による冷暖房の使用増加の影響が表れていると考えられる。今回の検証では時系列順にデータを入力しているため、この傾向の違いが学習しづらくなっていると考えられる。

また、図 2 (b) は電力消費と日照時間データの散布図であり、この図からデータ間の傾向があるとは言えず、入力データとして適していない。




図 2 電力消費及び気象データの散布図

4.2.2 曜日データを加えた場合

図 3 は曜日ごとの MAPE をグラフ化したものである。図 3 において、月曜日から金曜日については誤差の減少がみられるが、休日にあたる土曜日及び日曜日については誤差の減少が見られなかった。今回はデータを時系列で入力している。例えば土曜日を予測する際には、前日が金曜日である。そのため、電力需要が高い日のデータを用いて需要の低い日を予測していたため、誤差が大きくなっていたと考えられる。

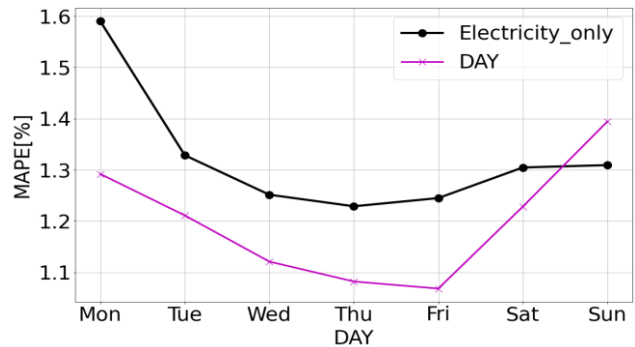


図 3 曜日ごと MAPE

4.2.3 時間帯データを加えた場合

図 4 は 1 時間ごとの MAPE をグラフ化したものである。図 4 より時間帯データを加えることで、ほぼ全ての時間で誤差が減少しており、夜間は 0.24%、日中は 0.28% 減少した。このことから、時間帯データを加えることで需要の変化の学習がしやすくなったといえる。

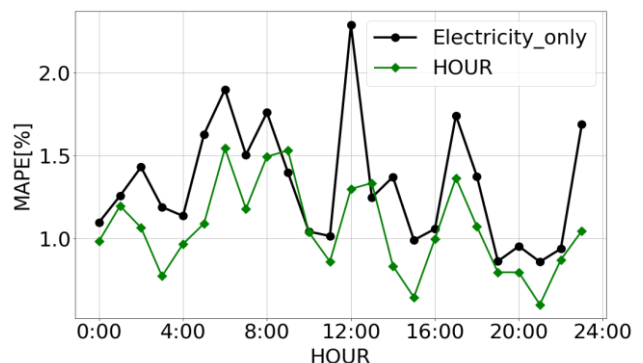


図 4 1 時間ごとの MAPE

5. 結論・まとめ

予測手法として QRNN を用いて、電力消費データ、気象データ、そして曜日・時間帯データをデータセットとして比較検証したところ、電力消費データと時間帯データを入力した場合が最も誤差率が小さく、MAPE で 1.06%、誤差最大で 8.22% であった。

また、気象データを加えた場合、地点数を増やしたとしても精度の向上につながらないことがわかった。

今回の検証では、30 分後の予測を行ったが、翌日分 (48 点分) を予測するように学習を行う場合について、今後検証を行う。また、関西電力供給エリア以外の地域についても比較検証並びに転移学習の可能性について検討を行う。

参考文献

[1],[2] J. Bradbury, "Quasi-Recurrent Neural Networks", ICLR2017, (2017)