

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

Evaluation of Factors Influencing Power Demand Forecast by Artificial Neural Network (2) Influence of Regional Characteristics

大谷 公哉 *・柴田 智文 *・寄田 保夫 *

Kimiya Otani

Tomofumi Shibata

Yasuo Yorita

川上 恭章 *・永富 悠 *・松尾 雄司 *

Yasuaki Kawakami

Yu Nagatomi

Yuji Matsuo

In this paper, we attempted to predict power demand in the next day using artificial neural network. This Short-term load forecasting (STLF) has become an active and important research topic with the recent rapid advancement of computers data processing capabilities. The model used in this verification performs the principal component analysis on the daily load curve, and it showed roughly good predictive performance in the previous study. In this study, in order to analyze the influence of the difference in the number of weather data points and in the learning method, we verified while changing these factors. Although prediction accuracy was not improved in all regions, at least we were able to obtain verification results that MAPE (Mean Absolute Percentage Error) improves by 0.2% or more in Tohoku Electric Power Company. We introduce this as an example of a technique for improving the accuracy of power demand prediction using an artificial neural network.

Keywords : Artificial neural network, Power demand forecast

1. はじめに

近年人工知能(Artificial Intelligence: AI)の進化が著しく、専門家のみならず広範な人々の関心を惹くに至っている。中でも注目を集めているのは人工ニューラルネットワーク(Artificial Neural Network: ANN)と呼ばれる手法である。深層への学習を効率的に行う多層のANNは「ディープラーニング」の手法とも呼ばれ、大量のデータを学習することで人間以上の能力をも発揮し得るものである。

先行研究ではANNによる日負荷曲線に主成分分析を行う短期の電力需要予測モデルを作成し、それを用いて国内の10電力供給区域ごとに予測を行い、概ね良好な予測性能を得た。モデルの予測性能は対象とするデータセットによって大きく変化するものであり、ある一つのデータセットで良い性能を示す手法が、他のデータセット、例えば同じ地域であったとしても異なる季節の電力需要を必ずしも精度良く予測できるとは限らない。

先行研究で用いたモデルはそれなりに高い予測性能を有すると思われたものの、過去の電力需要値と暦データの他に、域内の1地点のみの気象データ(天気概況及び最高・最低気温)を予測に用いる簡素なモデルであり、これが「最良」のものであると主張するものでは決してない。

本稿では、予測に用いる気象データの地点数等が予測性能にどのような影響を与えるかについて評価した。

2. 人工ニューラルネットワーク(ANN)を用いた短期電力需要予測モデル

ANNは入力のベクトルと目標値(スカラーまたはベクトル)との間の非線形な関係を、多量のデータを用いて機械に学習させる手法の一つである。その概念図は図2-1のように表される。

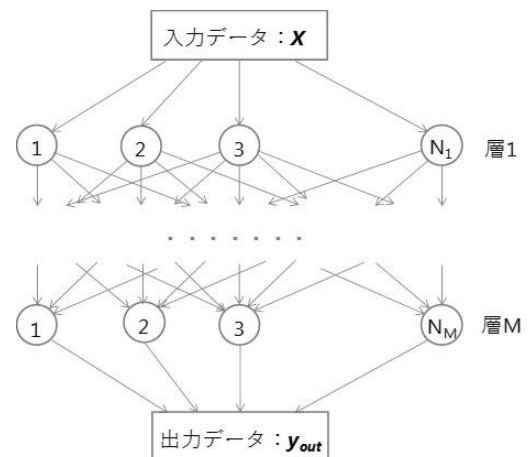


図 2-1 多層人工ニューラルネットワークの概念図

*一般財団法人日本エネルギー経済研究所
〒104-0054 東京都中央区勝どき 1-13-1 イヌイビル・カチドキ

ここでは、入力層と出力層の間にM層の中間層(隠れ層)が設定され、n番目の層はN_n個のノード(ニューロンと呼ばれる)によって構成される。このモデルに対して入力データXと出力データYとの多数の組を与えてモデルを「学習」させた上で、更に新たな入力データX_Fを与えることにより、未知の値Y_Fを推定しようとする試みがANNによる将来予測である。

本試算に用いたモデルでは電力会社の実際の運用を想定し、d日の朝、具体的には午前8時以前にd+1日の電力需要の24時間値を予測することを試みた。即ち利用可能なモデルへの入力データは全ての日の暦データ(年、月、日、曜日及び祝日)の他に、d日の朝7時までの電力需要実績値と、d-1日までの気象データ(天気概況及び最高・最低気温)実測値、並びにd日朝時点を得られる翌日までの気象予報データである。先行研究では旧一般電気事業者の本社・本店の所在地1地点のみの気象データを利用しており、本稿ではこの気象データの地点数および学習条件を変化させることによる予測結果への影響度について評価を行った。

3. 使用データの概要及び試算条件

3.1 電力需要データ

本分析ではANNを用いて北海道電力、沖縄電力を除く旧一般電気事業者各社管内8地域における電力需要の予測を行った。分析にあたっては各社が公表した電力需要データを用いている。用いたデータの期間等を表3-1に示す。基本的には2012年1月1日から2018年6月30日までのデータを用いてモデルの学習・検証・評価等を行っている。

表3-1 電力需要データ一覧

地域	収録期間	データ 日数	データ 欠損日数
東北電力	2012/1/1-2018/6/30	2,341	32
東京電力	2012/1/1-2018/6/30	2,344	29
中部電力	2012/1/1-2018/6/30	2,336	37
北陸電力	2012/1/1-2018/6/30	2,345	28
関西電力	2012/1/1-2018/6/30	2,347	26
中国電力	2012/1/1-2018/6/30	2,303	70
四国電力	2012/1/1-2018/6/30	2,372	1
九州電力	2012/1/1-2018/6/30	2,368	0

(出所) 各社HP, 公表資料より作成

3.2 気象データ

先行研究では気象データとして、旧一般電気事業者の本社・本店の所在となる各都市について、気象庁が公表する実績データ及び予報データを用いた。ここでは天候を示す変数(その日の天気概況が「晴」「曇」「雨」「雪」の各文字を含むか否か)及び最高気温・最低気温の値を用いている。

今回は地点数を増やした場合について検証を行った。また、表3-2に示す経済産業省が公表している都道府県毎の電力需要を基に数式(1)を用いて算出した加重平均値(Weighted Average Value: WAV)を学習させた場合についても検証を行った。ここでW_nは気象データ、P_nは電力需要量、nは気象データの地点数を表している。

$$WAV = \sum_n(W_n * P_n) / \sum_n P_n \quad (1)$$

表3-2 都道府県別電力需要データ(2018年4月:MWh)

東京電力	東京都	5,701,303	東北電力	新潟県	1,315,423		
	神奈川県	3,589,740		福島県	1,237,229		
	埼玉県	2,831,993		宮城県	1,147,098		
	千葉県	2,769,470		青森県	722,208		
	茨城県	1,945,300		岩手県	716,653		
	栃木県	1,294,734		秋田県	608,226		
	群馬県	1,255,402		山形県	658,504		
	静岡県	1,157,785		中国電力	広島県	1,565,669	
	山梨県	458,335			岡山県	1,291,986	
	中部電力	愛知県			4,631,603	山口県	988,085
三重県		1,529,993	島根県		442,012		
長野県		1,247,921	鳥取県		293,742		
岐阜県		1,188,619	四国電力		愛媛県	668,407	
静岡県		1,157,785			香川県	570,521	
関西電力		大阪府			4,352,895	徳島県	469,846
		兵庫県			2,909,754	高知県	311,538
		京都府			1,168,010	九州電力	福岡県
		滋賀県		1,002,374	熊本県		881,634
		奈良県		512,755	鹿児島県		751,728
	和歌山県	481,737		大分県	682,406		
	北陸電力	富山県		875,042	長崎県		596,675
		石川県		747,365	宮崎県		561,667
		福井県	648,713	佐賀県	514,623		

(出所) 経済産業省

3.3 試算条件

2017年7月から2018年6月までの期間を対象とした予測を行い、その予測値を実績値と比較して予測誤差を評価した。ANN等によって予測を行う際には、その時点で得られているデータを学習データと検証データに分けて評価を行うことが一般的である。学習データは文字通りモデルを学習させるために用いられるデータであり、学習したモデルを検証し、ハイパーパラメータの設定などを行うためのデータが検証データである。本稿で示す手法では、選択的アンサンブル平均をとる際に検証データを用いており、予測期間直前の1ヶ月間を検証期間とした。例えば2018年2月の予測を行って予測誤差を評価する場合には、2012年1月から2017年12月までのデータを学習データ、2018年1月のデータを検証データとしてモデルの学習を行う。このようにして得られたモデルに対し、例えば1月31日朝時点で得られるデータを入力して2月1日の電力需要を予測し、2月1日朝時点で得られるデータを入力して2月2日の電力需要を予測し、・・・と繰り返すことにより2月28日までの需要を予測して、それらの予測値を実際の需要値と比較した。なお同じ構造のANN及び全く同じ学習データであっても、学習前の初期値（一般的には乱数で与えられる）によって異なる学習をするため、それによる予測値（従って予測性能）も異なるものとなる。このため本稿では初期値を変えて同一の計算を15回繰り返し、その予測誤差の平均値によって評価を行った。

3.4 予測性能の評価指標

予測性能を示す指標としては、次に示す平均絶対誤差率 (Mean Absolute Percentage Error: MAPE) を採用した。

$$MAPE = 1/n \sum_t |(f_t - y_t)/y_t| \quad (2)$$

ここで f_t は予測値、 y_t は実績値であり、 n は予測期間におけるデータの個数である。MAPEは誤差率(%)を示しており、異なる地域間での予測性能を比べるために有用である。

なお、先行研究時(気象データ1地点時)の平均誤差率MAPEを本稿検証の比較対象として表3-3に示す。

表 3-3 気象データ1地点における平均誤差率(MAPE)

	春	夏	秋	冬	平均
東北	1.22%	1.66%	1.21%	1.66%	1.44%
東京	1.90%	3.10%	1.86%	2.48%	2.33%
中部	2.01%	2.50%	2.17%	2.36%	2.26%
北陸	2.25%	2.74%	2.06%	2.83%	2.47%
関西	1.86%	2.87%	2.22%	2.26%	2.30%
中国	2.53%	3.18%	2.54%	2.67%	2.73%
四国	2.12%	2.62%	2.29%	2.84%	2.47%
九州	2.35%	3.06%	2.63%	2.82%	2.71%

4. 試算結果及び考察

4.1 気象データ2地点を学習させた場合の影響検証

ここでは表4-1の2地点の気象データを学習させた場合の影響評価を行う。地点1は、先行研究時に用いた旧一般電気事業者の本社・本店の所在地、地点2はランダムにピックアップした。

表 4-1 気象データ対象都市

地域	地点1	地点2
東北電力	仙台(宮城県)	新潟(新潟県)
東京電力	東京(東京都)	宇都宮(栃木県)
中部電力	名古屋(愛知県)	静岡(静岡県)
北陸電力	富山(富山県)	福井(福井県)
関西電力	大阪(大阪府)	京都(京都府)
中国電力	広島(広島県)	松江(島根県)
四国電力	高松(香川県)	高知(高知県)
九州電力	福岡(福岡県)	鹿児島(鹿児島県)




図 4-1 気象データ2地点時の MAPE 改善値

表 3-3 に示す気象データ 1 地点における MAPE に対する改善値を図 4-1 に示す。この改善値は正の場合は予測性能の向上を表し、負の場合は予測性能の低下を表している。

1 地点のときと比べ東北電力のみ年間を通じて予測精度が向上した。一方で、他の地域では夏季のみ予測精度が向上する傾向が確認できたものの、年間を通じては予測精度が変わらない、もしくは低下するという結果を示した。

4.2 2 地点の加重平均値を学習させた場合の影響検証

ここでは表 4-1 に示す 2 地点の気象データを、数式(1)を用いて算出された加重平均値(WVA)を、学習させた場合について検証した。表 3-3 に示す気象データ 1 地点における MAPE に対する改善値を図 4-2 に示す。

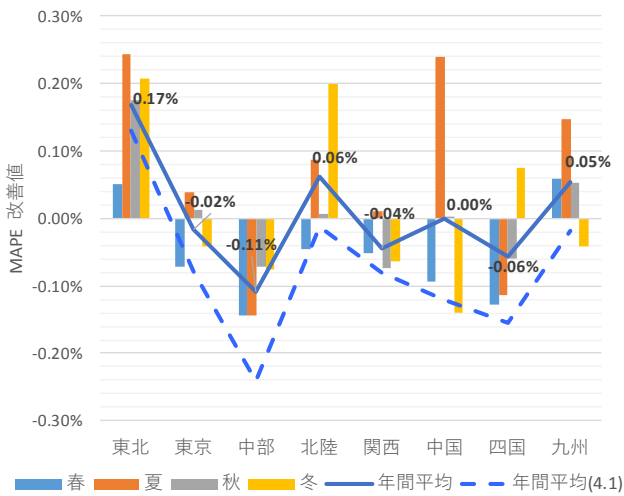


図 4-2 気象データ 2 地点(WVA)時の MAPE 改善値

1 地点のときと比べ東北電力、北陸電力、九州電力で予測精度が向上した。他の地域では、年間予測精度は向上しなかったものの、気象データを直接学習させた 4.1 の試算結果(図 4-2 破線)よりも良好な結果を示した。以上から、気象データを直接学習させるよりも、電力需要加重平均値を学習させた方が予測性能を向上させる可能性があると考えられる。

4.3 気象地点を増加させたときの影響検証

ここでは、これまでの試算で良好な予測精度改善が確認された東北電力管内において、地点数を表 4-2 に示す 5 地点まで増加させた場合の影響について検証を行った。

表 4-2 気象データ対象都市

地点 1	地点 2	地点 3	地点 4	地点 5
仙台	新潟	青森	福島	盛岡

気象データを直接学習させた場合を Case1、電力需要加重平均値を学習させた場合を Case2 として検証した。検証結果を図 4-3、4-4 に示す。




図 4-3 地点数による年平均予測誤差率(MAPE)の変化




図 4-4 地点数による予測誤差率(MAPE)の変化

図 4-3 から読み取れるように、東北電力管内での年平均誤差率は気象データ地点数を増やした方が低下する傾向が確認された。年平均誤差率は、Case1 では約 1.3%で収束、Case2 では約 1.2%で収束したことから、4-2 同様に加重平均値を学習させた方が良好な結果が得られたといえる。ただし、図 4-4 からは地点数を増やすことで予測誤差率が僅かに増加した月(4月、7月、9月、11月)も確認された。年間を通じての予測精度は気象データ地点数を増やすことで向上するものの、精度が低下するタイミングもあるという点については十分に留意しなければならない。

4.4 気象地点変更による影響検証

学習させる地点による影響を分析するために、東北電力管内について表 4-3 に示す 2 地点の気象データについて検証を行った。

表 4-3 気象データ対象都市

	地点 1	地点 2
Case1	仙台(宮城県:3位)	—
Case2	仙台(宮城県:3位)	新潟(新潟県:1位)
Case3	仙台(宮城県:3位)	福島(福島県:2位)
Case4	仙台(宮城県:3位)	青森(青森県:4位)
Case5	仙台(宮城県:3位)	盛岡(岩手県:5位)

()内は東北電力管内での電力需要順位(2018年4月)

これまでの検証から、加重平均値で学習させた方が気象データを直接学習させるよりも良好な結果が得られていたため、ここでは加重平均値による検証のみを行った。その結果を図 4-5 に示す。




図 4-5 気象地点による予測誤差率(MAPE)の変化

電力需要が最も大きい新潟県の気象データを学習させた場合には、最も高い予測精度を示した。対して興味深いのは、青森、盛岡の気象データを学習させた方が電力需要の大きい福島よりも高い予測精度が得られたという点である。福島は地点 1 の仙台と気象条件が比較的類似しているため、予測精度の向上は僅かであったが、気象条件の大きく異なる新潟、青森、盛岡の気象データを学習させることにより、大きな精度向上が得られたものと推察される。また、新潟の気象データを学習させた場合が、青森、盛岡よりも高い予測精度を示したことから、電力需要の大きさも重要な要素であると考えられる。

以上から、地点ごとの気象データの影響力は、電力需要

の大きさと気象条件の違いに対して相関性があり、電力需要が大きく且つ気象条件が異なる地点の気象データを優先的に学習させることで、予測精度が向上する可能性があると考えられた。

5. まとめ

本稿では国内の電力 8 供給区域を対象とし、簡易な人工ニューラルネットワークを用いて短期電力需要予測を試みた。気象データについての学習条件を変更し検証することで、以下の点について考察された。

- (1) 複数の気象データを学習させる場合には、直接気象データを学習させるのではなく、電力需要による加重平均値を算出し学習させた方が予測精度の向上が見込める可能性が高い。
- (2) 東北電力のように供給地域が広く、その域内で気象条件が大きく異なる場合には、気象データの学習地点数を増やすことで年間を通じての予測精度が大きく向上する可能性がある。一方で、複数地点の気象データを学習させることで、予測精度が低下する場合も確認されており、その点については十分に留意しなければならない。
- (3) 地点ごとの気象データの影響力は、電力需要の大きさと気象条件の違いに対して相関性があり、電力需要が大きく且つ気象条件が異なる地点の気象データを優先的に学習させることで、予測精度が向上する可能性がある。

今回検証した、学習させる気象データの変更は、人工ニューラルネットワークを用いた短期電力需要予測の精度を向上させるための手法の一例でしかない。今回用いたモデルに対し、湿度や 1 時間ごとの気温予報値等、より多種類の入力データを用いることや、選択的アンサンブルの試行回数を増やすことなどで更に予測性能を向上させることは可能であると考えられる。試行錯誤を繰り返し、工夫しながら改善を図ることが今後の重要な研究課題である。

参考文献

日本エネルギー経済研究所、「人工ニューラルネットワークを用いた短期電力需要予測— 国内 10 地域を対象とした検討 —」