

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

2019年1月

一般財団法人日本エネルギー経済研究所

○大谷 公哉、柴田 智文・寄田 保夫・
川上 恭章・永富 悠・松尾 雄司

研究目的および検証結果

研究目的

- 人工ニューラルネットワーク（ANN）を用いた電力需要予測モデルの予測性能の向上および気象条件の学習データが与える影響の検証

検証結果

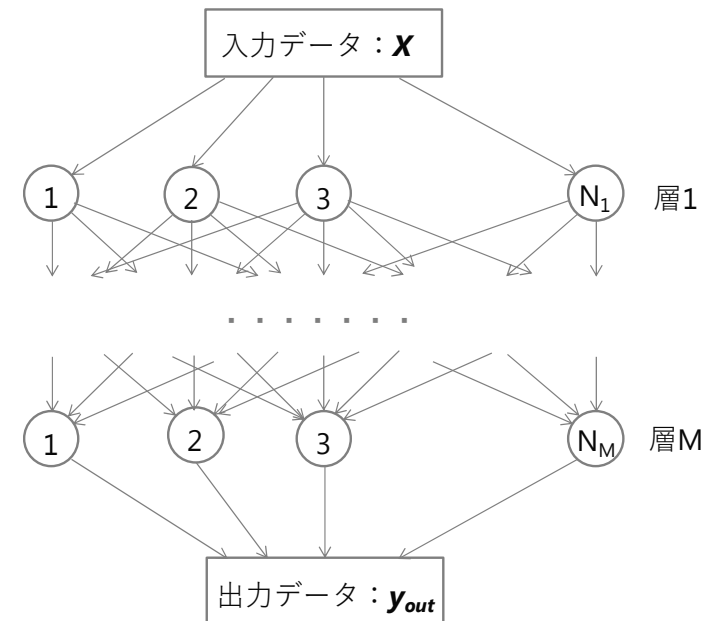
- 学習させるデータの種類や選定する地点によって異なる予測結果を示した。
- 気象データの地点数を増やすことで、予測精度が向上する傾向が確認された。中でも、東北電力管内では、MAPE（Mean Absolute Percentage Error）が最大0.2%改善され、比較的高い性能向上が確認された。

1-1 試算条件

- d日の午前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前提とする。
- 試算条件は以下の通り。
- 暦データは年、月、日、曜日及び祝日を表す。
- 気象データは天気概況(晴、雨、曇、雪)、最高温度、最低温度を表す。

入力データ x	d-1日：暦データ、電力需要(24時間)、気象データ(前日予報、実績) 主成分得点 d 日：暦データ、電力需要(0-7時)、気象データ(前日予報) d+1日：暦データ、気象データ(前日予報)
出力データ y	d+1日：電力需要(24時間)
中間層数 M	3層
ニューロン数 N	各層50個
試行回数 (選択的アンサンブル)	20回
予測期間	2017年7月~2018年6月

多層人工ニューラルネットワークの概念図



1-2 使用データおよび評価指標

- 電力需要データは旧一般電気事業者各社が公表している数値を使用。
- 気象データは気象庁の公表する天気概況、最高気温、最低気温の前日予報値、実績値を使用。
- 予測性能を示す指標には平均絶対誤差率(Mean Absolute Percentage Error: MAPE)を採用。

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
北海道	2012/1/1-2018/6/30	2,341	32
東北	2012/1/1-2018/6/30	2,341	32
東京	2012/1/1-2018/6/30	2,344	29
中部	2012/1/1-2018/6/30	2,336	37
北陸	2012/1/1-2018/6/30	2,345	28
関西	2012/1/1-2018/6/30	2,347	26
中国	2012/1/1-2018/6/30	2,303	70
四国	2012/1/1-2018/6/30	2,372	1
九州	2012/1/1-2018/6/30	2,368	0
沖縄	2016/4/1-2018/6/30	820	1

(出所) 各社HP、公表資料より作成，データの欠損は取得漏れ。

平均絶対誤差率 (MAPE)

$$MAPE = \frac{1}{n} \sum_t \left| \frac{f_t - y_t}{y_t} \right|$$

f_t : 予測値

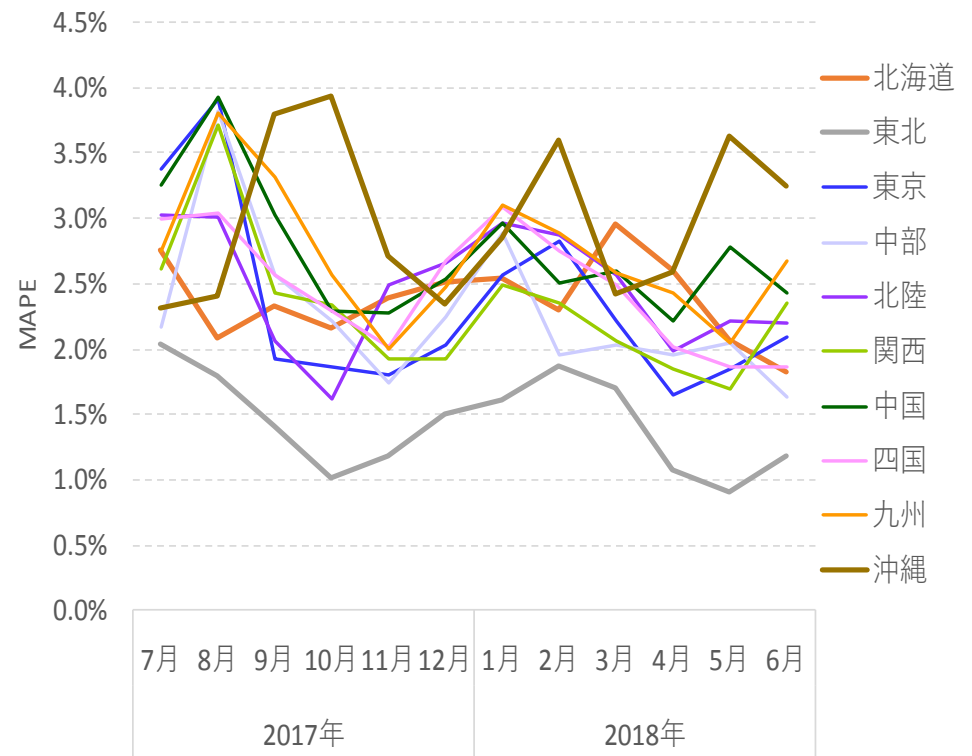
y_t : 実績値

n : 予測期間におけるデータの個数

1-3 気象データ1地点における予測結果


- 気象データの対象都市は電気事業者の本社・本店所在地。
- 春季4～6月、夏季7～9月、秋季10～12月、冬季1～3月。
- 冷暖房負荷の高い夏季、冬季は中間季(春季、秋季)に比べて性能低下が見られた。
- 年間を通じて平均MAPE 3%以下と概ね良好な結果が得られた。

	本社・本店所在地	MAPE				
		春	夏	秋	冬	年間平均
北海道	札幌	2.54%	2.22%	2.30%	2.45%	2.38%
東北	仙台	1.22%	1.66%	1.21%	1.66%	1.44%
東京	東京	1.90%	3.10%	1.86%	2.48%	2.33%
中部	名古屋	2.01%	2.50%	2.17%	2.36%	2.26%
北陸	富山	2.25%	2.74%	2.06%	2.83%	2.47%
関西	大阪	1.86%	2.87%	2.22%	2.26%	2.30%
中国	広島	2.53%	3.18%	2.54%	2.67%	2.73%
四国	高松	2.12%	2.62%	2.29%	2.84%	2.47%
九州	福岡	2.35%	3.06%	2.63%	2.82%	2.71%
沖縄	那覇	2.88%	2.66%	3.48%	2.94%	2.99%




1-4 気象データ1地点における予測結果

九州電力



北海道電力



2-1 気象データ2地点における影響検証(試算条件)


- 供給地域が1都道府県の北海道、沖縄は対象外とした。
- 気象データ対象都市を以下2地点とした(1地点目 本社・本店所在地、2地点目には位置、気象条件が比較的異なる場所を選定)。
- その他の条件は気象データ1地点時(1-1、1-2)と変更なし。

地域	地点1 (本社・本店所在地)	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)

2-2 気象データ2地点における影響検証(試算結果)

- 下のグラフは気象データ1地点時の試算結果(1-3)に対する改善値を表している。
- 正の場合は予測性能の向上、負の場合は予測性能の低下を表している。
- 夏季のみ性能向上が確認された地域もあるが、年間を通じて東北電力以外では性能が低下した。

	MAPE				年間平均
	春	夏	秋	冬	
東北	1.2%	1.5%	1.1%	1.5%	1.3%
東京	2.0%	3.0%	2.0%	2.7%	2.4%
中部	2.3%	2.7%	2.4%	2.6%	2.5%
北陸	2.3%	2.6%	2.1%	2.9%	2.5%
関西	2.0%	2.9%	2.3%	2.3%	2.4%
中国	2.7%	3.1%	2.7%	2.9%	2.8%
四国	2.4%	2.7%	2.6%	2.8%	2.6%
九州	2.4%	2.9%	2.7%	3.0%	2.7%



3-1 気象データ2地点(WVA)における影響検証(試算条件)

- 供給地域が1都道府県の北海道、沖縄は対象外とした。
- 検証2で選定した2地点の気象データを、地域別の電力需要を基に加重平均した値(Weighted Average Value : WAV)を使用した。
- 加重平均には、経済産業省が公表している都道府県別の電力需要データを使用した。
- その他の条件は気象データ1地点時(1-1、1-2)と変更なし。

都道府県別電力需要データ(2018年4月:GWh)

東北電力	新潟県	1,315	東京電力	東京都	5,701	関西電力	大阪府	4,353	九州電力	福岡県	2,418
	福島県	1,237		神奈川県	3,590		兵庫県	2,910		熊本県	882
	宮城県	1,147		埼玉県	2,832		京都府	1,168		鹿児島県	752
	青森県	722		千葉県	2,769		滋賀県	1,002		大分県	682
	岩手県	717		茨城県	1,945		奈良県	513		長崎県	597
	秋田県	608		栃木県	1,295		和歌山県	482		宮崎県	562
	山形県	659		群馬県	1,255		広島県	1,566		佐賀県	515
中部電力	愛知県	4,632	北陸電力	静岡県	1,158	中国電力	岡山県	1,292	四国電力	愛媛県	668
	三重県	1,530		山梨県	458		山口県	988		香川県	571
	長野県	1,248		富山県	875		島根県	442		徳島県	470
	岐阜県	1,189		石川県	747		鳥取県	294		高知県	312
	静岡県	1,158		福井県	649						

加重平均値WAV

$$WAV = \frac{\sum_n (W_n * P_n)}{\sum_n P_n}$$

W_n : 気象データ


P_n : 電力需要

n : 気象データ地点数

3-2 気象データ2地点(WVA)における影響検証 (試算結果)

- 下のグラフは気象データ1地点時の試算結果(1-3)に対する改善値を表している。
- 正の場合は予測性能の向上、負の場合は予測性能の低下を表している。
- 東北電力、九州電力、北陸電力管内では、年間を通じて予測性能が向上した。
- いずれも気象データを加工なしで学習させた2-2よりも高い性能を示した。

	MAPE				年間平均
	春	夏	秋	冬	
東北	1.2%	1.4%	1.0%	1.5%	1.3%
東京	2.0%	3.1%	1.8%	2.5%	2.3%
中部	2.2%	2.6%	2.2%	2.4%	2.4%
北陸	2.3%	2.6%	2.1%	2.6%	2.4%
関西	1.9%	2.9%	2.3%	2.3%	2.3%
中国	2.6%	2.9%	2.5%	2.8%	2.7%
四国	2.2%	2.7%	2.3%	2.8%	2.5%
九州	2.3%	2.9%	2.6%	2.9%	2.7%



4-1 気象地点増加時の影響検証(試算条件)

- これまでの試算で最も良好な予測精度改善が確認された東北電力において、気象データを以下表に示す5都市まで増加させた場合の影響を評価した。
- 気象データを直接学習させた場合をCase1、電力需要による加重平均値を学習させた場合をCase2として検証した。
- 加重平均には、経済産業省が公表している都道府県別の電力需要データを使用した。
- その他の条件は気象データ1地点時(1-1、1-2)と変更なし。


	地点1	地点2	地点3	地点4	地点5
都市 ()内都道府県	仙台 (宮城県)	新潟 (新潟県)	青森 (青森県)	福島 (福島県)	盛岡 (岩手県)
電力需要 (2018年4月 : GWh)	1,147	1,315	722	1,237	717

(出所)経済産業省


4-2 気象地点増加時の影響検証(試算結果)

- 年平均誤差率は、Case1では約1.3%で収束し、Case2では約1.2%で収束した。
- 3-2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。
- 地点数を増やすことで予測誤差率が僅かに増加した月も確認された。
- 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いけない。

地点数－年間平均MAPEの変化



Case2における地点数－MAPEの変化



5-1 気象地点変更による影響検証(試算条件)

- 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以下2地点の気象データを学習させた場合について検証を行った。
- 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。
- 加重平均には、経済産業省が公表している都道府県別の電力需要データを使用した。
- その他の条件は気象データ1地点時(1-1、1-2)と変更なし。


	地点1	地点2
Case1	仙台(宮城県 : 1,147GWh)	—
Case2	仙台(宮城県 : 1,147GWh)	新潟(新潟県 : 1,315GWh)
Case3	仙台(宮城県 : 1,147GWh)	福島(福島県 : 1,237GWh)
Case4	仙台(宮城県 : 1,147GWh)	青森(青森県 : 722GWh)
Case5	仙台(宮城県 : 1,147GWh)	盛岡(岩手県 : 717GWh)

(出所)経済産業省、()内 2018年4月の電力需要

5-2 気象地点変更による影響検証(試算結果)

- 電力需要が最も大きく、1地点目の仙台と気象条件の異なる新潟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。
- 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。
- 地点ごとの気象データの予測精度に与える影響力は、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ると考察された。

		MAPE				
		春	夏	秋	冬	年間平均
Case1	仙台	1.22%	1.74%	1.24%	1.73%	1.44%
Case2	仙台 新潟	1.17%	1.43%	1.17%	1.51%	1.27%
Case3	仙台 福島	1.29%	1.70%	1.14%	1.71%	1.40%
Case4	仙台 青森	1.14%	1.58%	1.16%	1.61%	1.34%
Case5	仙台 盛岡	1.21%	1.61%	1.20%	1.62%	1.35%



まとめ

- ❑ 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。
- ❑ 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。
- ❑ 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。

ご清聴ありがとうございました