

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

2019年1月30日

第35回エネルギーシステム・経済・環境コンファレンス

一般財団法人日本エネルギー経済研究所

柴田 智文・大谷 公哉・寄田 保夫

川上 恭章・永富 悠・松尾 雄司

研究内容および検証結果

研究内容

- 本研究では人工ニューラルネットワーク（ANN）を用い、主成分分析（PCA）によって電力日負荷曲線を分析するとともに、選択的アンサンブル平均を用いる方法によって短期電力需要予測を行い、その性能を評価した。
- また、ニューロン数、層数、選択的アンサンブル試行回数、活性化関数を変化させた場合、学習データに湿度データや気温24時間値を加えた場合など、各種学習条件が予想精度に与える影響について検討した。

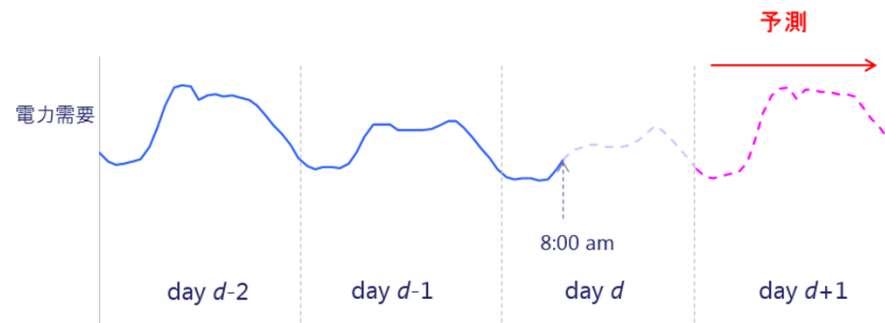
主な検証結果

- 主成分分析・選択的アンサンブル平均を実施することにより単純なANNによる予測よりも予想精度が改善する。
- 学習データに湿度を加えた場合、8・9月の予想精度に改善が見られる一方、通年の予想精度は悪化した。
- 気温予報データについて、最高・最低気温データに代えて、24時間予報値を利用し試算することで予報精度が改善する可能性がある。

予測方法の詳細

電力会社は日々の需給運用のために、短期電力需要予測(Short Term Load Forecasting: STLF)を常に行っている。正確な予測は安定的かつ効率的な電力供給のために極めて重要である。

本研究では人工ニューラルネットワーク(**Artificial Neural Network: ANN**)を用いた電力需要予測を試みる。ここでは中部電力管内を対象として、予測日(d+1)の前日(d)朝8時時点で得られているデータのみをもとに、d+1日の電力負荷曲線(電力需要の24時間値)を予測する。電力需要は24時間周期で変動することから、1日の電力負荷曲線の形状に関する分析を明示的に織り込み、予測性能の向上を目指す。

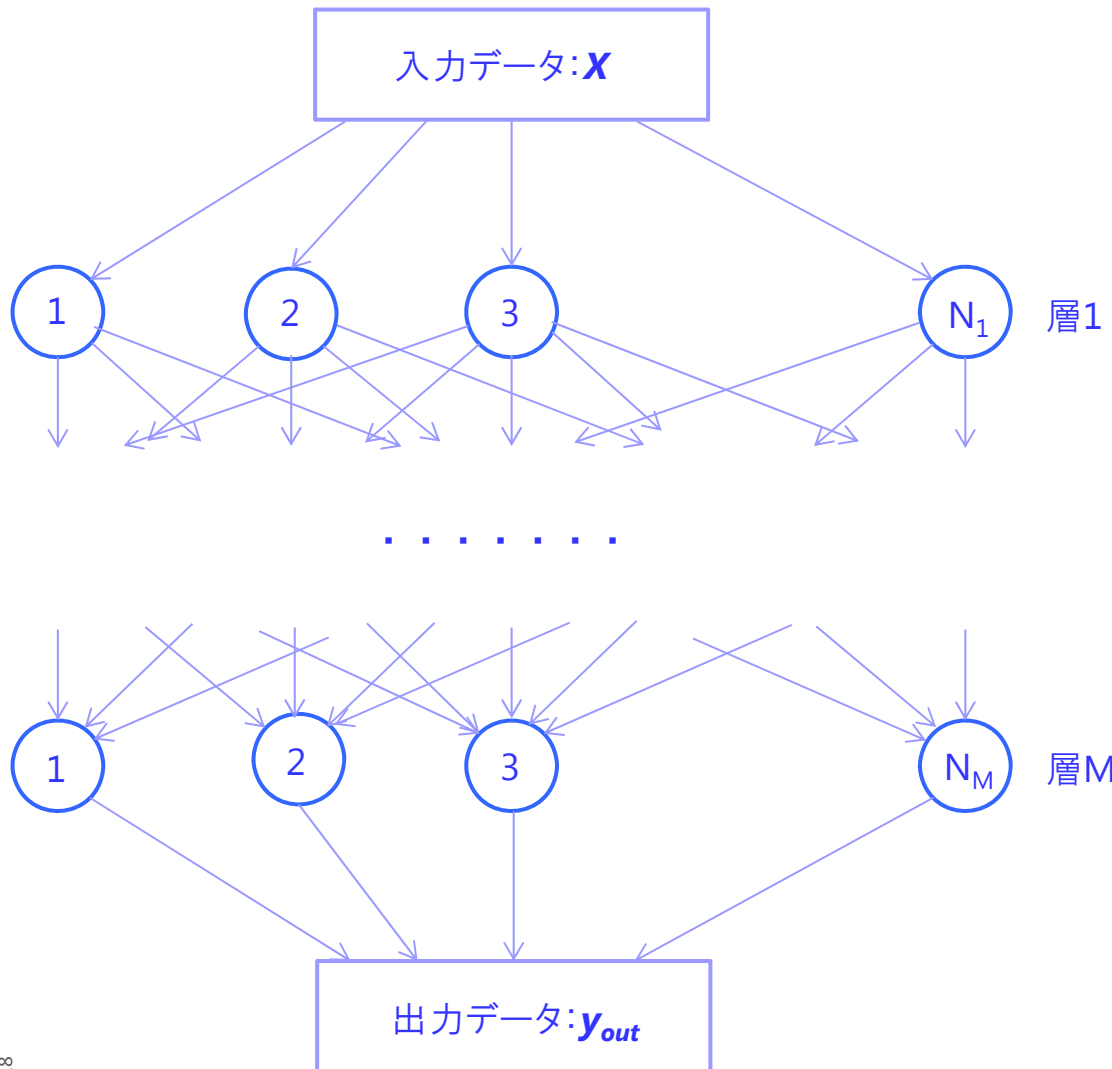


電力需要データ一覧

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。

人工ニューラルネットワーク (ANN) について



人工ニューラルネットワークは入力データ \mathbf{X} と出力データ \mathbf{y}_{out} との非線形の関係性を、 M 層の「隠れ層」によってモデル化する手法である。各層は N_n 個 ($n = 1, 2, \dots, M$) の「ニューロン」から成り立っている。

いま、各層が N_n 次元のベクトル \mathbf{y}_n で表されるとし、 \mathbf{y}_{n+1} と \mathbf{y}_n の間に関係式

$$\mathbf{y}_{n+1} = f(\mathbf{w}_n \mathbf{y}_n + \mathbf{b}_n)$$

が成り立つとする。このとき、入力データ $\mathbf{X} = \mathbf{y}_0$ から出力データ $\mathbf{y}_{M+1} = \mathbf{y}_{out}$ を逐次求めることができる。

ここで f は活性化関数と呼ばれる非線形の関数であり、 \mathbf{w}_n と \mathbf{b}_n はウェイト・バイアスと呼ばれる定数である。

ここではまず、1) \mathbf{w}_n 及び \mathbf{b}_n の初期値を(多くの場合乱数によって)設定し、その上で2) 入力データ \mathbf{X} と出力データ \mathbf{Y} の多数の組により、予測誤差 $|\mathbf{Y} - \mathbf{y}_{out}|^2$ を最小化するように \mathbf{w}_n と \mathbf{b}_n を決定する(「学習」と呼ばれる)。

モデルの入力データ及び出力データ

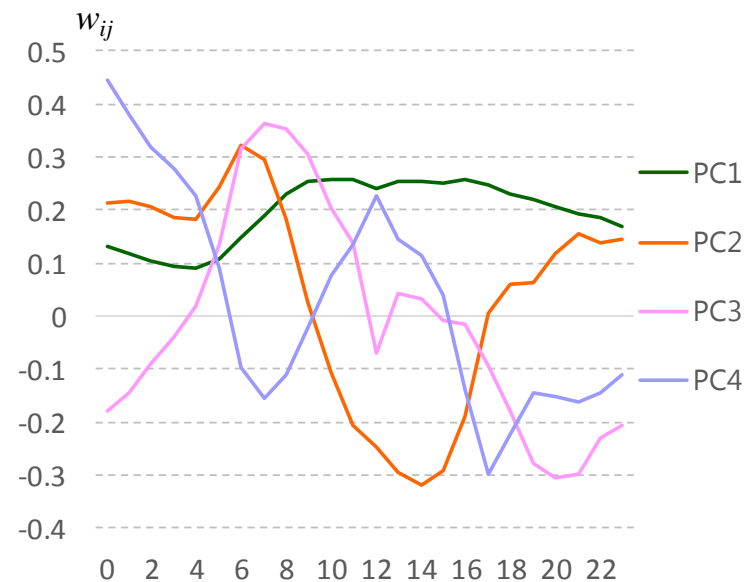

入力データ (X)

	電力需要(24時間値: $t = 0, 1, \dots, 23$)
Day $d-1$	気象データ: 最高気温、最低気温、天気概況(晴・曇・雨・雪) 暦データ(年、月、日、曜日、祝日) 主成分得点
Day d	朝7時までの電力需要($t = 0, 1, \dots, 7$) 暦データ(年、月、日、曜日、祝日) 気象庁による天気予報: 最高気温、最低気温、天気概況(晴・曇・雨・雪)
Day $d+1$	暦データ(年、月、日、曜日、祝日) 気象庁による天気予報: 最高気温、最低気温、天気概況(晴・曇・雨・雪)

出力データ (y)

Day $d+1$	電力需要(24時間値: $t = 0, 1, \dots, 23$)
-----------	-------------------------------------

主成分分析 (Principal Component Analysis: PCA)



電力需要は各主成分(ここでは第4主成分まで)の線形結合によって近似することができる。

$$L(d) = a_1(d)z_1 + a_2(d)z_2 + a_3(d)z_3 + a_4(d)z_4 + z_0$$

a_i : 主成分得点、 z_0 : 平均負荷曲線

ここではまずd+1日の主成分得点 a_1, \dots, a_4 を予測し、それを用いて近似曲線を得た上で24時間値を予測する。

$$\text{PC1: } z_1 = w_{11}y_1 + w_{21}y_2 + \dots + w_{p1}y_p$$

$$\text{PC2: } z_2 = w_{12}y_1 + w_{22}y_2 + \dots + w_{p2}y_p$$

$$\text{PC3: } z_3 = w_{13}y_1 + w_{23}y_2 + \dots + w_{p3}y_p$$

$$\text{PC4: } z_4 = w_{14}y_1 + w_{24}y_2 + \dots + w_{p4}y_p$$

各主成分の因子寄与率(PV):

PV1: 0.879, PV2: 0.087, PV3: 0.015, PV4: 0.012

選択的アンサンブル平均法

選択的アンサンブル平均(Zhou et al., 2002)

複数のモデルを作成し、その平均値等を予測値とすることによって予測性能の向上を図る手法は一般的にアンサンブル平均法、もしくはアンサンブル学習法などと呼ばれている。バギング・ブースティングなどさまざまなアンサンブル学習法が提案されている。

Zhou et al. (2002) は複数のモデルを作成したのち、それらの**全てではなく一部**のみを用いてアンサンブル平均をとることにより、全てを用いる場合よりも予測性能が向上し得ることを示した。

本研究での選択的アンサンブル平均法

短期電力需要予測においては、**検証データを予測期間の直前にとった場合にのみ**、検証データの誤差と予測誤差とが有意に相関する(=過去1ヶ月で良い予測性能を示したモデルは、そうでないモデルに比べて、近い将来をよりよく予測することが期待できる)。

この性質を利用して、本研究では乱数を用いた初期値から**複数個のモデルを作成した上で、その中で検証誤差の小さいもの(3個程度)を選択し、それらの平均値をもって予測値とした。**

予測
誤差

検証誤差

評価指標 (Principal Component Analysis: PCA)

平均自乗誤差 (Root mean square error : RMSE) ・ ・ ・ 単位 : GW

$$RMSE = \sqrt{\frac{1}{n} \sum_t (f_t - y_t)^2}$$

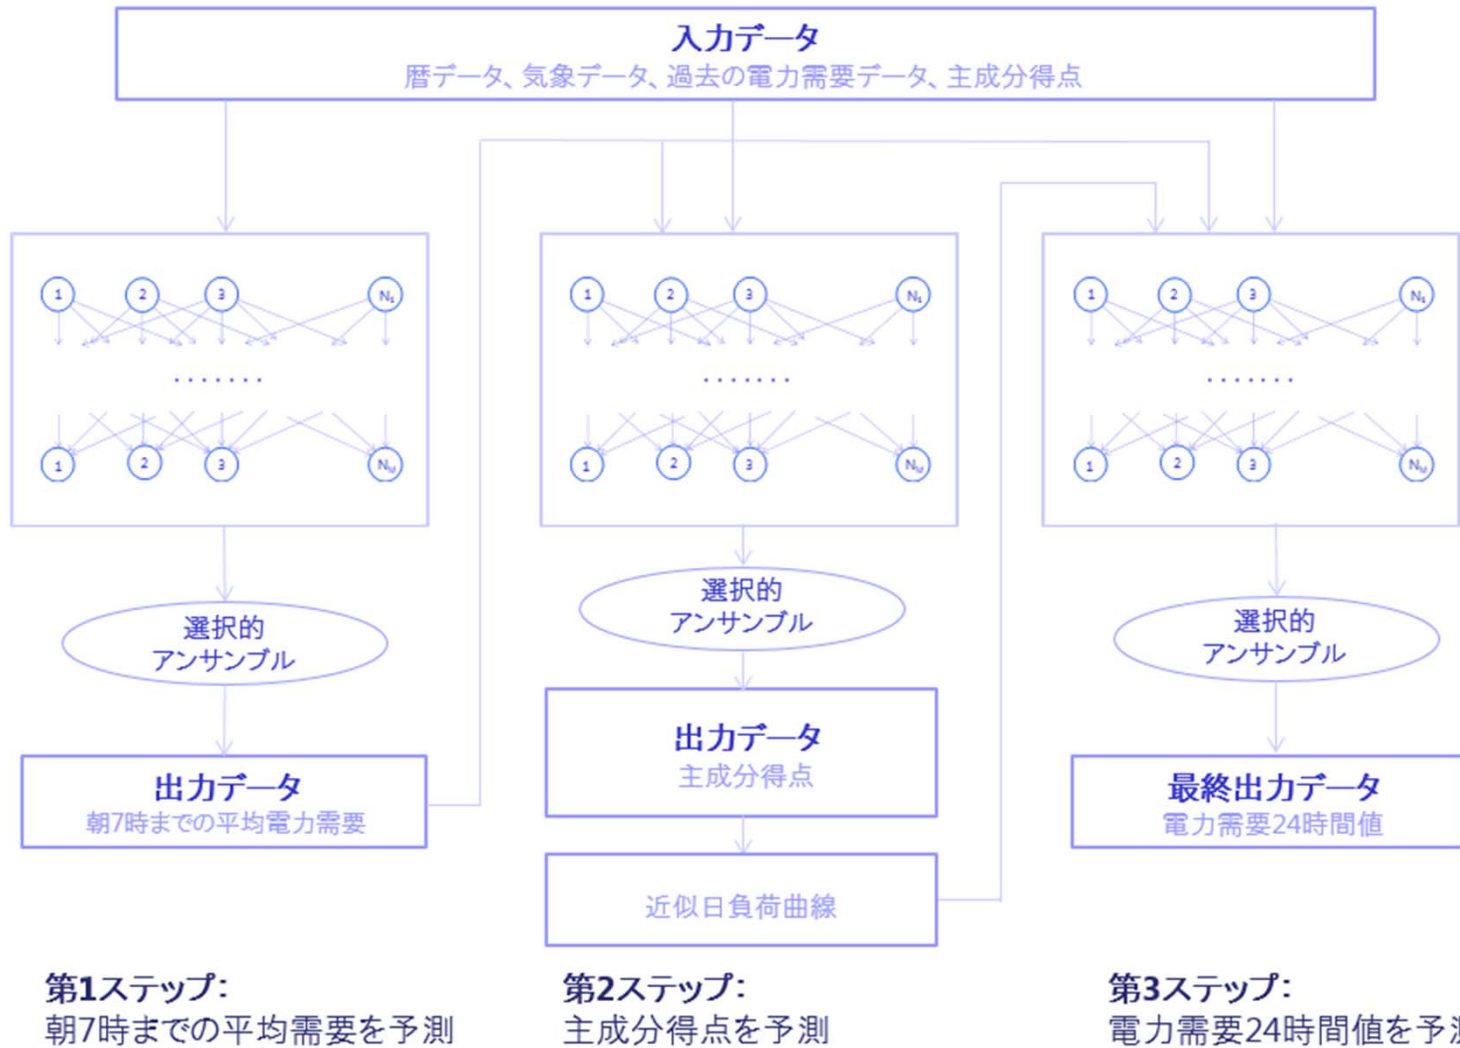
絶対平均誤差率 (Mean absolute percentage error : MAPE) ・ ・ ・ 無単位 (%表示)

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



f_t : 予測データ

y_t : 実測データ





予測手法：3ステップによる予測







各モデルの試算結果 (4月)



各モデルの試算結果 (8月)






各モデルの試算結果 (12月)



ニューロン数及び選択的アンサンブル試行回数によるMAPEの変化

ニューロン数 N の変化

ニューロン数 N の差 ($N=10 \cdot 20 \cdot 30 \cdot 50 \cdot 70 \cdot 100$) による誤差率の変化は以下のとおり。ここでは活性化関数は Softplus、選択的アンサンブル平均の試行回数 nT は $1 \cdot 5 \cdot 10 \cdot 20 \cdot 50$ 回としている。



○MAPE最小となる N の値は、4月に10、8月及び12月に50となった。

→予測がより複雑であり、MAPEが悪化する8月や12月には概ね $N=50$ 近傍で予測性能が改善。一方、予測がより単純で、より正確な予測が可能な4月は、小さな N でも十分現象を評価可能。


○アンサンブル試行回数を増やすにつれ予想精度は改善するも、その効果は逓減的。

ニューロン数及び層数によるMAPEの変化

層数 M の変化

層数 M の差による誤差率の変化は以下のとおり。ここでは活性化関数はSoftplus、選択的アンサンブル平均の試行回数 nT は20回、 $N=50$ としている。

層数 M と MAPE の推移



$M=3\sim 6$ では、MAPEに大きな変化はない一方、 $M=8\cdot 10$ では、MAPEが大幅に悪化する傾向が見られた。

活性化関数によるMAPEの変化

活性化関数をsoftplus関数から、正規化線形関数(ReLU)に変更した場合の変化は以下のとおり。選択的アンサンブル平均の試行回数 nT は20回、 $N=50, M=3$ としている。

N	4月		8月		12月	
	MAPE	差分	MAPE	差分	MAPE	差分
10	1.90%	0.06%	3.80%	-0.02%	2.51%	0.09%
20	1.89%	0.01%	3.82%	-0.06%	2.34%	-0.03%
30	1.90%	-0.06%	3.81%	0.01%	2.37%	0.06%
50	2.16%	0.27%	3.87%	0.12%	2.35%	0.22%
70	2.07%	0.20%	3.86%	0.20%	2.63%	0.43%
100	2.11%	0.22%	3.92%	0.08%	2.57%	0.41%

ソフトプラス関数を用いた予測と比較すると、多くの N においてMAPEが悪化した。

まとめと今後の課題

まとめ

- (1) 既往論文において示された通り、主成分分析および選択的アンサンブル平均を実施することにより、単純なANNによる予測よりもMAPEが改善すると考えられる。
- (2) MAPE最小となる最良な予想結果が得られるニューロンの個数は、予測対象となる月によって異なる可能性がある。予測がより複雑であり、MAPEが悪化する8月や12月には概ね $N=50$ 近傍で予測性能が最も良くなることを示している。一方で予測がより単純で、より正確な予測が可能となる4月には、より小さな N でもモデルが十分によく現象を評価できるものと考えられる。
- (3) 異なる層数の比較では、 $M=3\sim 6$ では、MAPEに大きな変化はない一方、 $M=8\cdot 10$ では、MAPEが大幅に悪化する傾向が見られた。
- (4) 活性化関数をReLUとした場合のMAPEは、ソフトプラス関数を用いた場合に劣後した。
- (5) アンサンブル平均の試行回数を増加させると、MAPEが改善する。他方で、MAPE改善効果は、試行回数の増加とともに逓減することが予想される。(図4参照)
- (6) 学習データに湿度を加えた場合、8・9月のMAPEに改善が見られた。一方、通年のMAPEについては、悪化意した。(図5参照)
- (7) 気温予報データについて、最高・最低気温データに代えて、24時間予報値を利用し試算することで予報精度が改善する可能性がある。

今後の課題

- 湿度・気温双方の24時間値を用いた予想モデルの検証
- 学習地点の複数地点化やその際に各地点に適用するデータにウェイト付けを行った場合の検証

ご清聴ありがとうございました