

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

Evaluation of Factors Influencing the Accuracy of Electric Demand Forecasting by Artificial Neural Networks (1): Effect of Changes in Model Configuration

柴田 智文 * · 大谷 公哉 * · 寄田 保夫 *

Tomofumi Shibata

Kimiya Otani

Yasuo Yorita

川上 恭章 * · 永富 悠 * · 松尾 雄司 *

Yasuaki Kawakami

Yu Nagatomi

Yuji Matsuo

Short-term load forecasting (STLF) using artificial intelligence (AI) methods has become an active and important research topic with the recent rapid advancement in data processing capabilities of computers. In this paper, we attempted to predict next-day hourly electric loads in Chubu area of Japan using artificial neural networks (ANNs). The model used in this study exploits principal component analysis (PCA) and the selective ensembling (SE) method to achieve a good predictive performance. The effects of changing several hyperparameters, such as the number of hidden layers and neurons, as well as the selection of the input data and the activation function, were tested on the load data obtained from the website of Chubu Electric Power Company. We obtained the following results:

- 1) With the optimal model configuration, mean absolute percentage error (MAPE) was reduced by 0.19 percentage points, from 2.32% to 2.13%.
- 2) Using relative humidity forecasts as part of the input data to ANN reduced MAPE by 0.34 and 0.19 percentage points in August and September, respectively.

Keywords : Artificial neural network, Short-term load forecasting, Artificial Intelligence, Electricity Demand, Principal component analysis,

1. はじめに

近年、人工ニューラルネットワーク (Artificial Neural Network: ANN) 手法への関心が高まっている。自動運転をはじめとした画像認識解析の分野から金融業における自動売買など幅広い分野での応用が見られ、エネルギー分野でも、電力需要や各種エネルギー価格の予測等で数多くの応用研究が見られる。

短期電力需要予測は古くから研究の主題となっており、自己回帰移動平均 (Autoregressive Moving Average: ARMA) モデルや自己回帰和分移動平均 (Autoregressive Integrated Moving Average: ARIMA) モデルなどの統計モデルを用いる手法¹⁾や類似日を用いる手法²⁾などが検討され、現在でも研究が進められている。一方で、特に近年ではサポートベクターマシーン (SVM)³⁾、ランダムフォレスト (RF)⁴⁾、及び ANN といったいわゆる機械学習を用いた手法が試みられるようになり、多くの研究例が出版されている。2001年には既に ANN による短期電力需要予測手法のレビュー論文が公表され⁵⁾、また 2003年の論文では機械学習を用いた数十の研究例がレビューされているが⁶⁾、その後十数年の間に更に夥しい数の論文が公表されて

いる。このような問題に ANN を適用する場合、少しの工夫によって予測性能を大幅に向上させ得ることが知られており、例えば再帰的ニューラルネットワーク (Recurrent Neural Network: RNN)⁷⁾、畳み込みニューラルネットワーク (Convolutional Neural Network: CNN)⁸⁾、極限学習器 (Extreme Learning Machine: ELM)⁹⁾などの特殊な ANN を使う方法や、Wavelet 変換¹⁰⁾、経験的モード分解 (Empirical Mode Decomposition: EMD)¹¹⁾によってデータ処理をする方法などさまざまな手法が提案されている。

これらの多くの手法を網羅的にレビューすることは現在既に困難になりつつあり、それらの優劣を比較することは更に困難である (例えば類似の予測問題である短期電力価格予測については ANN を含むさまざまな手法を網羅的に試み、その優劣を比較した論文は存在するが¹²⁾、ここでも ANN 自体の中での多くのバリエーションについては十分な評価がなされていない)。

このような中で、ある特定のデータセットを用い、多数の参加者によりモデルの予測性能を競いあう試みもなされている¹³⁻¹⁵⁾。それを踏まえ、筆者らは主成分分解及び選択的アンサンブル平均を用いる予測手法を試み、それを東京電力管内の電力需要予測に適用することで、最先端の予

*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

測技術に劣らない予測性能を発揮し得ることを示した

¹⁶⁾。但しここではANNのハイパーパラメータ等については暫定的な値を用い、網羅的な検討は行わなかったと同時に、主な分析対象は東京電力管内のデータであり、その他の地域についてバリエーションのあるモデルを用いた評価は行わなかった。このような経緯を踏まえ、本稿では新たに中部電力管内を対象としたモデルを構築し、それを用いて評価を行った。既往研究と比べた本稿の新奇性は以下の点にある。

- ・モデルのハイパーパラメータや活性化関数の形状など、バリエーションのあるモデルを用いて評価を行うことにより、提案手法による予測性能向上の可能性をより深く追求したこと。
- ・その上で、既往研究で用いたモデルに対し、新たな説明変数（湿度データ）を加えることで更なる性能向上の可能性について評価したこと。

既往研究では特に電力需要が大きくなる夏場（7月・8月）及び冬場（12月～2月）に予測性能が低下する傾向が示されており、そこでの予測性能の向上を念頭において評価を進めた。以下、本稿では2章で短期電力需要予測モデルの概要を記した上で、3章で使用したデータ及び試算条件について記述し、4章で評価の結果及び考察をまとめる。最後に5章では本検討で得られた知見をまとめ、今後の課題について記載する。

2. 短期電力需要予測モデルの概要

2.1 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1のように表される。

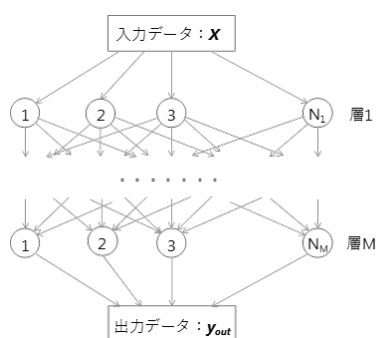


図1 多層人工ニューラルネットワークの概念図

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。いま入力データが N_0 次元のベクトル $\mathbf{y}_0 = \mathbf{X}$ で表され、 n 番目の中間層が N_n 次元のベクトル \mathbf{y}_n で表されるとすると、各層の間に次の形の関係式を想定することにより、入力データ \mathbf{X} から出力データ $\mathbf{y}_{out} = \mathbf{y}_{M+1}$ が逐次的に計算されることになる。

$$\mathbf{y}_{n+1} = f(\mathbf{w}_n \mathbf{y}_n + \mathbf{b}_n) \quad \text{但し } n \in \{0, 1, \dots, M\} \quad (1)$$

ここで f は活性化関数と呼ばれる非線形の関数であり、行列 \mathbf{w}_n とベクトル \mathbf{b}_n は、入力データ \mathbf{X} と出力データ（教師データ） \mathbf{Y} との組に最も適合するように（即ち、誤差 $\|\mathbf{Y} - \mathbf{y}_{out}\|^2$ が最小となるように）決定される。 \mathbf{X} と \mathbf{Y} の多数の組により学習されたモデルに対し、更に新たな入力データ \mathbf{X}_F を与えることにより、未知の値 \mathbf{Y}_F を予測することができる。

本稿では d 日朝 8 時に $d+1$ 日の電力需要 24 時間値を予測することを試みた。モデルへの入力データは $d-1 \sim d+1$ 日の暦データ、即ち年、月、日、曜日（0～6）、祝日であるか否か（0 または 1）を示す各変数と、 $d-1$ 日～ d 日朝 7 時までの電力需要実績値、 $d-1$ 日の気象データ実測値、並びに d 日朝時点で見られる $d+1$ 日の気象予報データであり、出力データは $d+1$ 日の電力需要 24 時間値である。

2.2 主成分分析

本稿で用いたモデルでは、日電力負荷曲線に対して主成分分析¹⁷⁾を行うことで予測性能の向上を図っている。ここではある日の電力需要（1時間平均値）は24次元空間内のベクトルと見做される。これに対して主成分分析を実施し、第4主成分まで（累計寄与率99.5%）の主成分得点 $a_{1,t} \sim a_{4,t}$ を計算する。ここで過去の主成分得点データによって学習させたモデルを用い、 $d+1$ 日の主成分得点 $a_{1,d+1} \sim a_{4,d+1}$ を予測することにより、第4主成分までの線形結合によって $d+1$ 日の電力需要 24 時間値の近似曲線を得ることができる。これは24次元のベクトルを4次元に圧縮することに相当し、それによって予測性能が向上する。

2.3 選択的アンサンブル平均法

一般に機械学習では、予測を行う際に1つのモデルによる結果のみを用いるのではなく、複数のモデルからのアンサンブル平均値を取ることによって予測性能が向上することが知られている。本稿で用いたモデルでは、選択的アンサンブル平均をとることにより更なる性能向上を図っている¹⁸⁾¹⁹⁾。これは電力需要を予測する際に、検証データを予測期間の直前に取った場合、検証データの誤差と予測データの誤差の間に強い相関を見出すことができる、という

観察事項に基づいている。即ち、検証データ期間を n_v 日とし、予測日から n_v 日前までのデータを用いた学習により n_r 個のモデルを作成する。これらのモデルのうち、検証期間（予測日前日までの n_v 日間）の予測誤差が小さい方から n_s 個のモデルのみを採用し、その予測値の算術平均を最終的な予測値とする。ここで n_s は検証期間でのアンサンブル平均値による誤差が最小となるように決定される。上述の通り検証期間を予測期間の直前に取った場合にはその誤差の間に強い相関があることが確認できるため、この方法により「良く学習された」モデルのみを選択的に採用し、予測誤差を大幅に低減することが可能となる。検証データを予測期間の直前ではなく、例えば学習データ期間の中に均一に（即ち、数年前からのデータも含めて）取った場合にはその誤差と予測期間の誤差との相関が薄れ、効率的なモデル選択が行えないことに注意が必要である。

2.4 予測モデルの構成

これらの手法を組み合せ、本稿では以下に示す3段階のモデル構成によって翌日電力需要予測を実施した。

まず第1段階では、朝7時までの電力需要の平均値 $L7_t$ の時系列データを用い、 d 日までのデータをもとに $d+1$ 日のデータ $L7_{d+1}$ を予測する。これは今回想定した予測業務において利用可能な朝7時までのデータを最大限活用するために行うものである。次いで第2段階では、 $L7_{d+1}$ の予測値をも入力データに含めた上で、 $d+1$ 日の主成分得点 $a_{1,d+1} \sim a_{4,d+1}$ を予測する。これによって $d+1$ 日の電力需要24時間値の近似値 $L_{ap,d+1,i}$ ($i \in \{0, 1, \dots, 23\}$) を算出した上で、第3段階では $L_{ap,d+1,i}$ と $L7_{d+1}$ を入力データに含め、 $d+1$ 日の電力需要 $L_{d+1,i}$ を予測する。またこれらの3段階のモデル全てについて、検証期間 $n_v=30$ 日として選択的アンサンブル平均をとり、予測を行った。

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を用いて中部電力管内における電力需要の予測を行った。分析にあたっては同社が公表した2012年1月1日から2018年6月30日までの電力需要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1参照)。

表1 電力需要データの概要

地域	収録期間	データ	データ
		日数	欠損日数
中部電力	2012/1/1-2018/6/30	2,336	37

3.2 気象データ

気象データとしては、気象庁が公表する名古屋市の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4つの変数（その日の天気概況がそれぞれ「晴」「曇」「雨」「雪」の各文字を含む場合に1、それ以外の場合に0をとる変数）及び最高気温・最低気温の値を用いている。

更に、追加的に1時間毎の気温データと湿度データを用いて検証を行った。但しこれらのデータについては過去の予報値が得られなかったことから、後述の通り乱数を用いて湿度予報値を擬似的に作成し、評価に用いた。

3.3 学習データと検証データの設定

ここでは、予測誤差が比較的大きくなる夏季及び冬季（2017年8月・12月）と、誤差が小さくなる春季（2018年4月）を選び、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。ここでは選択的アンサンブル平均法を用いている関係上、上述の通り予測期間の直前30日程度を検証期間とした。例えば2018年4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2018年2月までのデータを学習データ、3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 試算条件

本稿では以下の試算条件を変更し、その差異について比較を行った。

(1) 層数及びニューロン数

層数及びニューロン数はモデルの規模を示す重要なハイパーパラメータであるが、最適な値を予め決めることは難しい。一般的にモデルの規模が小さすぎると与えられた問題を十分によく表現できなくなる一方で、逆に大きすぎると計算に時間がかかるのみならず、学習が効率的に進ま

ず、予測性能が悪化することもある。ここでは層数について3~10, 1層のニューロン数について5~100の間で変化させ、予測性能への影響を評価した。

(2)活性化関数

本稿では、活性化関数として式(2)に示すSoftplus関数を用いている。但し活性化関数の形状は予測性能に影響を与える可能性があることから、式(3)に示す正規化線形関数(Rectified Linear Unit: ReLU)を用いた場合の評価も行った。

$$f(x) = \log(1 + e^x) \quad (2)$$

$$f_{ReLU}(x) = \max(0, x) \quad (3)$$

SoftplusとReLUはともに $x \rightarrow -\infty$ の極限で0, $x \rightarrow \infty$ の極限で x に近づく似た形状を有しているが、Softplusは微分係数が連続であるのに対し、ReLUは非連続であるという大きな差を有する。深層のニューラルネットワークではReLUを用いることで特に効率的に学習が進むことが知られており²⁰⁾、実際に広く用いられている。このため、ここではこの両者を比較して本問題に対する適否を検討した。

(3)選択的アンサンブル平均の試行回数

選択的アンサンブル平均の試行回数 nr は一般的に大きければ大きいほど多数のモデルからの選択を行うことになり、予測性能が向上するものと考えられる。ここでは1~50回の間で変化させ、比較を行った。

(4)湿度及び気温予報値

今回、過去の気象予報値は1日の最高気温・最低気温のみが入手可能であったことから、正確にはそれを用いた翌日電力需要予測のみが検証可能である。しかし実際の予測業務では、最高・最低気温のみでなく、気温と湿度の24時間値の予報データが利用可能である。湿度が電力需要に影響を与えることはよく知られており²¹⁾、その予報値を入力データに含むことにより予測性能が向上することが期待される。このため本稿では追加的に、湿度及び気温の24時間値を学習データとして用いた場合の予測性能向上の可能性について、乱数を用いて疑似的な予報値を作成して評価した。なお、湿度については、後述の通りそもそもの学習要素としての適否を明らかにするため、比較対象として、実績値と同じ正確な予報値が予測の入力データとして用いられるケースについても試算を行った。

ここでは日本気象協会のウェブサイトからダウンロードした2018年9月16日から10月15日の30日間の予報データ(24時間値)と実績データ(同)との誤差をもと

に、過去の予報値を模擬した。具体的なデータの生成方法は以下のとおり。

いま、30日間それぞれの時刻 i における湿度、もしくは気温の予報値の誤差(予報値-実績値)を $\mathbf{X}_i = (x_1^{(i)}, x_2^{(i)}, \dots, x_{30}^{(i)})$ と表す。この誤差の値は湿度について概ね11%ポイント程度、気温について概ね1.5°C程度の標準偏差でばらつくが、互いに独立ではなく、近接した時刻の予報誤差は強く相関している。ここで、名古屋における湿度について \mathbf{X}_i と \mathbf{X}_j ($i > j$)の間の相関係数 ρ を図示すると図2の通りとなる。このことから、隣接する時刻の予想誤差の間には、一定の相関があるが、時刻が離れるにつれて相関が失われる傾向が見てとれる。また、 ρ は概ね時間帯によらず、距離 $l = |i - j|$ のみに応じて減少している。




図2 \mathbf{X}_i と \mathbf{X}_j の間の相関係数(名古屋)

上記の性質は東京・大阪等の他の都市においても見られる。 $l = 1, 2, \dots, 10$ となる \mathbf{X}_i と \mathbf{X}_j の相関係数の平均値を図示すると図3のようになり、 ρ は l に従って単調に減少する傾向が見られる。名古屋については、これは概ね以下の式で表される。

$$\rho = e^{-0.126l} \quad (4)$$

即ち、時刻が1時間離れるごとに ρ は $\exp(-0.126) \approx 0.88$ 倍に減少する。




図3 各 l における相関係数の平均値

この関係を用いて本稿では、 t 日の時刻 i における湿度予報誤差データ $e_{t,i}$ を乱数によって作成した。但し $e_{t,i}$ は平均0, 標準偏差11%ポイントの正規分布に従うものとし、

かつ, $i \neq j$ に対して $e_{i,i}$ と $e_{i,j}$ は式(4)に示す相関係数で相関を持つものとした. このように作成された $e_{i,i}$ を湿度の実績値 $h_{i,i}$ に加算することにより湿度予報値の模擬データを作成し, モデルの入力データとして用いた. 気温についても同様の手法により, $\rho = \exp(-0.082l)$ として相関のある乱数によって24時間値を作成した上で, その最大値と最小値が過去の予想最高気温・最低気温と一致するように補正して模擬的な24時間予報値とした.

3.5 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.

$$\text{MAPE} = \frac{1}{n} \sum_t \left| \frac{f_t - y_t}{y_t} \right| \quad (5)$$

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.

4. 試算結果及び考察

4.1 ハイパーパラメータ等による影響

(1) ニューロン数及び層数

ニューロン数 N および層数 M の差による誤差率の変化を表2および表3に示す. 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 n_T は20回としている. また表2では $M=3$, 表3では $N=50$ としている.

表2 ニューロン数 N による MAPE の変化 ($M=3$)

N	4月		8月		12月	
	MAPE	p値	MAPE	p値	MAPE	p値
10	1.85%	—	3.82%	0.008	2.43%	9E-17
20	1.88%	0.102	3.88%	0.002	2.37%	3.5E-8
30	1.96%	0.003	3.80%	0.314	2.32%	1.4E-4
50	1.89%	0.020	3.75%	—	2.13%	—
70	1.87%	0.215	3.84%	0.010	2.20%	0.095
100	1.88%	0.354	3.85%	0.046	2.16%	0.007

表2から, 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. 表中にはこれらの最良値と他の N による試算結果との間で t 検定を行った場合の p 値も示している. 4月については, 最良値を取る $N=10$ の場合は, $N=20, 70, 100$ の場合よりも有意に良好であるとは言えない. 他方, 8月については $N=50$ における結果は $N=30$ の場合以外に対しては8%水準で有意に MAPE が小さくなっ

ており, また12月は $N=50$ における結果が $N=70$ に対して10%の有意水準で, 他の N に対して1%の有意水準で MAPE が小さくなっている.

一般的に, N が小さすぎる場合にはモデルが現象を十分に表現できない一方で, 大きすぎる場合にはモデルが冗長となり, 逆に予測性能が悪化すると考えられる. 表2に示す結果は, 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.

表3 層数 M による MAPE の変化 ($N=50$)

	M					
	3	4	5	6	8	10
4月	2.05%	1.91%	1.82%	1.84%	2.38%	12.22%
8月	3.75%	3.76%	3.78%	3.70%	4.30%	13.49%
12月	2.13%	2.32%	2.32%	2.37%	2.65%	13.65%

表3から, $M=3\sim6$ では, MAPE に大きな変化はない一方, $M=8\cdot10$ では, MAPE が大幅に悪化する傾向が見られた.

(2) 活性化関数

活性化関数をソフトプラス関数から, 正規化線形関数 (ReLU) に変更した場合の MAPE を表4に示す. ここで $M=3$ としている. 表3に示した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. また, $N=50$ における4・8・12月の値について t 検定を行ったところ, p 値がそれぞれ, 0.04%, 3.27%, 0.02% と5%水準以下で有意に ReLU を用いた試算値が劣化する傾向が見られた.

上述の通り, ReLU は深層のニューラルネットワークにおいて標準的に用いられる活性化関数であり, 他の関数に比べてより効率的に学習が進むことが知られている. 今回の計算では, 学習時に Softplus に比べて ReLU の方がより早く誤差が収束し, 学習データに対する過学習が進む傾向が確認された. 本稿で検討している翌日電力需要予測という問題は, ニューラルネットワークの観点からは比較的「単純な」問題であり, 膨大なデータから法則を学習させるよりもむしろ, 限られたデータの中でいかに過学習を防ぐかが予測性能を左右すると考えられる. このため, ここでは ReLU よりもむしろ学習が緩やかに進む Softplus の方が, 予測性能が向上する結果になっている.

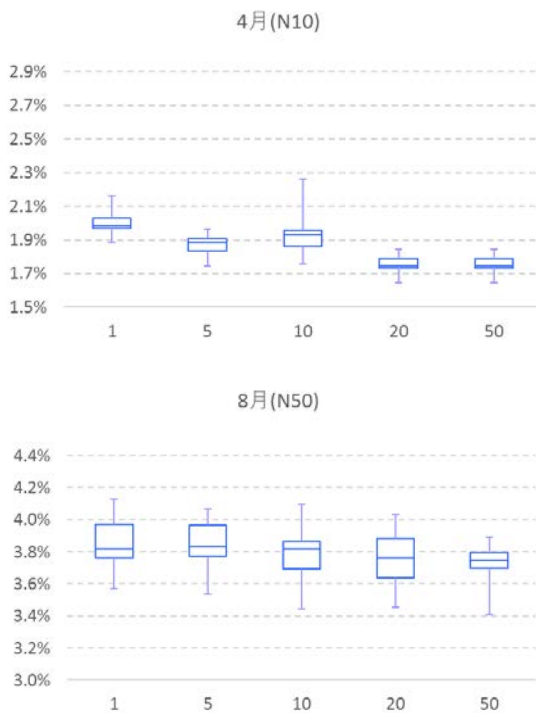
表4 ReLUによる予測時のMAPEの変化

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%

表内の差分は、ReLU関数による試算結果と、ソフトプラス関数による試算結果(表2)との差分。

(3) 選択的アンサンブル平均の試行回数

選択的アンサンブル平均の試行回数 nr を1~50の間で変化させた場合の影響について図4に示す。 nr が増加するにつれて、より多くのモデルの中から選択的に良いモデルを採用するため、MAPEが改善する傾向が見られる。但しその改善の程度は nr の増加につれて飽和に近づいており、例えば仮に $nr=200$ 、もしくは300まで増やしたとしても、それによるMAPEの改善は限定的であることが予想される。



12月(N50)




図4 アンサンブル平均の試行回数とMAPEの比較

4.2 気温及び湿度24時間値による影響

(1) ニューロン数 N による影響

湿度データを検討要素に加えた場合、表5に示す通り、8月のMAPEが湿度を考慮しない場合の最良値(3.75%)よりも最大0.34%改善した。他方で、4・12月のMAPEについては、悪化する傾向を示した。

表5 湿度追加時のMAPE(湿度予報値=実績値)

N	4月		8月		12月	
	MAPE	p値	MAPE	p値	MAPE	p値
50	2.24%	2 E-7	3.59%	5 E-5	2.85%	6 E-7
70	2.15%	5 E-6	3.46%	0.135	2.74%	2 E-5
100	2.10%	5 E-4	3.41%	—	2.62%	0.008
150	2.04%	0.017	3.45%	0.176	2.51%	—
200	1.89%	—	3.52%	0.007	2.56%	0.127

MAPE最小となる N の値は、4月200、8月100、12月150となった。表中にはこれらの最良値と他の N による試算結果との間でt検定を行った場合のp値も示している。4月については、 $N=200$ における結果は他の N に対し5%水準で有意にMAPEが小さくなっており、8月については、 $N=100$ の場合が、 $N=50, 200$ に対し5%水準で有意にMAPEが小さくなっている。また、12月については、 $N=150$ の場合が、 $N=200$ を除く N に対し5%水準で有意にMAPEが小さくなっている。

表2と比較して、最良値を示す N の数値が高いことから、学習要素を追加しモデルを複雑化させるにつれ、最良値を導くための N が増加する傾向があるものと考えられる。

(2) 湿度・気温24時間値を用いた予測性能の評価

各モデルの特性を比較するため、1.ANNによる単純試算値(4.1(2))の手法から主成分分析および選択的アンサン

ブル平均の過程を除外したもの), 2. 主成分分析及び選択的アンサンブル平均あり (4.1 (2) と同様), 3. 湿度実績値 (4.2 (1) と同様), 4. 湿度予報値 (湿度予報値を擬似データとしたもの), 5. 気温 24 時間予報値 (模擬データ), の 5 種類について, 通年 (2018 年 1 月~6 月及び 2017 年 7 月~12 月) の予想を実施した(図 5 参照).

なお, 全てのモデルにおいて n_T は 20 回, $M = 3$ とし, $1 \cdot 2$ は $N=50$, $3 \sim 5$ については, $N=100$ として試算した.




図 5 各モデルによる MAPE の比較

主成分分析および選択的アンサンブル平均を実施したモデルの MAPE は, 実施しないモデル場合との比較で年間平均で 2.51%から 2.25%まで, 0.25%ポイント低下した ($1 \cdot 2$ 比較). 特に予測誤差の大きな冬 (12 月~2 月) や夏 (8 月) において精度の向上が著しい.

湿度を用いた試算では, 実績値・模擬データを用いた場合ともに, 8・9 月の MAPE が低下 (低下幅は, 8 月: 実績値 0.34%, 模擬値 0.33%, 9 月: 実績値 0.19%, 模擬値 0.20%) する一方, 通年の MAPE は, 2.25%から 2.36%及び 2.56%まで逆に悪化した ($2 \sim 4$ 比較). 湿度が電力需要に大きく影響しているのは夏の一時期のみであり, それ以外の季節では不必要な湿度データの追加により予測精度が悪化すると考えられる.

気温 24 時間予報値 (模擬データ) を用いた試算値は, 最高・最低気温を用いて試算したモデルと比較して通年の MAPE が 2.25%から 2.17%まで 0.09%低下した ($2 \cdot 5$ 比較). 1 月・6 月及び 7 月ではわずかに MAPE の悪化が見ら

れるものの, その他の月では比較的大きな改善が見られている.

以上から, ①主成分分析および選択的アンサンブル平均を実施したモデルの試算値は, 単純な ANN による試算値よりも予測精度が一般的に改善すること, ②湿度が電力需要に与える影響が大きいと考えられる 8・9 月については, 湿度を学習データに加えることで予測精度が改善する可能性があるものの, 通年の予測精度は悪化すること, ③気温予報データについては, 最高・最低気温データに代えて, 24 時間予報値を利用し, より精細なデータセットを用いて試算することで精度が改善する可能性があること, が示唆される.

5. まとめ

本稿では中部電力管内を対象とし, 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. ニューロン数, 層数, 活性化関数の形状及び入力とする気象データについて条件を変更し検証した結果, 以下の考察が得られた.

- (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. (表 2 参照)
- (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, $M=8 \sim 10$ では, MAPE が大幅に悪化する傾向が見られた. (表 3 参照).
- (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化した. (表 4 参照)
- (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通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.

8月及び9月については、湿度・気温の24時間値を入力データに加えることにより何れも予測精度が向上したことから、両者をともに加えれば更に向上する可能性が高い。但しその場合、他の月においては気温の24時間値のみを考慮した場合に比べて精度が悪化し、年間平均でも悪化する可能性がある。このように、本稿で示した試算の結果は、季節ないし月に応じて最善の予測を行うモデルが異なる可能性を示唆している。本稿で用いたモデルでは同一の条件のもとで異なる初期条件から nr 個のモデルを作成し、選択的アンサンブル平均を行ったが、異なる条件（入力データの構成など）で多数のモデルを作成し、選択的アンサンブル平均をとることにより、季節の変化をも最適化してより良好な予測性能を実現し得る可能性があると言えるであろう。

今回検証した学習諸条件の変更は、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加え、学習対象の地点数を本稿の1地点から複数地点に増加させた場合や、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など、様々な組み合わせを検討することで更に予測性能を向上させることも可能であると考えられる。

また、本稿では、湿度の予報データについて、データ制約から、擬似的に生成した予報値により、学習と予測を実施したが、実際の湿度予報値の過去データを用いて学習を行うことが望ましい点は論を俟たない。

不足するデータを収集するとともに、より広範に手法を検討することは今後の重要な研究課題である。

参考文献

- 1) C. Kuster, Y. Rezgui, and M. Mourshed; Electrical load forecasting models: A critical systematic review, *Sustainable Cities Soc.*, 35 (2017), pp.257-270.
- 2) M. Tucci, E. Crisostomi, G. Giunta, and M. Raugi; A multi-objective method for short-term load forecasting in European countries, *IEEE Trans. Power Syst.*, 31-5 (2016), pp.3537-3547.
- 3) E. Ceperic, V. Ceperic, and A. Baric; A strategy for short-term load forecasting by support vector regression machines, *IEEE Trans. Power Syst.*, 28-4 (2013), pp.4356-4364.
- 4) P. Lusic, K. R. Khalilpour, L. Andrew, and A. Liebman; Short-term residential load forecasting: Impact of calendar effects and forecast granularity, *Appl. Energy*, 205 (2017), pp.654-669.
- 5) H. S. Hippert, C. E. Pedreira, and R. C. Souza; Neural networks for short-term load forecasting: A review and evaluation, *IEEE Trans. Power Syst.*, 16-1 (2001), pp.44-55.
- 6) K. Metaxiotis, A. Kagiannas, D. Askounis, and J. Psarras; Artificial intelligence in short term electric load forecasting: a state-of-the-art survey for the researcher, *Energy Convers. Manag.*, 44-9 (2003), pp.1525-1534.
- 7) F. M. Bianchi, E. Maiorino, M. C. Kampffmeyer, A. Rizzi, and R. Jenssen; Recurrent Neural Networks for Short-Term Load Forecasting: An Overview and Comparative Analysis, (2017), Springer.
- 8) K. Muralitharan, R. Sakthivel, and R. Vishnuvarthan; Neural network based optimization approach for energy demand prediction in smart grid, *Neurocomputing*, 273 (2018), pp.199-208.
- 9) Ö. F. Ertugrul; Forecasting electricity load by a novel recurrent extreme learning machines approach, *Int. J. Electr. Power Energy Syst.*, 78 (2016), pp. 429-435.
- 10) M. Rafiei, T. Niknam, J. Aghaei, M. Shafie-khah, and J. P. S. Catalão; Probabilistic load forecasting using an improved wavelet neural network trained by generalized extreme learning machine, *IEEE Trans. Smart Grid*, 2018.
- 11) Y. Qiu, X. Li, W. Zheng, Q. Hu, Z. Wei and Y. Yue, The prediction of the impact of climatic factors on short-term electric power load based on the big data of smart city, *J. Phys.: Conf. Ser.* 887 (2017), 012023.
- 12) J. Lago, F. De Ridder and B. De Schutter; Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms, *Appl. Energy*, 221 (2018), pp.386-405.
- 13) T. Hong, P. Pinson, S. Fan, H. Zareipour, A. Troccoli and R. J. Hyndman; Probabilistic energy forecasting: Global Energy Forecasting Competition 2014 and beyond, *Int. J. Forecasting*, 32-3 (2016), pp.896-913.

- 14) Réseau de transport d'électricité (RTE); Prédiction déterministe de la consommation électrique hivernale (volet 1), (2018).
<https://www.datascience.net/fr/challenge/33/details> (アクセス日 2018.11.15)
- 15) 東京電力パワーグリッド; 電力需要予測値の正確さを競う「第1回電力需要予測コンテスト」の結果について, (2017). https://www4.tepco.co.jp/press/release/2017/1463817_8706.html (アクセス日 2018.11.15)
- 16) 松尾雄司, 大谷公哉, 柴田智文, 寄田保夫, 川上恭章, 永富悠; 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—, (2018). <http://eneken.ieej.or.jp/data/8106.pdf> (アクセス日 2018.11.15)
- 17) M. Manera and A. Marzullo; Modelling the load curve of aggregate electricity consumption using principal components, Environ. Modell. Software, 20-11 (2005), pp.1389-1400.
- 18) Y. Matsuo and T. Oyama; Forecasting daily electricity demand by applying artificial neural network with Fourier transform and principal component analysis techniques, The 13th International Symposium on Operations Research and its Applications, Session 5-3, (2018).
- 19) 松尾雄司, 大山達雄; Short-term electric demand forecasting using artificial neural networks with daily load curve analysis techniques, 日本オペレーションズ・リサーチ学会 2018 年秋季研究発表会, 2-E-9, (2018).
- 20) Y. LeCun, Y. Bengio and G. Hinton; Deep learning, Nature, 521 (2015), pp.436-444.
- 21) S. R. Salkuti; Short-term electrical load forecasting using radial basis function neural networks considering weather factors, Electr. Eng. (2018), pp.1-11.

お問い合わせ:report@tky.ieej.or.jp