

コンシューマ・システム論文

# スモールデータアプローチによるオフィスの電力需要予測方式

川野 裕希<sup>1,a)</sup> 山田 敏志<sup>2</sup> 阿倍 博信<sup>1</sup> 中島 宏一<sup>3</sup>

受付日 2013年9月18日, 採録日 2014年2月28日

**概要:** 東日本大震災以降, 電力不足や電気料金の値上げにより省エネの重要性がこれまで以上に高まっている. オフィスを対象とした省エネ技術の1つに, 翌日の電力需要量の予測結果に基づく計画的な機器制御による節電がある. しかし, オフィスの電力需要量は, 気温や湿度, 天気, 季節, 曜日, 行事, 建物内の人数などの多様な条件で複雑に変化するため予測が困難であった. また, 既存の方式では, 予測精度向上のために多数のパラメータと過去数年分のデータを必要とし, 適用可能なオフィスビルに限られてしまうという課題があった. そこで, 本論文ではより多くのオフィスビルに適用できるように可能な限り少ない種類と量(期間)のデータ, つまりスモールデータで各時間帯の電力需要量を予測する方式を提案する. 具体的には, 過去の電力需要量と気温のみを用いた重回帰分析による予測方式において, オフィスの電力需要予測に適した説明変数の提案・選択や, 重回帰分析を用いた予測方式の課題である外挿への対応を検討して予測精度の向上を図り, オフィスの1年間の電力需要量を用いた予測精度評価によりその有効性を確認した.

**キーワード:** 電力需要予測, 回帰分析

## An Electricity Demand Forecasting Method for Office Buildings Using a Small Data Approach

HIROKI KAWANO<sup>1,a)</sup> SATOSHI YAMADA<sup>2</sup> HIRONOBU ABE<sup>1</sup> KOICHI NAKASHIMA<sup>3</sup>

Received: September 18, 2013, Accepted: February 28, 2014

**Abstract:** Energy conservation has grown in importance because of electricity shortages and the rise of electricity costs. One of the systems for energy conservation is a central control system for electric equipments in a building based on the prediction of electricity demand. However, electricity demand in an office building heavily depends on temperature, humidity, weather, the season, days of the week, events, a number of employees and so on. Thus accurate prediction is very difficult, and in general forecasting models require large data for training. In this paper, we propose a forecasting method from "small data", which means data observed easily in a short time period. The basic approach of the method is a multiple regression analysis with exception processing for parameters out of the training data. We adapt explanatory variables of multiple regression analysis to office buildings. The model is trained only using temperatures and electric power from the previous 25 days, and forecasting accuracy is better than a method based on selection of the nearest last observed data.

**Keywords:** electricity demand forecasting, regression analysis

<sup>1</sup> 三菱電機株式会社情報技術総合研究所  
Information Technology R&D Center, Mitsubishi Electric Corporation, Kamakura, Kanagawa 247-8501, Japan  
<sup>2</sup> 三菱電機株式会社コミュニケーション・ネットワーク製作所  
Communication Networks Center, Mitsubishi Electric Corporation, Amagasaki, Hyogo 661-8661, Japan  
<sup>3</sup> 三菱電機株式会社本社  
Head Office, Mitsubishi Electric Corporation, Chiyoda, Tokyo 100-8310, Japan

### 1. はじめに

東日本大震災以降, 電力不足や電気料金の値上げにより省エネの重要性がこれまで以上に高まっている [1]. オフィスを対象とした省エネ技術の1つに, 電力需要量を可

a) kawano.hiroki@dc.mitsubishielectric.co.jp

視化し、事前に設定された節電目標値を超えそうな場合に、ユーザに節電を促すものがある。しかし、どれくらいの節電が必要なのか不明なまま空調や照明を制御するため過剰に節電してしまうという問題があった。

上記の問題を解決するために、ビルなどの需要家を対象とした電力需要量の予測技術が必要である。たとえば、過去の電力需要量をもとに翌日の電力需要量を予測することができれば、事前に節電が必要な時間帯や減らすべき節電量が明確になり、必要最低限の空調や照明のみを停止する、もしくは、空調の運転開始などの電力需要量が大きい処理を他の時間帯にするといった、より計画的な制御が可能になる。

しかし、オフィスビルの電力需要量は、気温や湿度、天気、季節、曜日、行事、建物内の人数などの影響を受けて複雑に変化するため予測が困難という問題があった。これらの情報をフロア単位や部屋単位で詳細に取得し、過去数年分のデータを分析して予測することで高精度な電力需要量の予測が期待できるが、必要なすべての情報を取得・保存しているオフィスビルは少ない。また、これらの情報を新たに取得するにしても大量のセンサが必要となり、コストが高くなってしまう。したがって、オフィスビルの電力需要量を予測するには、予測精度と取得コストのトレードオフを考慮した方式が必要であった。

本論文では、より多くのオフィスビルに幅広く適用できるように、可能な限り少ない種類と量（期間）のデータ、つまりスモールデータで各時間帯の電力需要量を予測する方式を提案する。具体的には、過去1~2カ月の電力需要量と気温のみを用いた重回帰分析によりオフィスビルの各時刻の電力需要量を予測するものである。提案方式は、予測精度を向上させるために多種類かつ長期間のデータを必要とするのではなく、予測に用いるデータの種類や量を減らしつつ、その条件下で可能な限り予測精度を向上させるものである。これを実現するために本論文では、オフィスビルに適した重回帰分析の説明変数の提案・選択や、重回帰分析を用いた予測方式の課題である入力情報が学習データとは大きく異なる場合（以下、外挿）への対応を検討することで予測精度の向上を図っている。

なお、提案方式で電力需要量のほかに気温情報を利用することを許容しているのは、気温情報が新たなセンサを導入しなくてもインターネットを経由して気象庁などから容易に取得できるからである。また、提案方式では過去の電力需要量を特別に保持していない環境でもすぐに電力需要量を予測して、その予測結果をもとに省エネを実行できるように、予測に利用するデータ量を過去1~2カ月に制限している。これは、電力需要量を計測するスマートメータが保存可能なデータ量（約30~45日分）を参考としている。つまり、提案方式はスマートメータに保存されている過去の電力需要量と気象庁などの気温情報のみを用いて

すぐに予測ができるものであり、この条件の下で予測精度の向上を図っている。

以下、2章では既存の予測方式とその課題について述べ、3章で提案する予測方式について説明する。4章では、提案する予測方式の評価について述べ、5章でその評価結果を考察し、6章でまとめる。

## 2. 既存の予測方式

電力需要予測方式はこれまでも電力会社などの供給家が安定して電力を供給するために必要であり、様々な研究が行われてきた。予測方式としては、たとえば、ニューラルネットワークを用いた予測方式 [2], [3], [4], [5], [6], [7], [8] や本提案と同様の重回帰分析を用いた予測方式 [4], [9], [10], [11], [12] がある。しかし、これらの研究は予測精度向上が主目的であり、多種類かつ長期間（過去数年分）のデータを用いた予測方式であるため、多くのデータを取得・保持していないオフィスビルでは適用が困難であった。

オフィスビルを対象とした先行研究では、オフィスビルの複雑な電力需要量の変化に対応するため、過去数日間の最高気温の変化をもとに特性の異なる2つの予測方式を使い分けるものがある [13]（以下、既存の予測方式）。この予測方式では、過去3週間の最高気温の変動が安定しているならば、予測日の予想最高気温と最高気温が類似している日を過去3週間から複数選択し、その平均値を予測結果としている。また、過去3週間の最高気温の変動が大きいのであれば、予測日の予想最高気温をもとに翌日の最大電力需要量予測値を求め、その最大電力需要量予測値に合うように前日などの過去の電力需要量を補正する。このように既存の予測方式では最高気温の変動をもとに予測方式を使い分けることで、少ない種類と短期間のデータでも電力需要量の複雑な変化に対応した予測を可能とし、多くのオフィスビルに幅広く適用できるものであった。

しかし、既存の予測方式では、過去3週間のデータに予測日の予想最高気温と最高気温が類似した日が存在しない場合、予測精度が低下していた。また、最高気温が同じでも季節の違いにより午前や日没後の気温が異なるため、電力需要量も変化していることがあり、予測精度が低下していた。図1は一例としてあるオフィスビルの2010年6月21日と6月29日の電力需要量の変化を示したものである。この2日は、ともに最高気温は同じであるが、午前中の気温が異なっていたため、電力需要量の変化も異なっていた。

このように既存の予測方式では、少ない種類と短期間のデータで電力需要量を予測できるものであったが、予測に用いるデータの種類や量が少なすぎたため、正確な電力需要量を予測することができず、予測精度が低下していた。また、既存の予測方式では、最高気温のみを用いた予測のため、図1に示したような最高気温が同じでも他の時間帯の気温が異なり、電力需要量に変化している場合に対応す

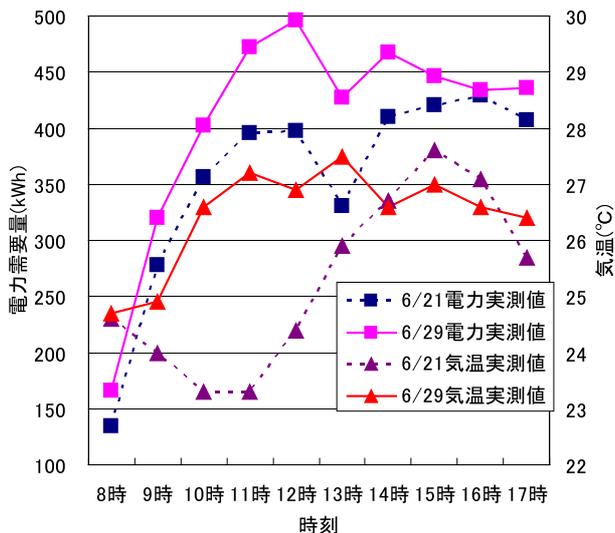


図 1 最高気温が同じ日の電力需要量と気温の変化

Fig. 1 Change of electricity demands and temperatures with the same day of maximum temperature.

ることができなかった。そのため、学習データを増やすことで、最高気温が予測日の予想最高気温と類似しているが季節が変化するため午前の電力需要量が異なっているデータを予測に用いて予測精度が低下する恐れがあり、安易に予測に用いるデータ（以下、学習データ）の量を増やすこともできなかった。さらに、既存の予測方式では予測日の条件（最高気温）に類似する日を選択して予測しているため、最高気温のほかに新たな情報を学習データとして追加した場合にすべての条件（最高気温とその他の情報）に類似する日を見つけることが困難になり、予測精度が低下する恐れがあった。このように、既存の予測方式では、さらなる予測精度向上のため学習データの量と種類を追加することが困難であった。

### 3. 提案方式

本章では、前章で述べた課題を解決するため重回帰分析を用いた予測方式を提案する。重回帰分析は、過去のデータから目的変数（電力需要量）と説明変数（最高気温やその他の情報）の相関を学習して予測するものである。そのため、既存の予測方式とは異なり、電力需要量と相関のある情報であれば学習データの種類（説明変数）として追加しても予測精度が低下することはない。また、既存の重回帰分析を用いた予測方式 [4], [9], [10], [11], [12] では長期間（過去数年分）のデータを用いているが、予測に必要な学習データの量は学習データ（説明変数）の種類に依存するものであり、学習データの種類を増やしすぎなければ、学習データの量は少なくできる。したがって、学習データの種類を厳選すれば、学習データの量が過去 1~2 カ月間であっても精度の良い予測が可能である。このように重回帰分析は少ない種類と量のデータで電力需要量を予測する提

表 1 重回帰分析の説明変数の候補

Table 1 Candidate of explanatory variables in multiple regression analysis.

最高気温	最高気温の 2 乗値
最低気温	予測開始時の気温
日毎の最高気温の差分	予測開始時の電力需要量
前日同時刻の電力需要量	前日の最大電力需要量
日毎の同時刻の電力需要量の差分	

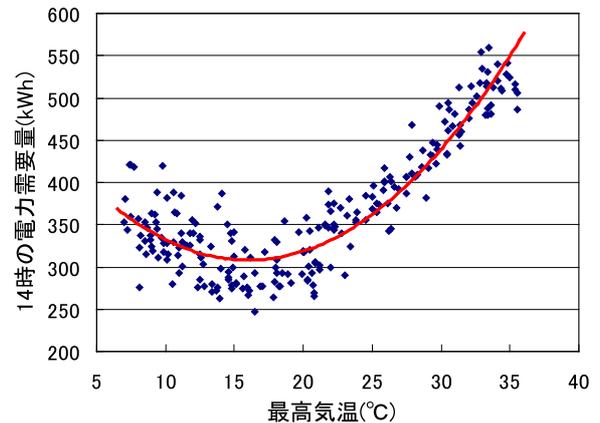


図 2 オフィスビルの電力需要量と最高気温の相関

Fig. 2 Correlation between electricity demand and maximum temperature in office building.

案方式の目的と適合している。

なお、提案方式はオフィスビルでの適用を想定したものである。一般的なオフィスビルでは電力需要量の半分近くを空調の電力需要量が占めているため [14]、提案方式では空調の電力需要量と相関が高く、入手しやすい気温情報を予測に用いている。また、提案方式はオフィスビルに限らず空調の電力需要量が占める割合が高い建物であれば、商業ビルや工場にも適用可能である。

#### 3.1 オフィスビルの電力需要予測に適した説明変数

重回帰分析で予測するためにはオフィスビルの電力需要量の変化に影響する要因を検討し、説明変数として選択する必要がある。本論文では、多くのオフィスビルに適用できるように、予測に用いる情報を気温と電力需要量のみ限定しているが、それでも選択可能な説明変数の候補は無数に存在する。たとえば重回帰分析を予測に用いる先行研究 [4], [9], [10], [11], [12] では、表 1 に示す説明変数を組み合わせて電力需要量を予測している。

本論文では、これらの候補の中から、これまでの研究 [13] で培ったオフィスビルの電力需要量に関する以下の知見をもとに説明変数を検討した。

- 夏季のオフィスビルでは電力需要量の 5 割を空調の電力需要量が占めるため、空調の稼動状況と相関のある最高気温は特に電力需要量の変化に影響する [14]。
- 最高気温と電力需要量には図 2 で示すような 2 次の

相関がある。しかし、2次の相関を学習するには多くの学習データが必要であり、学習データが不足していると図2のような下に凸の2次の相関ではなく、上に凸の誤った2次の相関が得られることもある。また、短い区間（たとえば25°C~30°Cの間）であれば直線（線形）に近い相関が得られている。したがって、学習データ数の少ない状況では最高気温と最高気温の2乗値を説明変数として用いるのではなく、最高気温のみを説明変数とすることが適している。

- 最低気温は午前や日没後の電力需要量の変化に影響する。特に冬季の午前の電力需要量は最低気温に影響を受ける。
- 予測開始時の電力需要量は、予測開始直後の電力需要量と高い相関がある。

以上から、本論文では説明変数として最高気温と最低気温、予測開始時の電力需要量の3つを選択した。最高気温に加えて最低気温と予測開始時の電力需要量を用いることで、既存の予測方式の課題であった最高気温が同じでも他の時間帯の気温が異なり、電力需要量に変化している場合への対応が期待できる。また、これらの説明変数は短期間の学習データでも正確に電力需要量との相関を学習できるものである。

### 3.2 提案方式の重回帰式

以下の式(1)は、前節で選択した最高気温と最低気温、予測開始時の電力需要量を用いて翌日の各時刻の電力需要量を予測する重回帰式である。

$$P_t = a_{t,1}T_{\max} + a_{t,2}T_{\min} + a_{t,3}P_0 + \varepsilon_t \quad (1)$$

左辺  $P_t$  は、時刻  $t$  の電力需要量予測値であり、たとえば24時間先まで電力需要量を1時間単位で予測するならば  $1 \leq t \leq 24$  となる。右辺の  $P_0$  は予測開始時の電力需要量実測値であり、 $T_{\max}$  と  $T_{\min}$  はそれぞれ最高気温と最低気温である。また、右辺  $a_{t,1} \sim a_{t,3}$  と  $\varepsilon_t$  は回帰変数と残差であり、時刻  $t$  の電力需要量を予測する際に最小二乗法による学習で求められる。なお、 $T_{\max}$  と  $T_{\min}$  は学習時には最高気温と最低気温の実測値を利用し、予測時には予想最高気温・最低気温を用いて電力需要量を予測する。最高・最低気温実測値と予想最高気温・最低気温はともに気象庁などから取得できる。

本論文では過去25日間（約1カ月間）のデータを用いて回帰変数と残差の学習を行う。過去25日間としているのは、複数の学習データ数を試した結果、最も予測精度が良くなったからである。これは、説明変数と電力需要量の相関を学習するためにある程度の日数が学習データとして必要となるが、古すぎるデータを用いるとオフィスビル内の人数変化などの予測方式に取り入れていない要因により電力需要量に変化していることがあり、正しく回帰変数と

残差の学習できなかつたためだと考えられる。なお、学習データ数はオフィスビル内の人数変化の頻度などに影響を受けるため、オフィスビルごとに設定する必要がある。

### 3.3 外挿時の補正

提案方式では、電力需要量と説明変数の相関が正しく学習できていれば、既存の予測方式の課題であった学習データに最高気温などの条件が類似した日が存在しない場合にも対応できる。しかし、一般的に重回帰分析を用いた予測方式では、予測日の予想最高気温や予想最低気温が学習データの最高気温や最低気温から外れていた場合（外挿が発生した場合）に予測精度が低下するという課題がある。特に本論文の提案方式では、学習データ数を25日と短くしているため、予測日の予想最高気温・最低気温や予測開始時の電力需要量のいずれかが学習データの範囲外となる可能性が高い。また、学習データ数を少なくするために電力需要量と2次の相関がある最高気温を線形の相関として（最高気温のみを用いて）予測しているため、短い期間、すなわち予測日の最高気温が学習データの範囲内に収まっている場合は問題ないが、外挿が発生した場合には線形の相関は適さず、大きな予測誤差を生む可能性がある。

この課題に対応すべく本論文では、重回帰分析の電力需要量予測値が学習データの電力需要量実測値から外れていた場合に、電力需要量予測値の補正を行う。具体的には、時刻  $t$  の電力需要量を重回帰分析により予測し、その予測値  $P_t$  が同時刻の学習データ（過去25日分）の電力需要量  $L_{t,1}, L_{t,2}, \dots, L_{t,25}$  の最大値と最小値の範囲外である場合に式(2)と式(3)の補正を行う。

- 予測値が学習データの最大値より大きい場合

$$P_t = \max(L_{t,1}, L_{t,2}, \dots, L_{t,25}) \quad (2)$$

- 予測値が学習データの最小値より小さい場合

$$P_t = \min(L_{t,1}, L_{t,2}, \dots, L_{t,25}) \quad (3)$$

式(2)と式(3)の補正により、外挿が発生した場合に予測値が大きく外れるのを防ぐことができる。

なお、提案方式の補正方法は電力需要量の予測値を過去の電力需要量が推移した範囲に抑えるものであり、気温の変化にあわせて正確に電力需要量を予測することはできない。しかし、学習データが少ない状況では、外挿時に電力需要量を過大もしくは過小に予測する場合があります。また、その環境（オフィスビル）でどの程度の範囲内で電力需要量が推移するかも分からないため予測値が異常値かどうか判断できない。そのため、外挿が発生した場合は少ない学習データから真値に近い電力需要量を予測しようとするのではなく、学習データの中から真値に最も近いであろう電力需要量を予測値とすることで、正確には予測できないがその環境の電力需要量の推移範囲から著しく外れた予測

をしないようにしている。

## 4. 評価

### 4.1 予測条件

本論文では、1つのオフィスビル全体の電力需要量を用いて提案方式を評価した。予測条件を表2に示す。予測時間を8時から17時までとしているのは、予測が特に必要な1日の最大電力需要量となる時間帯（就業時刻）に合わせたためである。このほかの時間帯はビル内の人数が少なく、それにともない電力需要量も小さいことから節電および予測の必要性が低いため、評価から除外した。

表2の期間においてこのオフィスビルでは、出張などにより日々人数は変化しているものの、大規模で長期間継続する人数の変化は起きていない。しかし、月単位の平均人数が緩やかに増加・減少していることがあり、2カ月間で在中人数が約30人（予測期間の平均在中人数の6%）増加していることもあった。建物内の人数変化は電力需要量に影響する。したがって、このオフィスビルでは提案方式の学習により多くのデータ（予測日から2カ月前のデータ）を用いても人数変化によって電力需要量が変化しているため予測精度の向上につながらず、結果として在中人数が予測日と類似している過去1カ月（過去25日分）の学習データを予測に用いることで最も予測精度が向上していた。

なお、提案方式で用いている予測開始時の電力需要量は、本評価では7時に計測された電力需要量である。また、提案方式では過去25日間のデータで学習するとしているが、その学習データはすべて出勤日のデータとし、休日のデータは傾向が大きく異なるため除外した。

本論文では予測方式の評価指標を各時刻の電力需要量実測値と予測値の平均絶対誤差率としている。予測方式の評価指標は予測結果の運用方法に合わせて複数考えられる。たとえば、予測結果に基づいて事前に電力を充電しておく、ピーク時に放電することでピーク電力の削減をするのであれば、ピーク前後の時間帯の電力需要量合計値の実測値と予測値の誤差率が重要となる。本論文では、実際にどのように予測結果を運用するかは決定していないため、各時刻の電力需要量の予測精度を平等に評価することを目的として各時刻の電力需要量の平均絶対誤差率を評価指標としている。

表2 予測条件

Table 2 Forecasting condition.

建物	オフィスビル (9階建て, 延床面積約 16,000m <sup>2</sup> )
期間	2010年3月18日~2011年3月10日 (出勤日のみ)
予測時間	8時から17時までの電力需要量を1時間単位
建物内の人数	平均470人在中 (400~500人で推移)

### 4.2 年間の予測精度の評価

表2に示した予測条件でオフィスビルの電力需要量を予測し、提案方式の予測精度を評価した結果を表3に示す。表3では、提案方式による予測精度の改善度を確認するため、同条件において2章で述べた既存の予測方式を用いた結果も示している。評価の結果、提案方式の予測精度は5.4%であり、既存の予測方式の予測精度6.2%より予測精度が向上している。

さらに、本論文では提案方式の予測精度の改善をより詳細に分析するため、予測精度の分布と各時間帯の予測精度、月単位の平均予測精度を評価した結果を、図3と図4、図5に示す。

表3 提案方式の予測精度

Table 3 Forecasting error of proposal method.

予測方式	平均絶対誤差率 (%)
提案方式	5.4
既存の予測方式	6.2

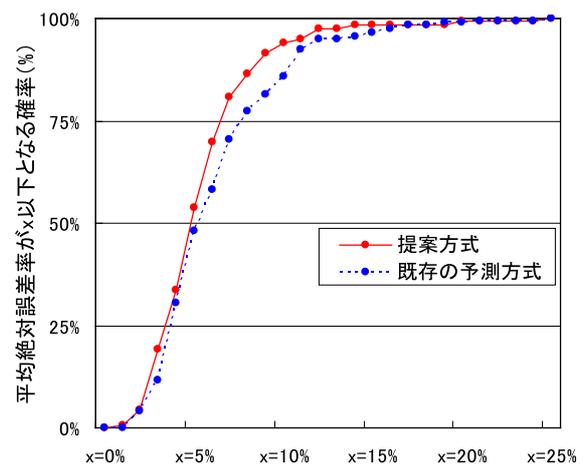


図3 提案方式の予測精度の分布

Fig. 3 Forecasting error distribution of proposal method.

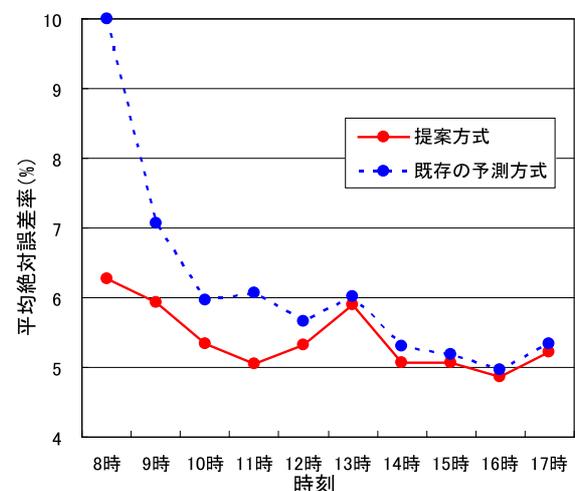


図4 提案方式の各時間帯の予測精度

Fig. 4 Hourly forecasting error of proposal method.

評価の結果、図 3 に示すように提案方式は既存の予測方式より予測精度が良いほうに分布する確率が高くなっている。ビルの電力需要量の予測結果は日々節電のために用いられ、予測が大きく外れれば節電の目標値を超えてしまい、翌年の電気料金の値上げにつながる恐れもある。そのため、平均の予測精度が良いだけでなく、つねに安定した予測精度が必要であり、提案方式は既存の予測方式よりオフィスビルの電力需要量の予測に適している。

また、図 4 で示すように提案方式では、特に午前中の予測精度が改善されている。これは、最高気温のほか最低気温、予測開始時の電力需要量を用いたためであり、提案方式では、各時間帯で精度の高い予測が可能であることを確認した。

図 5 は、月単位の平均予測精度を示したものである。提案方式は、既存の予測方式より 5 月を除いたすべての月で予測精度が向上している。特に電力需要量が増加し、電力削減の必要性が高まる夏期（7 月～9 月）や冬期（12 月～3 月）の予測精度が向上している。そのため、予測誤差の少ない提案方式の予測結果をもとに機器を制御することで、必要以上に空調や照明の電力需要量を削減して快適性が低減したり、電力削減量が足りずに節電の目標値を超えたりする可能性を低減させることができる。

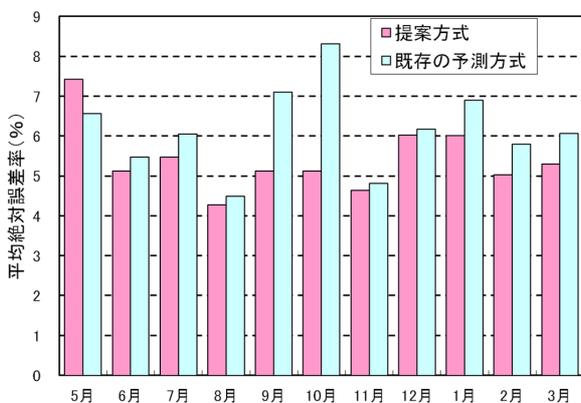


図 5 提案方式の月単位の平均予測精度

Fig. 5 Monthly forecasting error of proposal method.

### 4.3 説明変数の妥当性の評価

本論文では、オフィスビルに適した説明変数として最高気温と最低気温、予測開始時の電力需要量を選択したが、これらの説明変数がオフィスビルに適しているか評価するため、説明変数を変更し、表 2 に示した予測条件でオフィスビルの電力需要量を予測した。その予測結果が表 4 である。

表 4 では、提案方式で説明変数として用いている最高気温、最低気温、予測開始時の電力需要量の中からいずれか 1 つを減らした場合と、提案方式に最高気温の 2 乗値、前日同時刻の電力需要量、前日の最大電力需要量のいずれか 1 つを新たに説明変数として追加した場合の予測精度を示している。なお、予測開始時の気温は、最低気温を用いた場合と類似した結果が得られていたため、表 4 では示していない。

評価の結果、提案方式から説明変数をどれか 1 つ減らしても予測精度が低下しており、また、提案方式に最高気温の 2 乗値や前日同時刻の電力需要量、前日の最大電力需要量を説明変数として追加しても予測精度が向上しないと確認した。説明変数を増やすことは外挿の発生確率の増加にもつながるため、提案方式で説明変数として用いている最高気温、最低気温、予測開始時の電力需要量の組合せが最も予測精度が向上し、かつ、説明変数の種類も少ないため、オフィスビルの電力需要量の予測に適していると確認した。また、オフィスビルの電力需要量は最高気温と最低気温、予測開始時の電力需要量との相関はあるため、他のオフィスビルでもこれらの説明変数がこれらの説明変数に新たな説明変数を追加したものが、最適な説明変数として選択されると思われる。

## 5. 考察

### 5.1 既存の予測方式との比較

提案方式の予測精度を分析した結果、提案方式では既存の予測方式の課題であった学習データに最高気温が類似した日が見つからない場合や最高気温が同じでも午前や日没後の電力需要量が異なる場合にも対応できており、予測精

表 4 説明変数を変更した場合の予測精度

Table 4 Forecasting error of each explanatory variables.

説明変数	平均絶対誤差率 (%)
最高気温, 最低気温, 予測開始時の電力需要量 (提案方式)	5.4
最高気温, 最低気温	5.7
最高気温, 予測開始時の電力需要量	5.8
最低気温, 予測開始時の電力需要量	5.9
最高気温, 最低気温, 予測開始時の電力需要量, 最高気温の 2 乗値	5.4
最高気温, 最低気温, 予測開始時の電力需要量, 前日同時刻の電力需要量	5.4
最高気温, 最低気温, 予測開始時の電力需要量, 前日の最大電力需要量	5.4

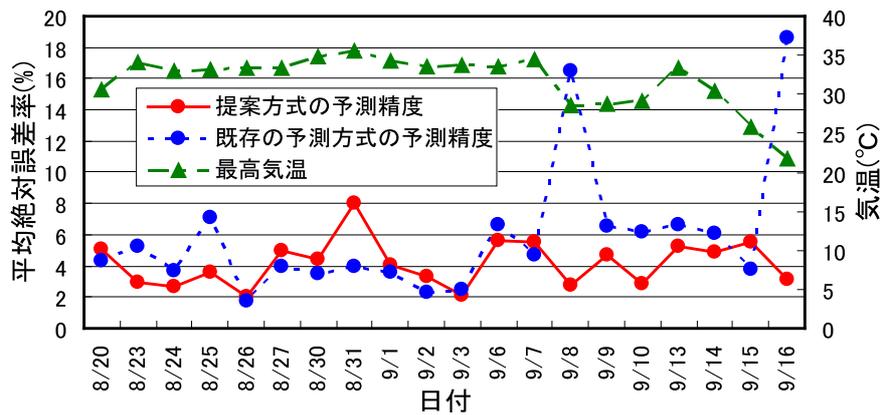


図 6 最高気温の変化による提案方式と既存の予測方式の予測精度の推移  
 Fig. 6 Change of forecasting error and maximum temperature.

度の向上が確認された。

図 6 は、過去データに最高気温が類似した日が見つからない場合で予測精度が改善された一例として、2010 年 8 月 20 日から 2010 年 9 月 16 日までの提案方式と既存の予測方式の予測精度の推移を最高気温の推移とあわせて示したものである。9 月 8 日と 9 月 16 日は過去数日間と比べると最高気温が低下している。そのため、既存の予測方式では最高気温が類似した日が学習データから選択できず予測精度が低下していた。

一方、提案方式では、最高気温などの条件が類似した日を特定するのではなく、重回帰分析で近日の説明変数と電力需要量の相関を正しく学習し、予測していたため、最高気温の低下にも対応して精度良い予測が可能であった。また、9 月 16 日は最高気温が学習データの最高気温より著しく低下していたため、外挿により重回帰分析の予測値が大きく外れそうになったが、外挿時の補正により、安定した予測精度が得られた。

図 7 は、既存の予測方式の課題であった最高気温が同じでも午前や日没後の気温が異なり、電力需要量が異なる場合に提案方式が対応できていることを示したものである。図 1 でも述べたように、2010 年 6 月 21 日と 6 月 29 日はともに最高気温が同じであるが、午前の気温が異なるため、午前中の電力需要量が異なっている。既存の予測方式では、最高気温のみを用いて予測しているため、6 月 29 日も 6 月 21 日と同様に電力需要量が変化すると予測し、予測精度が低下していた。しかし、提案方式では最高気温のほかに最低気温も用いていたため、最低気温の変化から午前中の電力需要量の変化を学習し、予測できていた。

### 5.2 外挿時の補正の効果

提案方式では 3.3 節で述べた外挿時の補正により予測精度の改善が見られた。表 5 は、表 2 の実験条件で提案方式を用いて電力需要量を予測した際に外挿が発生したデータのみを抽出したものである。外挿が発生した際に補正を

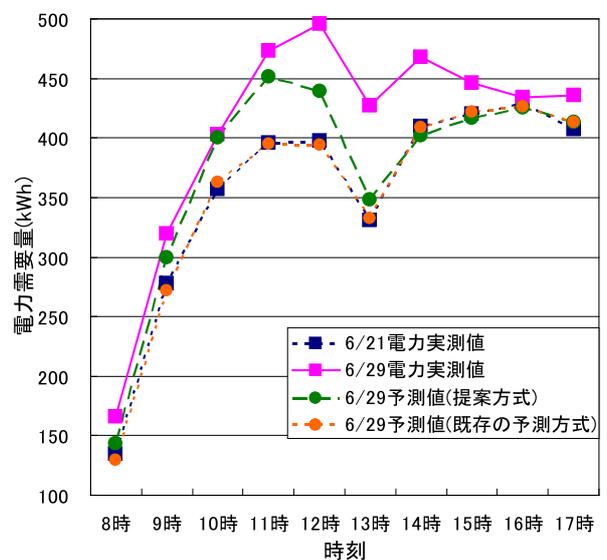


図 7 最低気温を用いたことによる提案方式の改善例  
 Fig. 7 Improvement example of proposal method.

表 5 外挿時の補正の有無による予測精度の差  
 Table 5 Change of forecasting error by the presence or absence of correction.

予測方式	平均絶対誤差率 (%)
外挿時に補正をする場合 (提案方式)	6.0
外挿時に補正をしない場合	6.9

行うか行わないかで予測精度がどのように変化するか示している。評価の結果、外挿時に補正をした場合の予測精度は 6.0%、しなかった場合の予測精度は 6.9%であり、補正の追加により、過剰に増加または低減された電力需要量予測値が発生せず、予測精度の向上が確認できた。

### 5.3 課題

提案方式では外挿時に補正を行うことで予測精度が向上しているが、この補正は外挿時の大幅な予測のずれを防ぐためのものであり、気温変化に合わせた電力需要量の正確

な予測は行っていない。そのため、表3と表5を比較して分かるように提案方式では、外挿時に若干の予測精度の低下が発生するという課題がある。過去のデータが豊富であれば、前年の予測日と同じ時期の最高気温や最低気温が類似しているデータを学習データとすることで外挿を発生させずに正確に予測が可能である。

したがって、本論文の提案方式は、新たにデータの計測を開始し、過去のデータ数が少ない場合や、新たな節電の取り組みにより空調稼働形式が変わり、過去のデータが参考にならなくなった場合などの学習データが十分に得られない場合に活用するものである。保持している過去のデータ数が増加した場合は、その増加に合わせて学習データ数を増やす必要がある。しかし、学習データ数の増加により予測の参考にならないデータ（たとえば、予測方式に取り入れていない要因によって電力需要量が増えているデータ）を含んでしまう可能性があるため、ただ学習データ数を増やしても予測精度は向上しない。予測精度を向上させるには最適な学習データ数を自動で決定する方法が必要である。この学習データ数の決定方法としては、たとえば、すでに実測値が計測されている予測日前日や前々日の電力需要量を学習データ数を変更して予測し、実際に予測精度が向上するか確認しながら学習データ数を決定する方法 [12] がある。

また、提案方式では、過去の電力需要量と気温のみで予測しているが、予測方式に取り入れていない要因により電力需要量が増えた場合に予測精度が低下する。図6の8月31日はその一例であり、この日は人が常駐していないエリア（会議室）の電力需要量の利用状況が変わったため、提案方式で予測精度が低下していた。もし、会議室の利用状況などの電力需要量の変化と相関のあるデータが取得できるのであれば、取得できる情報に合わせて新たな予測方式を検討する必要がある。

## 6. おわりに

本論文では、可能な限り少ない種類と短期間のデータでオフィスの電力需要量を予測する方式として、最高気温、最低気温、予測開始時の電力需要量のみを用いる重回帰分析による予測方式を提案し、実験により有効性を確認した。その結果、予測精度は5.4%であり、最高気温のみを用いた既存の予測方式の予測精度6.2%より改善できていることが確認できた。さらに、提案方式では、学習データの各時刻の電力需要量最大値・最小値による補正を加えることで、重回帰分析を用いた予測方式の課題である外挿に対応し、より安定した予測が可能であることを確認した。

提案方式は、少ない種類と量のデータで電力需要量を予測するという同じ目的を持つ2章で述べた既存の予測方式 [13] と比較すると学習データの種類と量が増えている。しかし、提案方式は2章の既存の予測方式より予測精度は向上してお

り、また、過去数年分のデータを必要とするニューラルネットワークを用いた予測方式 [2], [3], [4], [5], [6], [7], [8] や本提案と同様の重回帰分析を用いた予測方式 [4], [9], [10], [11], [12] と比較すると、予測に必要なデータが過去25日分の電力需要量と最高気温、最低気温のみであるため、十分少ない。そのため、提案方式は多くのオフィスビルに幅広く適用できるものである。

今後の課題としては、5.3節で述べたように学習に用いることができるデータ数が豊富になった場合に、データの増加に合わせて学習データ数や説明変数を新たに追加して予測精度の向上を図る予測方式の検討などが考えられる。また、本論文では多くのオフィスビルに幅広く適用できるように電力需要量と気温のみを用いた予測方式を提案しているが、オフィスビルから得られる情報（たとえば、建物内の人数や会議室の利用状況など）に合わせて新たな予測方式を検討する必要がある。

## 参考文献

- [1] 資源エネルギー庁：「平成23年度エネルギーに関する年次報告」（エネルギー白書2012），入手先（<http://www.enecho.meti.go.jp/about/whitepaper/2012html/>）（参照2014-05-07）。
- [2] 牧野恭子，島田 毅，市川量一，小野雅也，遠藤経一：ニューラルネットによる電力需要予測とその予測誤差低減手法の提案，電気学会電力・エネルギー部門誌，Vol.115，No.11，pp.1304-1313（1995）。
- [3] 荒家良作，植木芳照，松井哲郎：ニューロ・ファジィを用いた最大電力予測システムの開発，オペレーションズ・リサーチ：経営の科学，Vol.41，No.9，pp.487-492（1996）。
- [4] 田中英一，長谷川淳，伊藤正義：重回帰分析と階層型ニューラルネットによる翌日電力需要予測，オペレーションズ・リサーチ：経営の科学，Vol.41，No.9，pp.499-503（1996）。
- [5] 石岡 修，佐藤佳彦，石原 徹，植木芳照，松井哲郎，飯坂達也：NN 応用電力需要予測システムの開発，電気学会電力・エネルギー部門誌，Vol.120，No.12，pp.1550-1557（2000）。
- [6] 飯坂達也，松井哲郎，福山良和：構造化ニューラルネットワークの新しい学習法と最大電力需要予測への適用，電気学会電力・エネルギー部門誌，Vol.124，No.3，pp.347-354（2004）。
- [7] 小林正行：環境変化に対応した電力需要予測システムの開発，中部電力株式会社技術開発ニュース，No.123，pp.25-26（2006）。
- [8] 柳田将臣，石亀篤司：独立成分分析を前処理に用いた電力需要予測，電気学会電力・エネルギー部門誌，Vol.127，No.10，pp.1094-1095（2007）。
- [9] 灰田武史，武藤昭一：重回帰手法に基づいた最大需要予測支援システムの開発，オペレーションズ・リサーチ：経営の科学，Vol.41，No.9，pp.476-480（1996）。
- [10] 伊東重信，雪田和人，後藤泰之，一柳勝宏，中野寛之：気温地域分布および各近日データ比較値を用いた翌日最大電力需要予測，電気学会電力・エネルギー部門誌，Vol.130，No.3，pp.329-337（2010）。
- [11] 樋田祐輔，横山隆一，清水川純，伊庭健二，田中晃司，関 知道：需要家における需要予測を用いた電力貯蔵用システムの運用制御，電気学会電力・エネルギー部門誌，Vol.130，No.11，pp.995-1000（2010）。
- [12] 小林秀徳，所 健一，篠原靖志，井上俊雄，野見山史敏，

- 井手敏郎：3時間先電力需要予測手法，オペレーションズ・リサーチ：経営の科学，Vol.56, No.9, pp.530-534 (2011).
- [13] 川野裕希，山田敏志，阿倍博信，中島宏一：複数の予測法の組合せによる需要家向けの電力需要予測方式の提案，情報処理学会論文誌 コンシューマ・デバイス&システム (CDS)，Vol.3, No.1, pp.53-63 (2013).
- [14] 資源エネルギー庁：夏期最大電力使用日の需要構造推計（東京電力管内），入手先 (<http://www.meti.go.jp/setsuden/20110513taisaku/16.pdf>)（参照 2013-04-11）.



川野 裕希

平成 21 年九州大学工学部電気情報工学科卒業，平成 23 年同大学大学院システム情報科学府修士課程修了，同年三菱電機株式会社入社。以来，ビルシステムの研究開発に従事。コンシューマ・デバイス&システム (CDS) 研究会，電気学会各会員。



山田 敏志 (正会員)

平成 11 年新潟大学工学部情報工学科卒業，平成 13 年同大学大学院自然科学研究科修士課程修了，同年三菱電機株式会社入社。以来，携帯電話，映像監視システムの研究開発に従事。



阿倍 博信 (正会員)

昭和 63 年慶応義塾大学理工学部計測工学科卒業，平成 2 年同大学大学院理工学研究科修士課程修了，同年三菱電機株式会社入社。以来，グループウェアシステム，マルチメディア応用システムの研究開発に従事。平成 17 年慶応義塾大学大学院理工学研究科後期博士課程修了。博士 (工学)。電子情報通信学会，日本ソフトウェア科学会，映像情報メディア学会，画像電子学会，教育システム情報学会各会員。



中島 宏一

昭和 59 年早稲田大学理工学部電気工学科卒業，同年三菱電機株式会社入社。以来，テレビ会議システム，映像監視システム等のマルチメディア応用に関わる研究開発に従事。