

コンシューマ・システム論文

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

川野 裕希^{1,a)} 山田 敏志¹ 阿倍 博信¹ 中島 宏一¹

受付日 2012年5月18日, 採録日 2012年12月7日

概要: 東日本大震災の影響で電力不足が問題となる等, 省エネの重要性がこれまで以上に高まっている. 省エネ技術の1つに建物の過去の電力需要量等から翌日 24 時間分の電力需要量を予測し, 計画的に機器を制御するものがある. しかし, 建物の電力需要量は気温や曜日, 建物内の人数等により日々複雑に変化するため, すべての日を精度良く予測するのは困難であった. そこで, 本論文ではビルの電力需要量の変化を分析し, いくつかのパターンに分け, 各パターンに適した予測法を使い分ける手法について提案する. これにより, 電力需要量の複雑な変化に対応して, 高精度な予測が可能な手法の実現を目指す.

キーワード: 電力需要予測, 回帰分析, クラスタリング

Proposal of Electricity Demand Forecasting Method for Customer by Combination of Multiple Methods

HIROKI KAWANO^{1,a)} SATOSHI YAMADA¹ HIRONOBU ABE¹ KOICHI NAKASHIMA¹

Received: May 18, 2012, Accepted: December 7, 2012

Abstract: Recently, an electricity shortage is especially serious in Japan. Thus, we need an electricity demand forecasting method for customer to save energy. This is because we can control some equipment in buildings more effectively by getting an electricity demand for tomorrow. However, an electricity demand of buildings changes complexly by the weather or temperature. In this paper, we suggest an electricity demand forecasting method robust for the complex change by the combination of multiple forecasting methods, which have different advantages.

Keywords: electricity demand forecasting, regression analysis, clustering

1. はじめに

東日本大震災の影響で電力不足が問題となる等, 省エネの重要性がこれまで以上に高まっている [1]. 省エネの1つの手法として, ビルや家庭等の電力需要量を可視化し, 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手法がある. しかし, どれくらいの節電が必要なのか不明なまま機器 (照明や空調等) を制御するので, 過剰に節電してしまうという課題があった.

上記課題を解決するために, ビルや家庭等の需要家に対

象とした電力需要量を予測する技術が必要となっている. たとえば過去の電力需要量を基に翌日 24 時間分の電力需要量を予測することで, 事前に節電が必要な時間帯や減らすべき節電量が分かるため, 必要最低限の空調や照明だけを停止する, もしくは, 空調の運転開始等の電力需要量が大きい処理を他の時間帯にする等, より計画的な制御ができる.

電力需要予測方式は, 電力会社等の供給家が電力を需要量に合わせて過不足なく発電し, 供給するため必要であった. より安定かつ効率的に電力を供給するためにも予測精度の向上が必須であり, 様々な研究が行われてきた [2], [3], [4], [5], [6], [7], [8], [9], [10], [11].

供給家を対象とした予測精度の高い予測法は多数存在す

¹ 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

^{a)} kawano.hiroki@dc.mitsubishielectric.co.jp

るが、供給家向けの予測法を需要家向けとして導入するのは困難である。これは、供給家と需要家では予測に用いる入力情報の種類（天候や曜日等）や量が大きく異なるからである。供給家は、予測精度の向上のために豊富な種類のデータや過去数年分等の長期間のデータを用いて予測を行う。一方、ビルや家庭等の需要家では各需要家によって条件が異なり、取得できるデータの種類や量が限られてしまう。

また、需要家（ビル等）の電力需要量は気温や曜日、建物内の人数等により日々複雑に変化するため、すべての日を精度良く予測するのは困難であるという問題があった。特に電力需要量や気温、湿度等の予測に用いる入力情報の種類が少ない予測法 [12], [13] では、すべての状況に対応して精度良く予測するのは困難であり、気温の変化等による突発的な電力需要量の変化に対応できず、予測精度が大きく低下することがあった。

本論文では需要家、特にビルを対象とした翌日 24 時間分の電力需要量を 1 時間単位で精度良く予測できる技術について提案する。提案する予測法はビルの電力需要量の変化を分析し、いくつかのパターンに分け、各パターンに適した特性の異なる複数の予測法を使い分ける手法である。これにより、電力需要量の複雑な変化に対応して、高精度な予測が可能となる。また、本論文で提案する予測法は幅広い適用のため予測に用いる入力情報の種類を少なくしつつ、高い予測精度を実現する技術の開発を目的としている。以下では、複数の予測法を使い分けることで高精度な予測が可能であることを実験により確認する。具体的には、気温情報を基に電力需要量の変化を 2 つのパターンに分け、各パターンに適した 2 つの予測法を使い分ける手法を用いて、実際にビルの電力需要量を予測し、評価する。その結果を単一の予測法で予測した場合と比較することで高精度な予測が可能であることを示す。

なお、本論文の評価で用いている電力需要量は 1 つのオフィスビル全体から計測したものであり、予測精度を日中（8 時から 17 時）、夜間（17 時から 22 時）、深夜（22 時から 8 時）に分けて評価を行う。これは、各時間帯によって建物内にいる人数が異なり、電力需要量の変化も異なるからである。いずれは、各時間帯に適した予測法の開発を目指す。本論文では最大電力需要量を含む日中（8 時から 17 時）の予測結果に着目し、日中（8 時から 17 時）の予測結果のみ考察している。

また、本論文では翌日 24 時間分の電力需要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き、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。

以下では、2 章で需要家向けの電力需要予測方式の課題について説明する。3 章では本論文で提案する 2 つの予測法を使い分ける手法について説明し、4 章では提案手法を評価した結果について述べる。5 章では結果を考察し、6 章では本論文のまとめについて述べる。

2. 需要家向けの電力需要予測方式の課題

本章では、需要家向けの電力需要予測方式の課題を明確化するために、需要家を対象として提案された従来の予測法 [12] を用いて予測精度を評価した結果について述べる。

2.1 従来の需要家向けの電力需要予測方式 [12]

従来の予測法は、大学等のように曜日ごとに授業時間割や利用時間が決まっており、各施設で電力需要量の再現性が見られる場合に適した需要家向けの予測法である。大学等以外の建物でも曜日や気候により電力需要量は再現性が生じるので、従来の予測法はあらゆる建物への応用が可能である。

従来の予測法は、過去数日間の各時刻間の平均電力需要変動量を用いて、翌日 24 時間分の電力需要量を予測する手法である。従来の予測法の概要を図 1 に示す。従来の予測法では、まず予測日前日から過去 n 日分のデータで、1 時間ごとに電力需要量実測値の差分を求め、各時刻間の平均電力需要変動量を算出する。その後、予測開始 1 時間前の電力需要量実測値に各時刻間の平均電力需要変動量を足




図 1 従来の予測法の概要

Fig. 1 Electricity demand forecast with existing method.

し合わせていくことで翌日 24 時間分の電力需要量を求める予測法である。なお、本論文では従来の予測法に用いた予測日前日から過去 n 日分のデータのように予測に用いるデータのことを学習データとして定義する。

2.2 事前評価

従来の予測法を用いて表 1 の条件で予測し、予測精度を評価した。学習データの日数 n は実験により予測日前日から 5 日前までのデータが最適であったため、 $n = 5$ としている。学習データの日数 n が 5 日となったのは、学習データは気象や人数の変化による電力需要量の大きな変動を考慮すると予測日近日のデータを選択することが望ましく、また、日々の電力需要量の増減や外れ値の影響を考慮するとある程度の日数を学習データとして用いることが望ましいので、両方の観点から過去 $n = 5$ 日分（過去の平日 1 週間）のデータを用いることが最適であったためである。評価の結果を表 2 に示す。予測精度（8 時から 17 時までの平均誤差率）は 7.53% であった。

2.3 課題

従来の予測法の精度を評価した結果、予測精度が大きく低下している日が複数見られた。その原因は過去数日間にならぬ程急激に電力需要量が変化した場合に対応できなかったからである。

図 2 と表 3 は、予測精度が特に悪い予測日（2010 年 7 月 29 日）とその学習データ（2010 年 7 月 22 日から 28 日）の 8 時から 17 時までの電力需要量実測値を示したものである。図 2 と表 3 の予測日では、過去 5 日間と比べて電力需要量実測値が急激に低下している。そのため、学習データが予測日の電力需要量実測値の変化と類似しておらず、予測精度が大きく低下していた。

表 1 実験条件

Table 1 Experiment condition.

建物	オフィスビル(9 階建て, 延床面積約 16,000m ²)
期間	2010 年 6 月 24 日～2010 年 12 月 17 日(平日のみ)
予測時間	8 時から翌日 8 時までの 24 時間分の電力需要量を 1 時間単位
予測結果	日中(8～17 時), 夜間(17～22 時), 深夜(22～8 時)ごとに評価

表 2 従来の予測法の予測精度

Table 2 Forecasting error of existing method.

各時刻間の平均誤差率	従来の予測法
8～17 時平均誤差率(%)	7.53
17～22 時平均誤差率(%)	7.70
22～8 時平均誤差率(%)	17.69
24 時間平均誤差率(%)	11.37

このように従来の電力需要予測システムの課題は、ビルの電力需要量が天気や気温、湿度だけではなく、建物内の人数の変動や行事等様々な要因で複雑に変化するため、すべての状況に対応できず、予測精度が低下することであった。特に、単一の予測法では精度良く予測できる状況に限られ、図 2 と表 3 のように予測精度が大きく低下することが多数あった。

この課題に対応するには、供給家向けの電力需要予測方式と同様に多種類の入力情報の使用 [3], [8], [9] や過去数年分のデータの使用 [3], [4], [5], [6], [7], [9], [10], [11], [13] 等が必要である。しかし、入力情報や過去のデータ数を増やすほど適用できる対象が狭くなってしまい、あらゆるビルへの利用は困難となってしまう。

3. 2 つの予測法の組合せによる電力需要予測方式の提案

本章では、需要家向けの電力需要予測方式の課題を解決するため、特性の異なる複数の予測法を使い分け、電力需要量の複雑な変化に対応する手法について提案する。前章でも述べたように単一の予測法では精度良く予測できる状況に限られてしまう。そこで提案手法では、入力情報の種




図 2 8～17 時の電力需要量実測値 (2010/7/22～29)

Fig. 2 Electricity demand from 8am to 5pm (2010/7/22-29).

表 3 8～17 時の電力需要量実測値 (2010/7/22～29)

Table 3 Electricity demand from 8am to 5pm (2010/7/22-29).

時刻	8 時	9 時	10 時	11 時	12 時	13 時	14 時	15 時	16 時	17 時
7/29(kWh)	176	316	399	421	414	294	392	422	422	427
7/22(kWh)	222	452	544	554	546	377	510	537	527	519
7/23(kWh)	244	450	576	592	569	386	528	535	527	473
7/26(kWh)	234	447	543	557	539	378	554	550	550	546
7/27(kWh)	243	431	516	525	512	355	518	536	540	526
7/28(kWh)	228	421	515	531	521	347	486	495	507	481




図 3 提案手法の予測の流れ

Fig. 3 Algorithm of proposal method.

類や過去のデータ数が少なくても予測可能な特性（精度良く予測できる状況）が異なる予測法を複数用意し、各予測法を適切に使い分けることで予測精度の向上を図る。これまでの研究では、単一の予測法において学習期間や入力情報の種類を季節等によって使い分けて、特性を変化させることで予測精度の向上を図る手法 [4], [5], [8], [14] は存在した。本論文の提案手法では予測法を変更することで、より大きく特性の変更ができる。また、同じ入力情報でも予測法が異なれば得られる予測結果も異なるため、得られる入力情報の種類が少ない条件下でも特性の変更が可能となり、予測精度の向上が期待できる。

本章では複数の予測法を使い分ける手法として、ビルの電力需要量の変化を気温情報によって分析し、2つのパターンに分け、各パターンに適した予測法を使い分ける手法について述べる。各予測法は入力情報の種類や過去のデータ数が少なくても予測可能な手法である。

以下では、まず電力需要量と気温情報の関係について分析し、2パターンの電力需要量の変化について説明する。その後、各パターンに適した予測法を提案する。また、2つの予測法を使い分けるためには、予測開始時に2つの予測法のどちらが適しているか選択する必要があるため、識別法についても提案する。図 3 は提案手法の予測の流れを示したものである。

本論文で電力需要量の分析に気温情報を用いたのは、気温が電力需要量の変化と相関があるとされ、多くの文献 [2], [3], [4], [5], [6], [7], [8], [9], [10], [11], [13], [14] で使用されているからである。また、気温の変化が大きく影響する空調の電力需要量がビル全体の電力需要量の 5 割を占めるからである [15]。

3.1 気温情報と電力需要量の関係の分析

気温情報を用いて 2.2 節で用いたオフィスビルの電力需要量の変化を分析したところ、電力需要量の急激な変化の原因の 1 つは最高気温の変化であった。また、電力需要量は最高気温の変化に着目すると大きく分けて 2 つの傾向があると判明した。1 つ目は過去数日間の最高気温の変化が小さいため、日々の電力需要量の変化も小さく、安定して

表 4 最大電力需要量と最高気温の推移 (2010/7/22~29)

Table 4 Change of peak demand and maximum temperature.

日付	7/22	7/23	7/26	7/27	7/28	7/29
最大電力需要量(kWh)	554	592	557	540	531	427
最高気温(°C)	34.5	33.9	32.4	32.1	31.2	26.7

いる場合（以下、パターン ①）である。2 つ目は最高気温が急激に変化したため、電力需要量も過去数日間にないほど急激に変化する場合（以下、パターン ②）である。

表 4 は、パターン ① とパターン ② の変化を表す一例として図 2 と表 3 で示している予測日と過去 5 日間の学習データの最大電力需要量と最高気温の推移を示したものである。図 2 と表 3 の過去 5 日間の学習データ（2010 年 7 月 22 日から 28 日）の電力需要量実測値は最高気温の変化が安定しているため、日々の電力需要量実測値の変化が小さく、安定している。一方、予測日（2010 年 7 月 29 日）は前日と比較して最高気温が 4.5°C も低下しているため、それにともない電力需要量実測値も大きく低下している。

このように電力需要量は最高気温に合わせて大きく変動しており、2010 年 6 月 24 日から 2010 年 12 月 17 日までの各日の最大電力需要量と最高気温を基に相関係数を計算したところ 0.93 もの高い相関が得られた。したがって、予測精度の向上には気温情報が必要であり、気温を用いていない従来の予測法では、電力需要量の変動（パターン ②）に対応できず、予測精度が大きく低下する結果となった。

本論文では上記の 2 つのパターンに柔軟に対応できる 2 つの予測法を適切に使い分けることで予測精度の向上を図る。電力需要量の変化が安定しているパターン ① に適した予測法として予測法 ① を、電力需要量が急激に変化するパターン ② に適した予測法として予測法 ② を使い分ける。

3.2 予測法 ① の提案

予測法 ① は、過去数日間の電力需要量の変化が小さく、安定している場合（パターン ①）に高精度な予測ができなければならない。パターン ① に関しては従来の予測法でも対応可能であるが、本論文ではさらに予測精度を高めるため、予測日の予想最高気温と過去の気温情報を用いて改良した予測法を提案する。

従来の予測法では、予測日前日から過去 n 日分の電力需要量を用いて予測していたが、予測日の電力需要量実測値の変化と類似していない日が含まれていたため精度が低下していた。そこで、予測法 ① では、予測日の予想最高気温と過去の最高気温を用いて予測日の変化に類似しているデータ（以下、類似日）を学習データとして選択し、予測することで予測精度を向上させる。図 4 は予測法 ① の概要を示したものである。

本論文の予測法 ① では最初に予測日の予想最高気温を予測日前日から過去 m 日間の最高気温実測値と比較し、誤




図 4 予測法 ① の概要

Fig. 4 Electricity demand forecast with proposal method ①.

差が小さい順に n 日選択する．その後，最高気温が類似している n 日分のデータを学習データとして，各時刻の電力需要量実測値を平均することで翌日 24 時間分の電力需要量を予測する手法である．

3.3 予測法 ② の提案

予測法 ② は，過去数日間にないほど急激に電力需要量が変化した場合（パターン ②）に高精度な予測ができなければならない．そこで，過去の電力需要量実測値ではなく，変化の原因である気温情報に着目し，予測日の予想最高気温を基に予測する手法を提案する．最高気温は電力需要量の変化（最大電力需要量）と高い相関があるため，予測日の予想最高気温を用いれば電力需要量の急激な変化にも対応できる．

本論文では，予想最高気温を用いて電力需要量を予測する手法として単回帰分析を用いた．具体的には以下の式 (1) のように予測日の予想最高気温 T を説明変数として，目的変数である最大電力需要量 P を予測する．

$$P = \alpha \times T + \varepsilon \quad (1)$$

上記の式 (1) で求めた最大電力需要量予測値 P に合うように予測法 ① の予測結果を補正（増減）することで翌日 24 時間分の電力需要量を予測する手法である．予測法 ② の概要は図 5 のとおりである．回帰係数 α と残差 ε は，予測法 ① の学習データを探索する範囲に合わせて，過去 m 日間の最大電力需要量実測値と最高気温を用いて予測日ごとに最小 2 乗法により導出する．

単回帰分析を用いた予測法は，予測日の予想最高気温のみを用いて最大電力需要量を予測するため，過去数日間にないほど最高気温が変化し，それにともない最大電力需要




図 5 予測法 ② の概要

Fig. 5 Electricity demand forecast with proposal method ②.

量が変化しても，最高気温と最大電力需要量の関係（回帰係数 α と残差 ε ）が保たれているのであれば高精度な予測ができる．

予測法 ② は予測法 ① と違い過去数日間のすべてのデータを用いて予測を行う．そのため，気温の変化が小さく，電力需要量の変化も小さい場合（パターン ①）に関しては，予測法 ② よりも，最高気温で類似日を選択して予測する予測法 ① のほうがより高精度な予測が可能となる．

3.4 識別法（閾値設定法）の提案

本論文では，予測法 ① を用いて一定期間のデータで学習を行い，予測法 ① の予測結果（予測精度が良い日と悪い日）と予測開始前のデータとの関係を基に識別法（閾値）を決定している．このとき，予測精度の良い日を予測法 ① で 8 時から 17 時までの平均誤差率が 5% 以下の予測日，予測精度が悪い日を平均誤差率が 10% より大きい予測日として定義している．これは，予測精度が良くなるパターン ①（平均誤差率 5% 以下）では予測法 ① を使い，予測精度が悪くなるパターン ②（平均誤差率 10% より大きい）では予測法 ② を使って予測するためである．

予測精度が 5～10% の予測日についてはパターン ① とパターン ② の中間の電力需要量の変化をする（過去数日間の電力需要量の変化が若干ばらついている）場合である．この予測日では予測法 ① と予測法 ② のどちらでも同じような予測精度（5～10%）になるため識別法（閾値）の学習に用いていない．そのため，予測精度が 5～10% の予測日については，どちらの予測法を用いるか明確な基準はなく，予測精度が 5% に近ければ予測法 ①，予測精度 10% に近ければ予測法 ② を使う傾向となる．

3.4.1 クラス内分散・クラス間分散比による特徴選択

識別法（閾値）を決定するためには，最初に特徴を選択

する必要がある．特徴とは識別に必要な情報のことであり，たとえば，電力需要予測の場合は予測開始前に得られるデータとして「予測開始1時間前の電力需要量実測値の前日との絶対誤差」等が考えられる．精度良く識別するためには，多数の情報の中から識別に適した特徴を1つまたは複数選択する必要がある．

識別に適した特徴を選択するために本論文ではクラス内分散・クラス間分散比を用いた [16]．クラス内分散 σ_W^2 とクラス間分散 σ_B^2 はそれぞれ以下のような式 (2) と式 (3) で計算できる．

$$\sigma_W^2 = \frac{1}{z} \sum_{i=1}^c \sum_{\mathbf{x} \in \mathbf{X}_i} (\mathbf{x} - \mathbf{y}_i)^t (\mathbf{x} - \mathbf{y}_i) \quad (2)$$

$$\sigma_B^2 = \frac{1}{z} \sum_{i=1}^c z_i (\mathbf{y}_i - \mathbf{y})^t (\mathbf{y}_i - \mathbf{y}) \quad (3)$$

スカラー z は全パターン数を表しており， z_i はクラス i に属するパターン数である．ベクトル $\mathbf{x}$ は各パターンの特徴（各予測日の予測開始1時間前の電力需要量実測値の前日との絶対誤差等）をまとめたものであり， $\mathbf{X}_i$ はクラス i に属するパターン集合のことである．ベクトル $\mathbf{y}$ は全パターンの平均であり， $\mathbf{y}_i$ はクラス i に属するパターンの平均である．本論文では，クラスは予測法 ① で予測精度が良い日と予測精度が悪い日の2つとなり，パターンは予測法 ① で予測した各予測日のこととなる．

クラス内分散は，クラスごとのパターンの平均的な分散を表しており，クラス間分散は各クラス間の分散を表している．クラス内分散が小さく（各クラスのパターンが密集し），クラス間分散が大きい（各クラス間の分布が離れている）とき，その特徴は識別しやすい分布となっている．さらにクラス内分散とクラス間分散を以下のような式 (4) で表すと，このクラス内分散・クラス間分散比が大きいほど良い特徴であると評価することができる．

$$J_\sigma = \frac{\sigma_B^2}{\sigma_W^2} \quad (4)$$

3.4.2 限定探索空間中の順探索法による閾値の設定

クラス内分散・クラス間分散比の計算により，識別に適した特徴を選択できた場合，その特徴空間で各クラスを識別する閾値をどのように設定するかが問題になる．この閾値の設定には，各クラスの平均の中間を閾値とする手法等が考えられるが，本論文では探索空間を限定した順探索法により閾値を設定した．

順探索法による閾値の設定では，まず各クラスの平均の中間等に閾値を設定し，予測精度の良い日と悪い日の識別精度を計算する．計算が終わったら閾値を少し変更して，また識別精度の計算を実施する．この処理を繰り返し，その中から最も識別精度が良い閾値を選択する手法である．

この閾値の設定法は順探索で最適解を求めるため，計算の効率が悪い．本論文では全範囲で閾値を探索するのでは




図 6 限定探索空間中の順探索法で調べる閾値候補

Fig. 6 Candidate of threshold in limited search space.

なく，図 6 のように予測精度が良い日と悪い日の平均の間だけで計算することで計算量を低減させている．なお，図 6 に示している各閾値の間隔は，予測精度が良い日と悪い日の平均の間を 10 等分したものである．また，図 6 は，2 次元空間となっているが，横軸は 8 時から 17 時までの平均誤差率であるので識別に用いることはできない．よって識別の際は縦軸のみで判定を行う．

4. 提案手法の評価

提案手法を用いて 2.2 節と同じ条件で予測し，2 つの予測法を組み合わせることで予測精度が向上するか評価した．提案手法で用いている気温情報は，同じオフィスビルの外部に取り付けられている温度計より取得したものである．

4.1 識別法の評価

本章の評価では，まず 2 つの予測法を使い分ける識別法（閾値）を得るために，3.4 節で述べた特徴の選択と閾値の設定を実行した．クラス内分散・クラス間分散比を用いた特徴の選択には，予測開始前のデータから得られる特徴として表 5 で示している 28 個を用いている．表 5 の 15 番まではいずれの予測法でも共通して使える特徴，16 番目以降は予測法 ① の特性に基づいて選択した特徴である．表 5 で特定時刻（7 時）の電力需要量を用いているのは，本論文の予測は 8 時から開始しており，7 時の電力需要量が予測開始前に得られる最新のデータとなるからである．

この 28 個の各特徴でクラス内分散・クラス間分散比を計算し，順位付けした結果が表 6 である．評価の結果，クラス内分散・クラス間分散比が最大であった特徴は「最高気温の学習データ 3 日間の標準偏差」であった．本論文の予測法 ① では最高気温を基に類似日を特定しているため，最高気温を用いた特徴のクラス内分散・クラス間分散比が

表 5 予測開始前のデータから得られる特徴

Table 5 Feature obtained before electricity demand forecast.

番号	特徴	番号	特徴	番号	特徴
1	7時電力の前日との誤差率	11	最高気温の過去5日間の標準偏差	20	7時電力の学習データ3日間の標準偏差
2	7時電力の過去3日との平均誤差率	12	最高気温の過去8日間の標準偏差	21	7時電力の過去13日間との平均誤差率
3	7時電力の過去5日との平均誤差率	13	最大電力の過去3日間の標準偏差	22	最高気温の学習データ3日間の平均誤差率
4	7時電力の過去3日間の標準偏差	14	最大電力の過去5日間の標準偏差	23	最高気温の学習データ3日間の最小誤差
5	7時電力の過去5日間の標準偏差	15	最大電力の過去8日間の標準偏差	24	最高気温の学習データ3日間の最大誤差
6	7時電力の過去8日間の標準偏差	16	7時電力の学習データ3日間の平均誤差率	25	最高気温の学習データ3日間の平均誤差
7	最高気温の前日との誤差率	17	7時電力の学習データ3日間の最小誤差	26	最高気温の学習データ3日間の標準偏差
8	最高気温の過去3日間との平均誤差率	18	7時電力の学習データ3日間の最大誤差	27	最高気温の過去13日間との平均誤差率
9	最高気温の過去5日間との平均誤差率	19	7時電力の学習データ3日間の平均誤差	28	最大電力の学習データ3日間の標準偏差
10	最高気温の過去3日間の標準偏差				

表 6 各特徴のクラス内分散・クラス間分散比とその順位

Table 6 Ratio of between-class variance to within-class variance of each feature.

番号	1	2	3	4	5	6	7	8	9	10
クラス内分散・クラス間分散比	0.06693	0.21143	0.26892	0.08769	0.06772	0.14504	0.07648	0.07405	0.05812	0.22149
順位	21	9	6	16	20	12	18	19	23	7
番号	11	12	13	14	15	16	17	18	19	20
クラス内分散・クラス間分散比	0.21956	0.27430	0.19028	0.09433	0.13924	0.06349	0.01837	0.03236	0.04247	0.00001
順位	8	5	10	15	13	22	27	26	25	28
番号	21	22	23	24	25	26	27	28		
クラス内分散・クラス間分散比	0.37381	0.09616	0.18362	0.56018	0.42981	0.61851	0.08220	0.05275		
順位	4	14	11	2	3	1	17	24		




図 7 クラス内分散・クラス間分散比が最大の特徴

Fig. 7 Future with maximum ratio of between-class variance to within-class variance.




図 8 クラス内分散・クラス間分散比が最小の特徴

Fig. 8 Future with minimum ratio of between-class variance to within-class variance.

特に大きくなっている。

図 7 と図 8 は、それぞれクラス内分散・クラス間分散比が最大の特徴「最高気温の学習データ3日間の標準偏差」と最小の特徴「7時電力の学習データ3日間の標準偏差」の8時から17時までの平均誤差率との関係を表したものである。図 7 を確認すると、クラス内分散・クラス間分散

比を用いることにより、予測精度が良い日と悪い日の各パターンがそれぞれ接近し、クラス間（良い日と悪い日）の分布が離れている特徴が選択されている。逆にクラス内分散・クラス間分散比が小さい特徴（図 8）は、精度良く識別を行うのは困難である。

次にクラス内分散・クラス間分散比が最大であった特徴




図 9 3.4 節の閾値設定法で求めた最適な閾値

Fig. 9 Best threshold obtained by proposal method.

「最高気温の学習データ 3 日間の標準偏差」で識別精度を計算する順探索を実施し、最適な閾値を設定した。その結果が図 9 である。選ばれた閾値の識別精度は 86.5% (52 日中 7 日を誤識別) であった。なお、予測法 ① の予測精度は電量需要量と最高気温との相関等により変化するため、閾値は環境ごとに設定する必要がある。しかし、特徴は予測法 ① の特性に依存するものであるため、環境が変化しても今回選択された特徴「最高気温の学習データ 3 日間の標準偏差」や表 6 でクラス内分散・クラス間分散比が上位となった特徴が選択される。

4.2 予測精度の評価

図 9 の閾値を用いた提案手法でオフィスビルの電力需要量を予測し、その結果を評価した。予測法 ① の学習データを探索する範囲 m と学習データ数 n は、いくつかの組合せを試した結果、最も精度が良かった $m = 13$, $n = 3$ としている。

学習データの選択範囲が $m = 13$ 日 (過去の平日約 3 週間) となったのは、実験に用いたオフィスビルでは 14 日以上前のデータは気温が類似していても、その他 (建物内の人数等) の変化により電力需要量が変化する傾向が見られたからである。また、学習データ数が $n = 3$ 日となったのは、建物内の人数の変化等により日々の電力需要曲線の形状 (24 時間分の電力需要量の変化) にばらつきが見られたからである。そのため、最高気温が最も類似している日 ($n = 1$) のみでは予測日と電力需要曲線の形状が大きく異なることがあり、最高気温が類似している数日間の平均電力需要曲線を予測結果とした方が予測日の曲線と類似するようになっていた。なお、学習データを探索する範囲 m と学習データ数 n は、建物内の人数変化の頻度や空調の稼働計画等で変化するためビルごとに最適化しなければな

表 7 提案手法の予測結果

Table 7 Forecasting error of proposal method.

予測法	提案手法	予測法①	予測法②
8~17 時平均誤差率(%)	5.97	6.34	6.40
17~22 時平均誤差率(%)	6.10	5.68	7.16
22~8 時平均誤差率(%)	15.55	14.59	15.56
24 時間平均誤差率(%)	9.59	9.30	9.99

表 8 各予測法の予測精度の標準偏差

Table 8 Standard deviation of forecasting error of each method.

予測法	提案手法	予測法①	予測法②	既存の予測法
標準偏差	3.36	4.07	4.07	4.96

らず、そのビルの特徴を理解するためにも本論文と同様にいくつかの m と n の組合せを一定期間 (数カ月) のデータで試す必要がある。

提案手法を用いて予測した結果、予測精度は表 7 のとおりになった。また、2 つの予測法を組み合わせることにより精度が改善されたか確認するため、予測法 ① のみと予測法 ② のみで予測したそれぞれの結果についても表 7 に示している。

提案手法の予測精度 (8 時から 17 時の平均誤差率) は 5.97% であり、既存の予測法の予測精度 7.53% より予測精度は向上している。また、提案手法は予測法 ① と予測法 ② を適切に使い分けたことで各予測法を個別に用いた場合よりも予測精度の向上が図れている。

表 8 は、各予測法の予測精度のばらつき (標準偏差) を示したものである。提案手法は既存の予測法や予測法 ①、予測法 ② より予測精度がばらつき可能性が低いことが分かる。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、提案手法は他の予測法よりビル向けの電力需要量の予測法として適している。

5. 考察

2 つの予測法を組み合わせると予測精度が向上したのは、2 つの予測法を適切に使い分けたからである。図 10 と表 9 は、2 つの予測法を適切に使い分けた一例として 2010 年 9 月 13 日から 2010 年 10 月 6 日までの各予測法の予測精度 (8 時から 17 時の平均誤差率) の推移を示したものである。予測法 ① では予測精度が大きく低下する 9 月 24 日と 9 月 27 日では、識別法で予測法 ② を選択したことにより予測精度を改善できている。

表 10 は、識別法においてパターン ① とパターン ② のそれぞれに識別された日の既存の予測法と予測法 ①、予




図 10 各予測法の予測精度の推移 (2010/9/13~10/6)

Fig. 10 Change of forecasting error of each method.

表 9 各予測法の予測精度の推移 (2010/9/13~10/6)

Table 9 Change of forecasting error of each method.

日付	9/13	9/14	9/15	9/16	9/17	9/21	9/22	9/24
予測法①(%)	6.74	6.10	8.89	7.89	7.04	7.46	8.19	30.73
予測法②(%)	6.48	3.91	5.24	17.85	10.00	4.10	4.56	11.66
提案手法(%)	6.74	6.10	5.24	17.85	7.04	4.10	8.19	11.66

日付	9/27	9/28	9/29	9/30	10/1	10/4	10/5	10/6
予測法①(%)	23.60	5.79	4.69	6.22	14.51	5.71	5.10	3.23
予測法②(%)	6.73	8.96	3.97	8.04	14.88	5.32	4.41	3.08
提案手法(%)	6.73	8.96	3.97	6.22	14.88	5.71	5.10	3.23

表 10 各パターンにおける予測精度

Table 10 Forecasting error in each pattern.

パターン	パターン①			パターン②		
	既存の 予測法	予測 法①	予測 法②	既存の 予測法	予測 法①	予測 法②
8~17 時平均誤差率(%)	7.03	5.29	5.84	9.17	9.90	8.28
17~22 時平均誤差率(%)	7.98	5.25	6.62	6.76	7.13	9.02
22~8 時平均誤差率(%)	17.85	13.72	13.73	17.18	17.58	21.77
24 時間平均誤差率(%)	11.28	8.44	8.96	11.67	12.20	13.49

測法②の予測精度を示したものである。予測法①のパターン①とパターン②の予測精度はそれぞれ5.29%と9.90%であり、大きな差がある。このように識別法は予測法①で予測精度が良くなる場合と悪くなる場合を予測開始前のデータを基に識別しており、予測精度が悪くなる場合において予測法①を用いないようにすることで予測精度を向上させている。また、予測法①はパターン①において既存の予測法より予測精度を約1.7%向上させており、予測法②はパターン②において予測精度が低下している予測法①より予測精度を約1.6%向上させている。このように予測法①と予測法②は互いに異なる状況で予測精度を向上させ、提案手法はこの2つの予測法を識別法により適切に使い分けたことで、単一の予測法よりも精度良く予測できている。

また、今回提案した予測法に用いた入力情報の種類は過去の電力需要量に気温情報を追加しただけであり、天気や湿度等を用いておらず、十分に少ないものである。さらに

表 11 各予測法の予測精度と最大電力需要量、最高気温の推移 (2010/9/9~16)

Table 11 Change of forecasting error of each method and peak demand, maximum temperature.

日付	9/9	9/10	9/13	9/14	9/15	9/16
最大電力需要量(kWh)	446	464	562	464	401	395
最高気温(℃)	27.7	28.8	33.1	29.4	25.1	21.6
予測法①予測精度(%)	15.24	7.69	6.74	6.10	8.89	7.89
予測法②予測精度(%)	4.35	6.41	6.48	3.91	5.24	17.85
提案手法予測精度(%)	4.35	6.41	6.74	6.10	5.24	17.85

表 12 各予測法の予測精度と最大電力需要量、最高気温の推移 (2010/9/24~10/1)

Table 12 Change of forecasting error of each method and peak demand, maximum temperature.

日付	9/24	9/27	9/28	9/29	9/30	10/1
最大電力需要量(kWh)	314	299	331	417	329	341
最高気温(℃)	19.9	18.1	20.6	24.5	21.1	23.1
予測法①予測精度(%)	30.73	23.60	5.79	4.69	6.22	14.51
予測法②予測精度(%)	11.66	6.73	8.96	3.97	8.04	14.88
提案手法予測精度(%)	11.66	6.73	8.96	3.97	6.22	14.88

提案した予測法は過去13日間の電力需要量と気温情報があれば予測が可能であるため、多くの需要家に幅広く適用することが可能である。

しかし、提案手法では、予測精度を向上させることができたが、依然として図10と表9の9月16日と10月1日のような予測精度が大きく低下している場合が見られ、改善の余地がある。9月16日と10月1日で予測精度が低下しているのは、いずれも最大電力需要量と最高気温の関係が過去数日間とは異なったからである。表11と表12は2010年9月16日と10月1日の当日と過去5日間の最大電力需要量実測値と最高気温を示したものである。9月16日と10月1日では最高気温が急激に変化したため、識別法は電力需要量も急激に変化する(パターン②)と判断して予測法②を選択した。しかし、実際の電力需要量は変化せず(パターン①)、最大電力需要量と最高気温の関係が過去数日間とは異なることとなり、予測法②では精度が低下した。

9月16日では予測法①で7.89%の予測精度が得られているので、より正確に電力需要量の急激な変化が起きるか識別できれば予測精度は改善できる。具体的には、本論文では識別法(閾値の設定)の特徴を1つ(1次元)に限定していたが、多数の特徴(多次元)を用いることにより改善が期待できる。10月1日は予測法①と予測法②のどちらでも予測精度が悪いので、識別法を改善するだけでなく、個々の予測法の改善も必要である。もしくは、10月1日に適した予測法③を新たに追加することも考えられる。

なお、本論文の提案手法は8時から17時の予測精度の向上を目的としているため、他の時間帯の電力需要量の予測には別の予測法を用意する必要がある。たとえば、17時から22時の電力需要量では予測法①は良い予測精度が得られているが、予測法②はパターン①でもパターン②でも予測法①より精度は劣っている。よって、17時から22時の予測には予測法①を単独で用いるか、新たな予測法と組み合わせるか検討する必要がある、その他の時間帯でも電力需要量の傾向を分析し、それぞれに適した予測法を検討する必要がある。

6. おわりに

本論文では、2つの予測法を組み合わせることで電力需要量の複雑な変化に対応する手法について提案し、実験により有効性を確認した。その結果、単一の予測法では6.34%が限界であった予測精度を、2つの予測法を組み合わせることで予測精度5.97%まで改善することができた。また、今回提案した予測法は、予測に用いる入力情報の種類やデータの量が少ないため、多くの需要家に幅広く適用できる。

今後の課題としては、5章で述べた識別法の改良や個々の予測法の改良、新たな予測法③の追加等が考えられる。他にも電力需要量を気温だけでなく、他の情報（建物内の人数等）を用いて分析し、より詳細に複数の（2つ以上）のパターンに分け、特性の異なる複数の予測法を使い分ける手法について検討する予定である。また、本論文では2つの予測法のどちらか一方を選択して予測結果を得ていたが、今後は複数の予測法で予測結果を求め、加重平均して1つの予測結果を得ることも検討する。

参考文献

- [1] 資源エネルギー庁：平成22年度エネルギーに関する年次報告概要，入手先 (<http://www.enecho.meti.go.jp/topics/hakusho/2011/gaiyou.2011.pdf>)
- [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] 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)。
- [4] 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)。
- [5] 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)。
- [6] 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)。
- [7] 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)。
- [8] 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)。
- [9] 倉田栄太郎，森 啓之：Informative Vector Machine を用いた短期電力負荷予測，電気学会電力・エネルギー部門誌，Vol.127，No.4，pp.566-572 (2007)。
- [10] 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)。
- [11] 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)。
- [12] 上吉悠人，峰 豪毅，西 宏章：クラスタ型エネルギーマネジメントに向けた大学キャンパスのエネルギー計測システム，情報処理学会研究報告，Vol.2010-UBI-27，No.3，pp.1-8 (2010)。
- [13] 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)。
- [14] 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)。
- [15] 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>)。
- [16] 石井健一郎，上田修功，前田英作，村瀬 洋：わかりやすいパターン認識，オーム社 (1998)。



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 年慶應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 年慶應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．映像情報メディア学会会員．