

需要曲線の特徴を考慮した \mathcal{H}_∞ フィルタによる短期電力需要予測

正員 滑川 徹* 学生員 細田 康彦*

\mathcal{H}_∞ Filter-based Short-term Electric Load Prediction
considering Characteristics of Load Curve

Toru Namerikawa*, Member, Yasuhiko Hosoda*, Student Member

This paper deals with \mathcal{H}_∞ filter-based short-term electric load prediction considering characteristics of load curve. We propose a predictive method to forecast a future electric load demand for 36 hours from 0 PM, and then evaluate the peak and bottom of load curves in the next day. We propose a load model, estimates unknown parameters of model via \mathcal{H}_∞ filter using the separated data from holiday and weekday, a same pattern of the previous data have been chosen and assigned to parameters for the model. The simulation results show the effectiveness of the proposed prediction methodology.

キーワード：短期電力需要予測, \mathcal{H}_∞ フィルタ, 需要曲線の特徴, 推定, 予測

Keywords: Electric load prediction, \mathcal{H}_∞ filter, Characteristics of load curve, Estimation, Prediction

1. はじめに

電力需要予測技術が社会的に求められ、各電力会社では、日々の需要データとその予測曲線をオンラインで公表し、ピーク時の電力使用の抑制を呼びかけている。東日本大震災以降、各電力会社において電力需要が逼迫しており、東京電力管内では計画停電なども実施された。また、分散型電源の普及の要望が高まっており、循環型の社会の実現が今後の日本の早急な課題となっている。現在、電力会社では日々の電力需要予測により翌日の発電機の運転・停止計画を立て、供給予備力の確保や経済的な電力系統運用により一層努めている。一方で、太陽光発電をはじめとする分散型電源の普及、発電燃料の高騰、地球温暖化問題等を背景に、電力会社を取り巻く環境は大きく変化している⁽¹⁾。そのため、その業務から大量の二酸化炭素を排出する電力会社は可能な限り二酸化炭素の排出量を削減するという大きな責任を持っている。よって、発電燃料の使用量を抑え二酸化炭素の排出量の少ない運転を行うために、電力需要予測の精度向上が求められている⁽²⁾⁽³⁾。

これまでに短期電力需要予測の研究として文献⁽³⁾⁻⁽¹⁷⁾が挙げられる。文献⁽³⁾⁻⁽⁸⁾では現在の短期需要予測手法の主流となっているニューラルネットワーク (NN)、重回帰分析

を取り扱っており、予測条件やアルゴリズム、気象分類条件、予測説明の明瞭化についての研究がされてきた。NN の特徴として、設計者の意図を反映しやすく、他の予測手法に比べ高精度な予測ができるメリットがある。一方で、NN は一般に、物理システムとパラメータの関係が不明瞭であり、学習回数を多く必要とするが、文献⁽⁶⁾では構造化ニューラルネットワークを用いて予測説明の明瞭化を提案し、説明能力を向上させている。しかしながら、依然として学習回数は改善の余地がある。これらに対し文献⁽¹⁷⁾では、モデル構造やパラメータと電力需要の関係が明確で学習回数を低減させることのできるカルマンフィルタによる電力需要予測手法を提案している。具体的には、現在の電力需要が過去の電力需要と気温に依存したハイブリッドモデルを使用し、この需要モデルに対して学習用データを基にカルマンフィルタによる未知パラメータ (係数) の推定を行っている。しかし、電力需要予測においては初期パラメータの推定が重要であるが、カルマンフィルタの枠組みでは直接的に扱うことが困難であり、モデルは多くのパラメータ推定誤差を含む。更に、実際の電力需要は平日と休日で需要曲線の特徴が大きく異なるため明確にこれらを区別する必要がある。しかし、文献⁽¹⁷⁾ではこれらに対して具体的な記述がなく、平日と休日の需要が干渉しあい、予測結果が劣化することが考えられる。

そこで本稿では文献⁽¹⁷⁾と同様のモデルにおいて \mathcal{H}_∞ フィルタを用いてパラメータ推定を行う。 \mathcal{H}_∞ フィルタは NN や重回帰分析と同様で未知パラメータを推定する予測手法

* 慶應義塾大学理工学部
〒 223-8522 横浜市港北区日吉 3-14-1
Faculty of Science and Technology, Keio University, 3-14-1 Hiyoshi, Kohoku-ku, Yokohama 223-8522

であり, その推定方法の特徴として, 最悪な雑音の状況を想定し, 予測誤差が最小となるようなゲインの設定により予測精度の向上を図る手法である。これによって, パラメータ推定誤差に対しより正確な推定が可能であり, 本研究の目的にも則した予測手法であると考えられる。また, 学習回数が文献⁽⁶⁾に対し学習回数を約 200 分の 1 に抑えることができ, パラメータ推定における推定誤差の上限を H_∞ ノルムにより保証している。さらに, 実際の運用を想定し平日と休日の需要曲線の特徴を考慮した電力需要予測手法を提案する。具体的には過去データを平日と休日 (土, 日, 祝日) に分割し, 2 つの場合の電力需要パラメータを H_∞ フィルタを用いて推定する。その時, 平日 (休日) の予測に休日 (平日) の需要が影響しないように過去データを選び予測を行う。これによって, 平日と休日明確に区別され, 予測精度の向上が期待される。本稿では, カルマンフィルタに対する需要曲線の考慮した H_∞ フィルタの有効性と, 文献⁽⁶⁾⁽¹⁷⁾に対する有効性を検証する。

2. 問題設定

2.1 電力需要のダイナミクス 本稿では電力需要モデルとして (1) 式に示す過去の需要と気温に依存したハイブリッドモデルを用いる。

$$y(k) = a_0(k) + a_1(k)y(k-1) + a_{23}(k)y(k-23) + a_{24}(k)y(k-24) + a_{25}(k)y(k-25) + b_0(k)t(k) + b_1(k)t(k-1) + b_{24}(k)t(k-24) \quad (1)$$

$k[h]$ は時刻を表し, $y(k)[w]$ は電力需要, $t(k)[deg]$ は気温である。 $y(k-i), t(k-i)$ は, 時刻 k に対して i 時間過去の需要と気温の値である。 $a_1(k), a_{23}(k), a_{24}(k), a_{25}(k)$ は時刻 k における需要パラメータであり, $b_0(k), b_1(k), b_{24}(k)$ は気温パラメータである。また, $a_0(k)$ は定数項を意味している。

[注意 1] (1) 式は現時刻 k の電力需要が 1, 23, 24, 25 時間前の需要と気温のみに依存する電力需要モデルである。筆者らは他の時間の需要を組み込んだモデルを用いた検証も行ったが, 予測結果との相関が弱く予測結果にあまり変化が見られなかったため用いていない。

2.2 予測目的 本稿で行う電力需要予測として, 予測日の当日 13 時から翌々日 0 時までの 36 時間先を予測することを想定する問題を考える。これまでは 24 時間先の予測手法が多いが, 例えば, Fig. 2 では約 26 時間後に電力需要の最大値があり, 予測期間が 24 時間では不十分である。そのため, 本稿では正午に予測を開始する際に十分な 36 時間先まで予測する。一般に, 電力中央給電指令所では発電機運用計画を立てる正午頃に翌日の電力需要予測を行う。また, その予測を行う際に使用する過去データとして予測開始時である 13 時を含め過去 30 日分の電力需要, 気温の実測値を使用する。ただし, その過去データは 1 時間毎に測定されたものであり日付, 時間, 曜日がラベリングされているとする。

さらに本稿で提案する予測手法では予測開始日の前日の 13 時から翌々日の 0 時までの気温が必要になる。しかし, この気温は未来の値であり実際に得ることはできない。そのため, 実際の運用の際には気象庁等から得られる気温の予報値を用いる。

また, 本稿では記述の煩雑さを防ぐため, Fig. 1 に示すように予測する前後の日付を定義する。

- L ... 予測を開始する前日の 0 - 23 時
- T ... 予測を開始する日の 0 - 23 時
- N ... 予測を開始する翌日の 0 - 23 時

本稿の目的は, 発電機の計画的な運用の為に電力需要予測である。Fig. 2 に予測目的の図を示す。予測目的は予測日の翌日 N において, Fig. 2 に示す最大需要予測誤差 (MEP) と最小需要予測誤差 (MEB) の予測誤差を小さくする予測手法を見つける。(2), (3) 式に予測の評価として MEP と MEB を定義する。ただし, y_p, y_b は予測日の翌日 N における実測値 $y(k)$ の最大・最小値とし, \hat{y}_p, \hat{y}_b は予測日の翌日 N における過去の予測値 $\hat{y}(k)$ の最大・最小値とする。

$$MEP [\%] = \left\| \frac{y_p - \hat{y}_p}{y_p} \right\| \times 100, \dots \dots \dots (2)$$

$$MEB [\%] = \left\| \frac{y_b - \hat{y}_b}{y_b} \right\| \times 100, \dots \dots \dots (3)$$

where

$$y_p = \max y(k) , y_b = \min y(k)$$

$$\hat{y}_p = \max \hat{y}(k) , \hat{y}_b = \min \hat{y}(k)$$

$$12 \leq k \leq 36.$$




Fig. 1. Definition of date

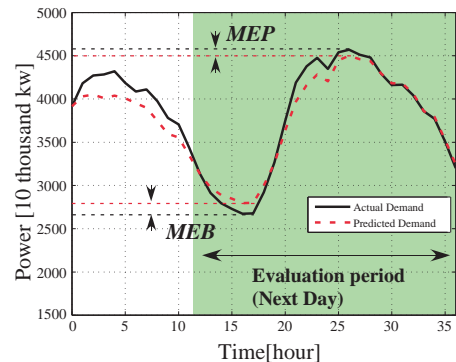


Fig. 2. Evaluation period of prediction

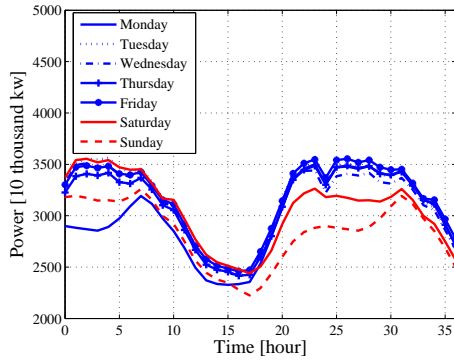


Fig. 3. Comparison between 7 days load curves

3. 電力需要予測

本節では上記の予測目的を達成するような電力需要予測アルゴリズムについて述べる。本稿で行う電力需要予測手法は2つのパートから構成されている。まず1つ目のパートとして過去の電力需要の実測値を基に(1)式の需要パラメータと気温パラメータを推定する。その後、2つ目のパートとして、パラメータを推定したモデルを用いて時間シフトすることで36時間先までの需要予測結果を得る。以降、各パートについて詳しく説明する。

3.1 パラメータ推定 本節では需要パラメータと気温パラメータのパラメータを推定するアルゴリズムについて述べる。

パラメータ推定には次のような離散時間状態空間表現を用いる。

$$x(k+1) = x(k) \dots\dots\dots (4)$$

$$z(k) = C(k)x(k) + w(k) \dots\dots\dots (5)$$

ここで、 $x(k)$ は推定したい未知パラメータ状態ベクトルであり、次のように(6)式として定義する。

$$x(k) = [a_0 \ a_1 \ a_{23} \ a_{24} \ a_{25} \ b_0 \ b_1 \ b_{24}]^T \dots\dots(6)$$

$z(k)$ は測定できる変数を表しており、需要 $z(k) = y(k) + w(k)$ である。 $C(k)$ は時変出力ベクトルであり、ここでは、次のような過去の需要と気温の値とする。 $w(k)$ は観測ノイズベクトルである。

$$C(k) = \begin{bmatrix} 1 & y(k-1) & y(k-23) & y(k-24) \\ y(k-25) & t(k) & t(k-1) & t(k-24) \end{bmatrix} \dots\dots (7)$$

(4)-(7)式に基づき、 H_∞ フィルタを用いたパラメータ推定を行う⁽¹⁸⁾。 H_∞ フィルタはカルマンフィルタと比較し、パラメータ推定誤差等に対してロバストであり、電力需要モデルのように様々な要因に依存し、正確なモデリングが困難な場合に有効である事が知られている⁽¹⁹⁾。

設計パラメータ γ を(8)式を満たすように設計する。 H_∞ フィルタを用いることで(4)、(5)式に対し以下を満足する推定値 $\hat{x}(k)$, $k = 0, 1, \dots, N$ を得ることが出来る。

$$\sup_{x_0, v} \frac{\sum_{k=0}^N \|x(k) - \hat{x}(k)\|^2}{\|x(0) - \hat{x}(0)\|_{P(0)}^2 + \sum_{k=0}^N \|w(k)\|_{R^{-1}}^2} < \gamma^2 \dots (8)$$

$P(0)$, R はそれぞれ初期状態の不確かさ、観測ノイズに対する重み行列である。また、 $\hat{x}(k)$ はパラメータの推定値である。(8)式から推定値 $\hat{x}(k)$ は初期値の不確かさを考慮し、推定誤差エネルギーと雑音エネルギーの比の最大値が γ^2 未満となる。ここで、 H_∞ フィルタアルゴリズムは以下の再帰計算で表現される。

1. (フィルタゲインの更新)

$$K(k) = P(k)C(k)^T (C(k)P(k)C(k)^T + R)^{-1} \dots (9)$$

2. (状態推定の更新)

$$\hat{x}(k+1) = \hat{x}(k) + K(k)(z(k) - C(k)\hat{x}(k)) \dots\dots(10)$$

3. (誤差分散の更新)

$$P(k+1) = (P(k)^{-1} + C(k)^T R^{-1} C(k) - \gamma^{-2} I)^{-1} \dots(11)$$

以上の手順1-3を複数回繰り返すことで(1)式のパラメータである(6)式を推定することが出来る。また、分散行列 R が推定ゲインでありこの値を調整することで推定速度を調整することが出来る。

3.2 需要予測 本節では前節までの議論から導出した電力需要モデルを基に36時間先までの需要予測について説明する。36時間先までの予測値は次式を計算することで得られる。

- 1時間先の予測

$$\begin{aligned} \hat{y}(k+1) = & a_0(k) + a_1(k)y(k) + a_{23}(k)y(k-22) \\ & + a_{24}(k)y(k-23) + a_{25}(k)y(k-24) \\ & + b_0(k)t(k+1) + b_1(k)t(k) + b_{24}(k)t(k-23) \\ & \dots\dots (12) \end{aligned}$$

⋮

- 36時間先の予測

$$\begin{aligned} \hat{y}(k+36) = & a_0(k) + a_1(k)\hat{y}(k+35) + a_{23}(k)\hat{y}(k+13) \\ & + a_{24}(k)\hat{y}(k+12) + a_{25}(k)\hat{y}(k+11) \\ & + b_0(k)t(k+36) + b_1(k)t(k+35) + b_{24}(k)t(k+12) \\ & \dots\dots (13) \end{aligned}$$

ここで \hat{y} は予測値である。2時間先からは予測値 $\hat{y}(k+1), \dots, \hat{y}(k+35)$ を基に予測を行う。

4. 需要曲線の特徴を考慮した電力需要予測

前節までの予測手法では特に平日と休日(土、日、祝日)の区別を行うことなく議論をしてきたが、実際の需要曲線はFig. 3に示すように平日と休日大きくその特徴が異なるため、これらを明確に区別する必要がある。ただし、本稿では平日と休日(土、日、祝日)の2つのカテゴリに区別し、それを考慮した需要予測を提案する。

〔注意2〕 本稿では土、日、祝日をまとめて休日というカテゴリに分割したが、厳密にはそれぞれに需要曲線の特徴

があるため、別のカテゴリに分類した方が予測精度が向上する可能性がある。しかし、休日は平日に比べてデータが少なく特に祝日に関してはそれが顕著である。それによってパラメータ推定の際に十分に収束しない可能性もあるのでこれを考えて設計する必要がある。

4.1 需要曲線の特徴を考慮したパラメータ推定 需要曲線の特徴を考慮するために電力需要モデル (1) 式において平日用のパラメータと休日用のパラメータを用意する。そのため過去の需要データを平日と休日に分割し、分別したデータを用いて平日用、休日用のパラメータを求める。そして、それらに基づいて平日用、休日用の2つのモデルを作成する。一方、電力需要は季節によってもその特徴が大きく変化し、長期のデータを用いてパラメータ推定を行うことは合理的でない。そのため、過去データのある程度の区間に限定してパラメータ推定を行う必要がある。以上のことを考慮して次の手法を提案する。

- (i) パラメータ推定に使用する過去データの区間を選択
- (ii) 選択した区間内の過去データを平日と休日で分割
- (iii) 平日のみ、休日のみが連結した過去データを作成
- (iv) (4), (5) 式により平日、休日用のパラメータを推定

4.2 需要曲線の特徴を考慮した需要予測アルゴリズム 前節までの需要予測手法では予測を開始する13時から単純に23, 24, 25時間前の需要データを使用していた。しかしその場合、平日(休日)から休日(平日)を予測する際に休日(平日)の予測に平日(休日)の需要が影響してしまう。例えば予測日の前日 L が休日、予測日 T が平日の場合に、 T の13時を予測する時、 (L) の需要を基に予測することになる。つまり、異なる特徴を持つ平日と休日の需要曲線が影響し、推定精度が劣化してしまう。そこで、本節では Fig. 4 に示す予測手法を提案する。

- A : L, T, N が平日か休日かを調べる。
 - B : $[L, T, N]$ が [平日, 平日, 平日] または [休日, 休日, 休日] である。
 - C : 3.2 節の手法を用いて電力需要予測を行う。
 - D : 以下の作業を行う。
- (1) 過去データから、平日、休日の組み合わせが予測開始日 T 、予測開始日の翌日 N と同じ連続する2日間を抜きだし、 T と最も近い組み合わせを選択する。
 - (2) そのデータのうち T に対応する日と T の差の日




Fig. 4. Flowchart of the forecasting

数を i とする。

(3) 以下の計算によって電力需要予測を行う。

• 1時間先の予測

$$\hat{y}(k+1) = a_0(k) + a_1(k)y(k) + a_{23}(k)y(k-24i-22) + a_{24}(k)y(k-24i-23) + a_{25}(k)y(k-24i-24) + b_0(k)t(k+1) + b_1(k)t(k) + b_{24}(k)t(k-23) \dots \dots (14)$$

• 36時間先の予測

$$\hat{y}(k+36) = a_0(k) + a_1(k)\hat{y}(k+35) + a_{23}(k)\hat{y}(k-24i+13) + a_{24}(k)\hat{y}(k-24i+12) + a_{25}(k)\hat{y}(k-24i+11) + b_0(k)t(k+36) + b_1(k)t(k+35) + b_{24}(k)t(k+12) \dots \dots (15)$$

以上の手法を用いることで予測の際に平日と休日を明確に区別することが出来る。

5. シミュレーション

本節では前節までの予測手法を基に関東地方における実際の需要と気温を用いて需要予測を行う。需要予測は東京電力で公表されている2011年の1時間間隔の時系列需要データと、気象庁で公表されている東京都における1時間間隔の時系列温度データを用い、2011年の6月1日から6月30日までの30日間の予測を行う。具体例として、予測の種類を予測A~Dの4通り設けた。予測A~Dはそれぞれ、平日から休日、休日から休日、休日から平日、平日から平日、として選んだ。予測A~Dの過去データはTable 1の条件で行い、予測日と過去データの具体的な日付をFig. 5中に示した。

本稿のシミュレーションでは気温については予報値ではなく実測値を用い、シミュレーションで用いる過去データは予測開始日から30日前のデータを用いてパラメータ推定を行った。また、分散行列 R 、状態ベクトル x 、誤差分散行列 P の初期値は以下としてパラメータの推定を行った。

$$R = 1 \dots \dots \dots (16)$$

$$x(0) = [0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0]^T \dots \dots (17)$$

$$P(0) = I_8 \dots \dots \dots (18)$$

本稿ではパラメータ推定には季節による需要の違いと過去データの数を考慮して予測日の30日前までのデータを使用する。パラメータ推定に用いるデータに関してFig. 6に示す。また、予測A-Dの H_∞ フィルタにおけるパラメータ推定の設計パラメータ γ を休日パラメータ $\gamma_H = 33$ 、平日パラメータ $\gamma_W = 10$ とした。

予測Aの場合の平日・休日用モデルに関するパラメータ推定結果をFigs. 7, 8に示す。パラメータが一定値に収束していることから推定が良好にできていることが確認できる。パラメータは電力需要モデルに代入することによって1時刻先の予測値を計算できることから、物理システムと対応がとれた明瞭な予測手法であることがわかる。また、学習回数は500回程度で十分にモデルを推定でき、文献(6)の学習回数10万回に対し約200分の1の学習回数に抑え予



Fig. 5. Calendar

Table 1. Prediction day

	T	N
Prediction A	17 Fri	18 Sat(holiday)
Prediction B	18 Sat(holiday)	19 Sun(holiday)
Prediction C	26 Sun(holiday)	27 Mon
Prediction D	27 Mon	28 Tue




Fig. 6. Previous Data for Parameter estimation

Table 2. Predicted result of MEP and MEB in Case 1

	Filter	MEP [%]	MEB [%]
Prediction A	Kalman Filter	0.4136	5.2549
	H_∞ Filter	0.4355	5.1950
Prediction B	Kalman Filter	2.1929	1.3901
	H_∞ Filter	2.1913	1.3617
Prediction C	Kalman Filter	1.8143	0.1155
	H_∞ Filter	1.7865	0.4203
Prediction D	Kalman Filter	1.2947	4.8044
	H_∞ Filter	1.5246	4.6189

測できている。予測 A-D のそれぞれにおいて電力需要予測アルゴリズムによって使用される過去データを次の Fig. 9 に示す。(a) は Fig. 4 における C の場合、(b) は D の場合を示しており、特に、D の場合において、気温データが過去気温情報を用いず、現時刻から遡った気温データを用いていることに注意する。Fig. 9 (a) より休日または平日が連続する場合には予測に用いる過去データと予測値が連続する。一方 Fig. 9 (b) のように平日と休日が混在し、それらが連続しない場合、過去データと予測値が明確に区別され予測の際に用いられる。

5.1 フィルタの違いによる予測 Table 3 に予測条




Fig. 7. Parameter estimation results of "a" and "b" in Weekday at prediction A


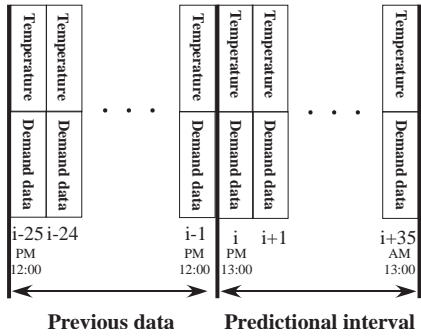
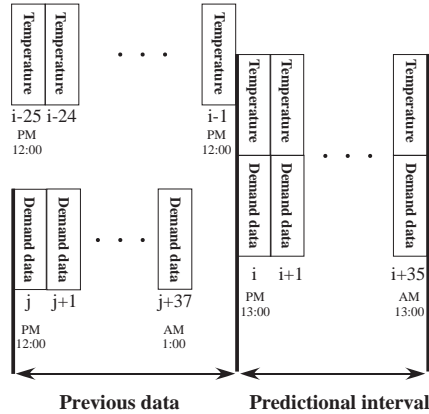


Fig. 8. Parameter estimation results of "a" and "b" in Holiday at prediction A

件の Case 1 と Case 2 を示す。本節では Case 1 の条件で H_∞ フィルタとカルマンフィルタの違いを比較した。ただし、パラメータ推定では共に平日、休日を区別し、需要曲線を考慮している。シミュレーションにおける Case 1 での具体的な予測結果を Fig. 10 に、(2), (3) 式で定義した MEP, MEB の予測結果のをまとめたものを Table 2 に示す。また 6 月における 30 日間の MEP, MEB の推移を Fig. 11 に示す。Fig. 10 中で横軸の"0"の時点が予測開始日の 12 時



(a) Continuation pattern



(b) Discontinuance pattern

Fig. 9. Previous data allocation

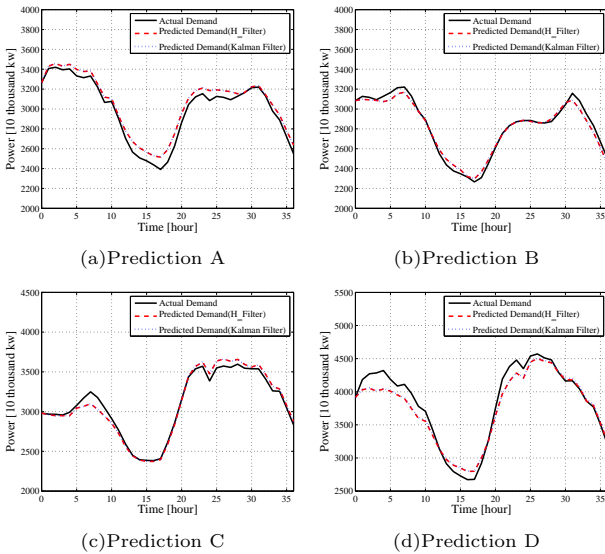


Fig. 10. Predicted result of H_∞ Filter and Kalman Filter in Case 1

に対応している。Fig.10,11 の予測結果からもわかるように本稿で提案した予測手法でも電力需要予測が良好に行っていることが分かる。 H_∞ フィルタとカルマンフィルタの予測精度を比較すると、同程度の予測精度であるが、Fig. 11 の30日分の予測を見ると平均的には MEB の予測には H_∞ フィルタの方が精度よく予測出来ていることが分かる。特に、Table 2 の予測 A,D の MEB のような予測誤差が比較的大きい場合において、 H_∞ フィルタを用いることによって約 0.2[%] の予測誤差の改善が見らる。 H_∞ フィルタは H_∞

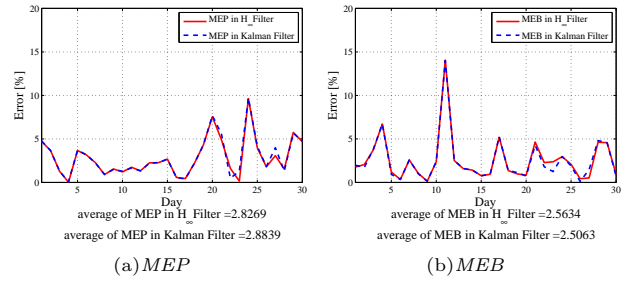


Fig. 11. Result of MEP and MEB for a month (with considering characteristics of load curve)

ノルムによって雑音を含む観測誤差と雑音を含まない公称値の比を閾値 γ 以下に抑えることで誤差の大きさを保証している。そのため、観測雑音による予測誤差が比較的大きな Table 2 の予測 A, D の MEB においてその有効性が見て取れる。全体的な誤差としては Fig. 11 の図の下に示した平均値からも分かるように、どちらのフィルタを用いても MEP , MEB 共に平均値が 3[%] 以下と良好な結果が得られている。設計パラメータ γ は無限大にすることで H_∞ フィルタはカルマンフィルタに一致することが知られており、この意味で H_∞ フィルタはカルマンフィルタを包含している。また、Fig. 11 から、平日を予測する場合に比べて休日を含む予測をする方が予測精度が低いことが分かった。これは平日に比べて休日の過去データが少なく、十分にパラメータ推定が行われていないためであると考えられる。文献⁽⁶⁾と比較すると、 MEP における予測誤差 2.53[%] に対し、提案法では 2.83[%] となり、0.3[%] 劣るものの、電力会社で目標とされる予測誤差 3[%] 以内に抑えることができ、良好な予測手法であるといえる。

5.2 曜日考慮の違いによる比較 シミュレーションにおける Case 2 での具体的な予測結果を Fig. 12 に、(2), (3) 式で定義した MEP , MEB の予測結果のをまとめたものを Table 4 に示す。ただし、従来法は文献⁽¹⁷⁾に基づく予測手法とした。さらに、6月における MEP , MEB の推移を Fig. 13 に示す。予測結果から、需要曲線を考慮した場合が考慮しない場合において著しく有効であることが分かる。予測 D のように平日から平日を予測した場合には、同程度の予測誤差となったが、需要曲線の特徴の異なる L , T を予測した場合である、予測 A-C のにおいては異なる需要曲線の特徴を含んでおり、予測精度が劣化していることが見てとれる。全体的には MEP , MEB の平均値は需要曲線を考慮した場合のみ共に 3[%] 以下の誤差となり、考慮しない場合に比べて格段に予測精度の向上が出来た。

6. おわりに

本稿では需要曲線を考慮した H_∞ フィルタによる電力需要予測手法を提案した。予測は発電機の計画的な運用の為に、翌日の最大電力需要量と最小電力需要量を予測する。具体的には、(1) 式の電力需要モデルを設計し、未知パラメータを平日・休日に分け H_∞ フィルタを用いてパラ

Table 3. Condition of Filter and Method in simulation

	Filter	Method
Case 1	Kalman Filter or H_∞ Filter	Proposed method
	H_∞ Filter	
Case 2	Kalman Filter	Conventional method

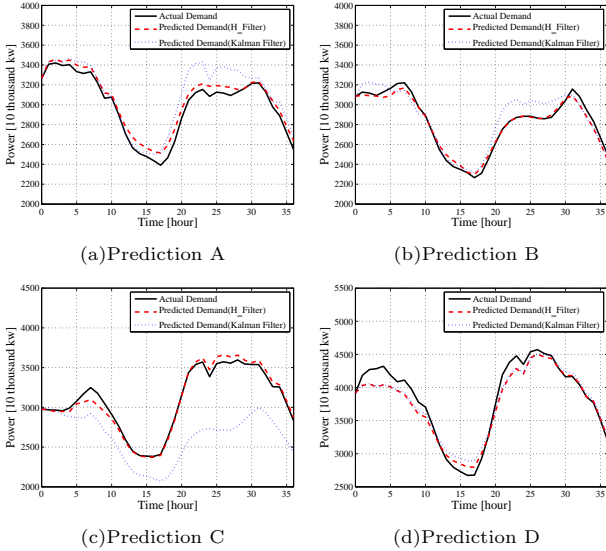


Fig. 12. Predicted result by Proposed and Conventional methods in Case 2

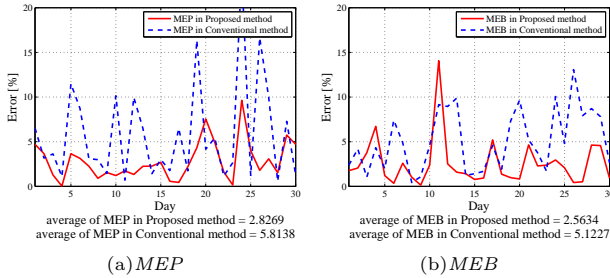


Fig. 13. Result of MEP and MEB for a month (without considering characteristics of load curve)

Table 4. Predicted result of MEP and MEB in Case 2

	Method	MEP [%]	MEB [%]
Prediction A	Conventional	1.7404	1.9179
	Proposed	0.4355	5.1950
Prediction B	Conventional	16.3343	7.3205
	Proposed	2.1913	1.3617
Prediction C	Conventional	16.6185	13.0696
	Proposed	1.7865	0.4203
Prediction D	Conventional	0.5727	8.7038
	Proposed	1.5246	4.6189

メータ推定を行った。パラメータ推定には過去 30 日間の需要データと気温データを使用し、パラメータ推定によって得た値をモデルに代入することによって予測値を計算した。また、得られたデータを逐次的に代入計算することに

よって 36 時間先まで予測した。この時、需要曲線は予測日の当日と翌日を考慮した組み合わせによって過去データを適切に選んだ。以下に本論文の結論をまとめる。

- (1) 提案法は文献⁽¹⁷⁾の需要曲線の特徴を考慮し、カルマンフィルタよりも本研究の目的に適した H_∞ フィルタを用い予測し、有効性を確認した。
- (2) 提案法は文献⁽⁶⁾に比べ予測精度は 0.3[%] 劣り、学習回数を約 200 分の 1 に抑え、予測説明に優れた明瞭な予測手法である。
- (3) 説明能力や学習回数よりも予測精度を重視する場合には文献⁽⁶⁾の従来法を用い、予測精度よりも説明能力を重視する場合は、学習回数に制限のある場合には提案手法を使うことが考えられる。
- (4) 今後は、理論的検討により、従来法よりもさらに高精度な予測手法を提案する必要がある。

謝 辞

本研究を進めるにあたり御協力いただいた北陸電力技術開発研究所の金尾則一氏をはじめ、金沢大学大学院の藤田裕之氏、武田孝史氏に深く感謝致します。

文 献

- (1) 横山明彦, 他著: 「スマートグリッドの構成技術と標準化」, 日本規格協会 (2010)
- (2) 電力系統の需給制御技術調査専門委員会: 「電力系統の需給制御技術」, 電気学会技術報告 (II 部) 第 302 号 (1989).
- (3) T. Onoda: "AI Technology in Next Day Electric Peak Load Forecast", Japanese Society Artificial Intelligence, Vol. 12, No. 4, pp. 550-558 (1997) (in Japanese)
小野田崇: 「翌日最大電力需要予測における AI 技術」, 人工知能学会誌, Vol. 12, No. 4, pp. 550-558 (1997)
- (4) O. Ishioka, Y. Sato, T. Ishihara, Y. Ueki, T. Matsui and T. Iizaka: "Development of Electric Load Forecasting System using Neural Networks", *IEEJ Trans B*, Vol. 120, No. 12, pp. 1550-1557 (2000) (in Japanese)
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」, 電学論 B, Vol. 120, No. 12, pp. 1550-1557 (2000)
- (5) S. Ito, K. Yukita, Y. Goto, K. Ichianagi and H. Nakano: "Daily Peak Load Forecasting of Next Day using Weather Distribution and Comparison Value of Each Nearby Date Data", *IEEJ Trans B*, Vol. 130, No. 3, pp. 329-337 (2010) (in Japanese)
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」, 電学論 B, Vol. 130, No. 3, pp. 329-337 (2010)
- (6) T. Iizaka, T. Matsui and Y. Fukuyama: "A New Training Method for Analyzable Structured Neural Network and Application of Daily Peak Load Forecasting", *IEEJ Trans B*, Vol. 124, No. 3, pp. 347-354 (2004) (in Japanese)
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」, 電学論 B, Vol. 124, No. 3, pp. 347-354 (2004).
- (7) T. Iizaka and T. Matsui: "Structured learning of neural networks for analysis and knowledge extraction", *IEEJ Trans C*, Vol. 121, No.3, pp.673-680 (2001) (in Japanese)
飯坂達也, 松井哲郎: 「解析と知識抽出のためにニューラルネットワークの構造化学習」, 電学論 C, Vol. 121, No. 3, pp. 673-680 (2001)
- (8) T. Ishida and S. Tamura: "Daily Electric Load Forecasting Using Artificial Neural Network", *IEEJ Trans B*, Vol. 114,


No. 11, pp.1109-1115 (1994) (in Japanese)
 石田隆張, 田村滋: 「ニューラルネットを用いた翌日電力需要予測」, 電学論 B, Vol. 114, No. 11, pp.1109-1115 (1994)

- (9) T. Haida: "Study on Daily Electric Load Curve Forecasting Method based on Regression Type Hourly Load Modeling with Yearly Load Trends, Day-types and Insulations", *IEEJ Trans B*, Vol. 129, No. 12, pp. 1477-1485 (2009) (in Japanese)
 灰田武史: 「日種別・日射量を考慮した時刻別回帰型トレンド調整項付き需要モデリングによる電力ロードカーブ予測手法」, 電学論 B, Vol. 129, No. 12, pp. 1477-1485 (2009)
- (10) W. R. Christiaan: "Short-term Load Forecasting Using General Exponential Smoothing", *IEEE Transaction on Power Apparatus and Systems*, Vol. PAS-90 (1971)
- (11) M. A. Abu-El-Maged, N. K. Shinha: "Short-term load demand modeling and forecasting: a review", *Trans. on Systems and Cybernetics*, No. 3, pp. 370-382 (1982)
- (12) S. Kawachi and H. Sasaki: "A Very Short-Term Load Forecasting of Long-Term Fluctuation Components in the Electric Power Demand", *IEEJ Trans B*, Vol. 124, No. 1, pp. 77-83 (2004) (in Japanese)
 河内清次, 佐々木博司: 「電力需要長周期成分の短時間先予測」, 電学論 B, Vol. 124, No. 1, pp. 77-83 (2004)
- (13) N. Ohmi and H. Mori: "A Gaussian Processes Technique for Short-term Load Forecasting with Considerations of Uncertainty", *IEEJ Trans B*, Vol. 126, No. 2, pp.202-208 (2006) (in Japanese)
 近江正太郎, 森啓之: 「ガウシアンプロセスによる不確定性を表現した短期電力負荷予測」, 電学論 B, Vol. 126, No. 2, pp.202-208 (2006)
- (14) K. Yukita, S. Kato, Y. Goto, K. Ichianagi and Y. Kawashima: "Daily Peak Load Forecasting by Structured Representation on Genetic Algorithms for Non-linear Function Fitting", *IEEJ Trans B*, Vol. 124, No. 3, pp. 355-362 (2004) (in Japanese)
 雪田和人, 加藤慎也, 後藤泰之, 一柳勝弘, 川島靖弘: 「構造的 GA による GMDH を用いた翌日最大電力需要予測」, 電学論 B, Vol. 124, No. 3, pp. 355-362 (2004)
- (15) T. Zheng, A. A. Girgis, E. B. Makram: "A hybrid wavelet-Kalman filter method for load forecasting", *Electric Power Systems Research*, Vol. 54, No.5, pp. 11-17 (2000)
- (16) I.Moghran and S.Ragman: "Analysis and evaluation of five short term load forecasting techniques", *IEEE Trans. on Power Systems*, Vol. 4, No. 4, pp. 1484-1491 (1989)
- (17) H.M.A. Hamadi and S. A. Soliman: "Short-term electric load forecasting based on Kalman filtering algorithm with moving window weather and load model", *Trans. on Electric Power Systems Research*, No.68, pp. 47-59 (2004)
- (18) T. Başar and P. Bernhard: " H_∞ Optimal Control and Related Minimax Design Problems", Birkhäuser (1995)
- (19) 片山徹: 新版 応用カルマンフィルタ, 朝倉書店 (2010)

細田康彦 (学生員) 2011年3月金沢大学工学部電気電子システム工学科卒業。同年4月慶應義塾大学大学院理工学研究科総合デザイン工学専攻博士前期課程入学。主としてフィルタリング理論に基づく予測の研究に従事。



滑川 徹 (正員) 1994年金沢大学大学院自然科学研究科



システム科学専攻博士課程中退。同年金沢大学工学部電気・情報工学科助手。同講師を経て2002年長岡技術科学大学機械系助教授。2006年金沢大学大学院自然科学研究科電子情報科学専攻助教授を経て2007年同大学理工研究域電子情報学系准教授。2009年より慶應義塾大学理工学部システムデザイン工学科准教授となり現在に至る。ロ

バスト制御理論, 分散協調制御理論とそのエネルギー環境システムへの応用に関する研究に従事。博士(工学)。計測自動制御学会, システム制御情報学会, IEEEなどの会員。