

$\mathcal{H}_\infty$ フィルタとクラスタリングによる短期太陽光発電量予測*細田 康彦^{*1}, 滑川 徹^{*2}Short-term Photovoltaic Prediction by using $\mathcal{H}_\infty$ Filtering and ClusteringYasuhiko HOSODA^{*1} and Toru NAMERIKAWA^{*2}^{*1*2} Department of System Design Engineering, Keio University
3-14-1, Hiyoshi, Kohoku-ku, Yokohama-shi, Kanagawa-ken, 223-8522, Japan

This paper deals with prediction algorithm applying for photovoltaic (PV) systems in smart grid. This prediction is aim to predict the amount of the next day of generation using the previous data and the weather forecast which get from Japan Meteorological Agency. The procedure of prediction consists of two steps, the data processing and the unknown parameters estimation. In the data processing, our proposed method considers the characteristics of PV generation using cluster ensemble. We propose the cluster ensemble based on k-means to choose the groups with a correlation with previous data. In the unknown parameters estimation, we provide the regression model for PV generation and the unknown parameters are estimated via $\mathcal{H}_\infty$ filtering. The effectiveness of the proposed prediction method is demonstrated through numerical simulations.

Key Words : PV, Short-term, Prediction, Smart Grid, Clustering, k-means, Estimation, $\mathcal{H}_\infty$ Filtering

1. は じ め に

環境・エネルギー問題への社会的な対応が早急な課題となっており、太陽光発電システム（PV システム）の導入はこれらの課題を解決するための有効な手段として期待されている⁽¹⁾。特に、PV システムは家庭での普及が多く見込まれていることから、各家庭単位での予測が必要とされる。しかし、ならし効果が適用できない単独での予測は困難であることが知られており、一般に PV システムは天候に左右されやすく、発電量は短時間に大きく変動し出力が不安定であることから高精度に予測することが求められている。また、PV システムの運用管理における技術的な問題点の一つが出力変動である⁽²⁾。出力変動は、出力抑制、電力貯蔵システム全体での調整機能に対応することとなる。その為、PV システムには出力変動の特性を把握するとともに、変動を予測することが求められている。

これまでに、太陽光発電の翌日の発電量を予測する研究として文献^{(2)~(7)}が挙げられる。文献^{(2)~(5)}ではデータベース型ブラックモデリングの一種である Just-In-Time モデリングやニューラルネットワークを用い、その入力に気象庁が配信する GVP(Grid Point Value) を使用し日射量を予測している。文献⁽⁶⁾では、用いる情報を過去の日射量と天気予報にとどめ、天気予報パターンから日射量を予測している。また、この時の天気予報は気象庁から得られる 3 時間間隔の予報を基に 1 時間間隔の予報を提案している。日射量から太陽光発電量を予測する際には、日射量から発電量へ変換する新たなモデルが必要である。そのため、太陽光発電の予測をする際には、太陽光パネルの温度特性を考慮したモデルを考える必要がある。また、文献⁽⁷⁾では太陽光パネルの温度特性を考慮し、サポートベクターマシン (SVM) を用いて、大規模な PV システムの発電量を天気予報と過去の太陽光発電出力から直接的に予測している。その際に各天気予報にモデルを与え天気予報ごとに予測している。SVM の特徴として、未学習データに対して高い識別性能を得るため太陽光発電の予測に対して有用な手法であると考えられる。

* 原稿受付 2012 年 7 月 17 日

*1 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 (〒 223-8522 神奈川県横浜市港北区日吉 3-14-1)

*2 正員、慶應義塾大学理工学部システムデザイン工学科 (〒 223-8522 神奈川県横浜市港北区日吉 3-14-1)

Email: yasuhiko@nl.sd.keio.ac.jp, namerikawa@sd.keio.ac.jp

本研究では、文献⁽¹⁾を拡張させ発電特性を考慮した、太陽光発電の翌日発電予測手法を提案する。具体的には回帰式によって太陽光発電モデルを表現し、過去の発電量から $\mathcal{H}_\infty$ フィルタによってパラメータを推定する。その際に、過去の発電データをクラスタリングによって発電特性を判別する。提案法の特徴として、予測の信頼性をパラメータ推定の係数によって陽に保証し、さらに3時間間隔の天気予報から1時間間隔の発電量を予測する。本稿では $\mathcal{H}_\infty$ フィルタとクラスタリングによる予測法を提案し、文献⁽⁷⁾との比較することで有効性を検証する。

2. 問題設定

本節では扱うモデルやいくつかの仮定、定義に関して述べる。太陽光発電モデルを設計するにあたり以下を仮定する。

仮定 1.

気象庁により24時間先までの気温情報、天候予報の情報が取得できる。

仮定 2.

予測対象である太陽光発電の過去90日間の発電データ、気温データの情報を蓄積している。

仮定1は予測をするために必要な未来の情報であり、具体的には3時間間隔で得られる気象庁による天気予報を用いる。仮定2は予測をするために必要な過去の情報であり、パラメータ推定のために用いる。

2.1 太陽光発電特性と予測アルゴリズム

本節では太陽光発電特性を考察し、発電特性から予測アルゴリズムを提案する。図1に7日間の太陽光発電の発電の軌跡、図2にある1日の発電量の軌跡を示す。図1の横軸は時刻と日付、縦軸は発電量を示し、図2の横軸は時刻、縦軸は発電量を示している。図1より、太陽光発電の発電波形がおおよそ似通っているといえ、12時から15時にかけて最大値をとっている。図2から、天候パターンによって大きく発電量が左右されることがわかり、晴れの日15時から17時にかけてなど時折、急激な発電量の変化の様子も見て取れる。これらより、予測は過去の発電特性を考慮し、天気予報に基づく天候情報から予測精度の向上が考えられる。




Fig. 1 Power Generation Data for 7 Days




Fig. 2 Characteristics of PV Generation

以上で考察した太陽光発電の発電特性を考慮した予測アルゴリズムを図3に示す。予測手順は大まかにデータプロセスとパラメータ推定の2つの手順から成る。データプロセスでは過去の発電データを用いて天気パターンごとに分け、パラメータ推定では予報と過去データに基づいて予測値を計算する流れとなっている。具体的に、データプロセスでは太陽光発電の特徴を考慮するため、k-平均法に基づくクラスタリングアルゴリズムによって過去データから発電特性を判別し天候パターンごとに分ける。パラメータ推定では、次節で述べる回帰式による数理モデルに基づき、パラメータを $\mathcal{H}_\infty$ フィルタによって過去データを用いてモデルの未知パラメータを推定する。この時、データプロセスによって天候パターンごとに分けられたデータと、気象庁による予報データに基づいてデータを選別したデータからパラメータ推定する。

2.2 太陽光発電モデル

太陽光発電の発電原理は、太陽光パネルに入射した光エネルギーによって電子が誘起され、半導体内に電位差が生じ発電する。この時、半導体は温度特性を持つため温度は発電効率に依存する⁽⁸⁾⁽⁹⁾。時刻 $t \in \mathbb{Z}_+$ におけるパネル




Fig. 3 Prediction Process

温度 $T_p(t)$ と発電効率 $\eta(t)$ の関係式を (1) 式に示す^{(7)~(9)}.

$$\eta(t) = \eta_o (1 - \alpha (T_p(t) - T_o)) \quad (1)$$

ただし, T_o は基準温度として 298 [K], η_o は T_o における変換効率, $\alpha (> 0)$ はパネル温度とバッテリーによる係数である.

太陽光発電量の一般化線形モデルを (1) 式の変換効率を用いて, (2) 式の回帰式によって表されたとする.

$$y(t)\eta(t) = a(t-24)y(t-24)\eta(t-24) + a(t-48)y(t-48)\eta(t-48) + \dots + a(t-24p)y(t-24p)\eta(t-24p) \quad (2)$$

(2) 式は時刻 t の温度を規格化した発電量 $y(t)\eta(t)$ が温度を規格化した過去発電量 $y(t-24)\eta(t-24), y(t-48)\eta(t-48), \dots, y(t-24p)\eta(t-24p)$, 未知係数 $a(t-24), a(t-48), \dots, a(t-24p)$ の積に等しいことを意味する. また, $p \geq 1$ はモデルの次数を表し, サンプリング時間は 1 時間とする. 左辺の発電効率 $\eta(t)$ を移項して (2) 式は (3) 式と表現できる.

$$\begin{aligned} y(t) &= a(t-24)y(t-24)\frac{\eta(t-24)}{\eta(t)} + a(t-48)y(t-48)\frac{\eta(t-48)}{\eta(t)} + \dots + a(t-24p)y(t-24p)\frac{\eta(t-24p)}{\eta(t)} \\ &= \sum_{i=1}^p a(t-24i)y(t-24i)\frac{\eta(t-24i)}{\eta(t)} \end{aligned} \quad (3)$$

未知係数を推定するにあたり, (3) 式に基づきモデルを離散時間状態空間表現とし, 時刻 $k+1$ の太陽光発電システムは (4) 式とする.

$$x_{k+1} = x_k + w_k \quad (4)$$

ただし, $x_k \in \mathbb{R}^{p \times 1}$ は p 次元状態ベクトルとし (5) 式に表す.

$$x_k = [a_k(t-24) \quad a_k(t-48) \quad \dots \quad a_k(t-24p)]^T \in \mathbb{R}^{p \times 1} \quad (5)$$

また, $w_k \in \mathbb{R}^{p \times 1}$ はプロセス雑音で正規分布に従う共分散行列 $W > 0$, 平均 0 の白色雑音過程であるとする.

具体的に, 状態モデル (4) は (6) 式のように更新される.

$$\begin{bmatrix} a_{k+1}(t-24) \\ a_{k+1}(t-48) \\ \vdots \\ a_{k+1}(t-24p) \end{bmatrix} = \begin{bmatrix} a_k(t-24) \\ a_k(t-48) \\ \vdots \\ a_k(t-24p) \end{bmatrix} + \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} w_k \quad (6)$$

時刻 $k+1$ の未知係数が時刻 k における状態ベクトル, プロセス雑音によって表されている.

時刻 k における観測モデルは (7) 式とする.

$$y_k = C_k x_k + v_k \quad (7)$$

ただし, C_k は p 次元観測ベクトルであり (8) 式により

$$C_k = \begin{bmatrix} y_k(t-24) \frac{\eta_k(t-24)}{\eta_k(t)} & y_k(t-48) \frac{\eta_k(t-48)}{\eta_k(t)} & \cdots & y_k(t-24p) \frac{\eta_k(t-24p)}{\eta_k(t)} \end{bmatrix} \in \mathbb{R}^{1 \times p} \quad (8)$$

$v_k \in \mathbb{R}^{1 \times 1}$ は観測雑音で正規分布に従う共分散行列 $V > 0$, 平均 0 の白色雑音過程とする.

具体的に, 時刻 k の (7) 式の観測モデルは (9) 式で更新される.

$$y_k = \begin{bmatrix} y_k(t-24) \frac{\eta_k(t-24)}{\eta_k(t)} & y_k(t-48) \frac{\eta_k(t-48)}{\eta_k(t)} & \cdots & y_k(t-24p) \frac{\eta_k(t-24p)}{\eta_k(t)} \end{bmatrix} \begin{bmatrix} a_k(t-24) \\ a_k(t-48) \\ \vdots \\ a_k(t-24p) \end{bmatrix} + v_k \quad (9)$$

ここでシステム (4), (7) に含まれる雑音成分に関する仮定を以下にまとめる.

仮定 3. システム (4), 観測モデル (7) に対して以下の雑音の仮定が成り立つ.

1. $E\{w_k w_s^T\} = E\{v_k v_s^T\} = 0 (k \neq s)$: 現時刻の自己相関以外は 0
2. $E\{v_k w_k^T\} = 0$: 白色性であるためシステム雑音と観測雑音は無相関
3. $E\{w_k w_k^T\} = W > 0, E\{v_k v_k^T\} = V > 0$:
4. 与えられた N に対して次式を満たす積算エネルギーが有界な確定的雑音である.

$$\sum_{k=0}^N \|w_k\|^2 < \infty, \quad \sum_{k=0}^N \|v_k\|^2 < \infty$$

2.3 予測更新式

24 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 hour ahead

$$\hat{y}(t+1) = a(t-24)y(t-24) \frac{\eta(t-24)}{\eta(t+1)} + a(t-48)y(t-48) \frac{\eta(t-48)}{\eta(t+1)} + \cdots \\ \cdots + a(t-24p)y(t-24p) \frac{\eta(t-24p)}{\eta(t+1)} \quad (10)$$

• 2 hours ahead

$$\hat{y}(t+2) = a(t-23)y(t-23) \frac{\eta(t-23)}{\eta(t+2)} + a(t-47)y(t-47) \frac{\eta(t-47)}{\eta(t+2)} + \cdots \\ \cdots + a(t-24p+1)y(t-24p+1) \frac{\eta(t-24p+1)}{\eta(t+2)} \quad (11)$$

⋮

• 24 hours ahead

$$\hat{y}(t+24) = a(t-1)y(t-1) \frac{\eta(t-1)}{\eta(t+24)} + a(t-25)y(t-25) \frac{\eta(t-25)}{\eta(t+24)} + \cdots \\ \cdots + a_p(t-24p+23)y(t-24p+23) \frac{\eta(t-24p+23)}{\eta(t+24)} \quad (12)$$

ここで $\hat{y}$ は予測値である. 太陽光発電モデル (3) では 1 時間先から 24 時間先までを予測するにあたり過去の観測値のみを用いて予測している.

2.4 予測目的

予測目的はエネルギーの有効利用のために翌日の太陽光発電量を高精度に予測することにある. 予測精度の評価関数を平均相対誤差 MRE (Mean Relative Error), 平均二乗誤差 $RMSE$ (Root Mean Square Error), 平均二乗誤差に基

づく評価関数 J_{rmse} を用い, (13)-(15) 式により定義する.

$$MRE = \frac{1}{N} \sum_{t=1}^N \frac{\|y(t) - \hat{y}(t)\|}{W_{total}} \times 100 \quad [\%] \quad (13)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^N (y(t) - \hat{y}(t))^2}{N}} \quad [W] \quad (14)$$

$$J_{rmse} = \frac{RMSE}{W_{total}} \times 100 = \frac{\sqrt{\frac{\sum_{k=1}^N (y(k) - \hat{y}(k))^2}{N}}}{W_{total}} \times 100 \quad [\%] \quad (15)$$

ただし, W_{total} は太陽光発電の定格出力を表し, 本稿で扱う実験機は 55[W] である. N はデータ数を表す. これらの評価関数は予測した時刻でのみ評価し, 本検証では 8 時から 18 時までの 11 時間で評価する. なお, 評価関数 $MRE, RMSE, J_{rmse}$ が小さくなる予測問題, ならびに予測手法を考える.

定義 1. 定格出力: 定格出力とは国際規格で定められたある条件 (STC: *Standard Test Condition*, 標準試験条件) のもとで得られる最大の出力のことで, パネルの温度は 298[K], 日射量 1000[W/m²] (快晴時相当の強さの光) を照射して発電される発電出力を定格出力とする.

3. パラメータ推定

本節では, 回帰モデルの未知パラメータの推定アルゴリズムについて述べる. 本稿はパラメータ推定において $\mathcal{H}_\infty$ フィルタを提案する. $\mathcal{H}_\infty$ フィルタ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, 未来の予測値を推定する問題において陽に予測の信頼性を保証することが必要である. 具体的には, 予測に必要な過去情報を取り扱っている本問題においては, 情報量が十分性を検討する必要がある. 本稿で提案する予測手法では推定の様子から陽に予測の信頼性を保証しており, 予測に必要な情報量を満たしているか否かを判断できることが本提案法の特徴である.

3-1 $\mathcal{H}_\infty$ フィルタによる推定

本節では $\mathcal{H}_\infty$ フィルタについて記述する. $\mathcal{H}_\infty$ 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, PV システムの様に外的な要因に依存することで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.

設計パラメータ γ を (16) 式を満たすように設計する. $\mathcal{H}_\infty$ フィルタを用いることで (4), (7) 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⁽¹⁾.

$$\sup_{x_0, v} \frac{\sum_{k=0}^N \|x_k - \hat{x}_k\|^2}{\|x_0 - \hat{x}_0\|_{P_0}^2 + \sum_{k=0}^N \|w_k\|_{W^{-1}}^2 + \sum_{k=0}^N \|v_k\|_{V^{-1}}^2} < \gamma^2 \quad (16)$$

ここで, P_0, W, V は初期状態 x_0 , プロセス雑音 w_k , 観測雑音 v_k のそれぞれにおける重み行列を意味し, それぞれ状態誤差共分散行列の初期値, プロセス雑音の共分散行列, 観測雑音の共分散行列である. (16) 式から, 推定値 $\hat{x}_k$ は初期値の不確かさを考慮している. また, 推定エネルギーと雑音エネルギーの和と推定エネルギーの和の比の最大値を γ^2 未満と抑えることで, 最悪な状況を想定した予測をしている. 一般に, (16) 式の左辺を x_k について最小化することが本来の $\mathcal{H}_\infty$ フィルタの最適フィルタリング問題であるが, 特別な場合を除いて最適値を求めることができないため γ を設計することで (16) 式の準最適フィルタリング問題を解く. 適当な大きさの γ から始めて少しずつ値を減少させながら解を繰り返し求めて, 満足の行く解が得られるまでこの過程を続ける.

$\mathcal{H}_\infty$ フィルタアルゴリズムは以下の再帰計算で表現される.

$$\hat{x}_{k+1|k} = \hat{x}_{k|k} \quad (17)$$

$$\hat{y}_{k|k-1} = C_k \hat{x}_{k|k-1} \quad (18)$$

$$S_k = \text{cov}(y_k - \hat{y}_{k|k-1}) \quad (19)$$

$$K_k = P_{k|k} C_k^T S_k^{-1} \quad (20)$$

$$x_{k|k} = \hat{x}_{k|k} + K_k (y_k - \hat{y}_{k|k-1}) \quad (21)$$

$$\psi_k = I + (C_k^T V^{-1} C_k - \gamma^{-2} I) P_{k|k} \quad (22)$$

$$P_{k+1|k} = P_{k|k} \psi_k^{-1} + W \quad (23)$$

(17)-(18) 式は予測の過程であり, この予測値を基に (19) 式では観測値と予測値の誤差の期待値を計算している. (20) 式では観測値と予測値の誤差によってカルマンゲインを更新式し, (21) 式ではカルマンゲインによって状態推定の更新をしている. (22)-(23) 式では観測誤差共分散の更新を行なっている. 上記の (17)-(23) 式で表す推定アルゴリズムによって (16) 式を満たすように繰り返し推定を行う.

3.2 k -平均法に基づくクラスタリング

本節では k -平均法に基づくクラスタリングを提案する. クラスタリングの目的は相関の持つデータの集合に分けることによって, 発電特性を考慮したパラメータ推定をすることを考える. 本稿では観測データとして発電量と気温データの 2 次元のデータを取り扱い, これらのデータに対してクラスタリングを用いることで過去データの特徴を考慮し予測する. 一般的な k -平均法は n 次元のデータの分類に適した手法である. しかしながら, 初期値に関してランダムに選択するため初期値依存が大きい欠点を持つ⁽¹⁰⁾⁽¹¹⁾. 本稿では気温と発電量の 2 次元のデータを扱っているため (1) 式により気温に関して標準化することで 1 次元のデータとして扱う. そこで k -平均法に関して以下に問題を定義する.

問題 1. 1 次元のデータに対して初期値依存問題を解決する k -平均法に基づくアルゴリズムを求めよ.

以上の問題 1 に対し, k -平均法に基づくクラスタリングアルゴリズムを以下に示す.

k 個のデータ $z_1, \dots, z_k$ を n 個のデータ集合 $\mathbb{Z} = \{Z_1, \dots, Z_n\}$ に分割することを考える. ただし, $k \geq n$ とする.

1. k 個のデータ $z_1, \dots, z_k$ を大きさ順に並べる.
2. データの最大値から n 等分し, n 個のグループに分類する. これにより初期グループの集合 $\mathbb{Z} = \{Z_j \mid j = 1, \dots, n\} \in \mathbb{Z}$ が生成する.
3. Z_j の中心である d_o を計算し, 初期非類似度とする.
4. 非類似度 $d_j(Z_j)$ を (24) 式により求める.

$$d_j(Z_j) = \|E[Z_j]\| \quad (24)$$

ただし, $\|\cdot\|$ は絶対値を表す.

5. 非類似度 d_i が最小となるようにグループを割り当てる.
6. ステップ 4 に戻り, 非類似度を計算しグループを割り当てることを繰り返し, グループの移動がなくなるまで続ける.

4. 太陽光発電予測

本節では前節までの議論を基に, 慶應義塾大学矢上キャンパス 24 棟屋上に設置した太陽光発電を予測した. 太陽光発電予測は本研究室で計測した 1 分間隔の発電データを 1 時間間隔で平均化し事前に処理したデータを用い予測を行った. また, 予測検証期間として 2012 年 6 月 1 日から 2012 年 6 月 30 日まで予測を行い, 予測には予測日の過去 90 日間までを遡った発電データを用いた. 気象データは気象庁による予報を用いて予測する. 具体的には, 晴れ, 曇, 雨の 3 パターンを想定している. しかし, 本稿での予測は クラスタリングで分別したデータが天気パターン

に一致すると仮定し、天気予報を用いていない。太陽光発電機の定格は 55 [W] であり方角は北、地面に対して 30 度の傾きで固定している。また、周辺には日影となる障害物がない環境に太陽光発電を設置している。

4.1 予測条件

太陽光発電モデルとして (25) 式を設ける。

$$y(t) = a(t-24)y(t-24)\frac{\eta(t-24)}{\eta(t)} + a(t-48)y(t-48)\frac{\eta(t-48)}{\eta(t)} + a(t-72)y(t-72)\frac{\eta(t-72)}{\eta(t)} \quad (25)$$

時刻 t を予測するにあたり 24, 48, 72 時間前の発電データを用いてモデル化する。この時、(4), (7) 式の各行列は以下となる。

$$x_k = [a_k(t-24) \quad a_k(t-48) \quad a_k(t-72)]^T \quad (26)$$

$$C_k = \begin{bmatrix} y_k(t-24)\frac{\eta_k(t-24)}{\eta_k(t)} & y_k(t-48)\frac{\eta_k(t-48)}{\eta_k(t)} & y_k(t-72)\frac{\eta_k(t-72)}{\eta_k(t)} \end{bmatrix} \quad (27)$$

また、状態、推定誤差共分散行列の初期値 x_0, P_0 , プロセス雑音、観測雑音の共分散 W, V , 設計パラメータ γ は以下とした。

$$x_0 = \begin{bmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{bmatrix}, \quad P_0 = I_3, \quad W = 10^{-6}I_3 \\ V = \text{cov}(Y^n), \quad \gamma = 7.5$$

ただし、ここでの Y^n は過去も発電量を観測した集合とする。

4.2 予測結果と考察

パラメータ推定の収束結果例として、ある日時における収束の様子を図 4 に示す。横軸はイテレーション回数であり、縦軸が未知パラメータの大きさである。推定結果からパラメータが一定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 (2) 式の太陽光発電モデルに代入することによって予測値を計算する。このことから、物理システムと対応がとれた予測手法であり、提案法の特徴でもある。また、収束の様子から、推定の初期には変動は大きい、イテレーションが進につれ一定値に収束しており、予測ができていることを表す。これより、陽に予測の信頼性を保証しているといえる。晴れ、曇り、雨の日における具体的な予測結果を図 5-7 に示す。検証期間での $MRE, RMSE$ の推移を図 8-9 に示す。また、図 8-9 の横軸は日に対応している。具体的な予測結果から、良好な予測結果が得られていることがみてとれる。 $MRE, RMSE$ の推移により、 MRE は平均 5.95 [%], 最大でも 16 [%] 以内の予測結果となった。また、 $RMSE$ に関しては、定格容量 55 [W] に対して平均で 10.85 [W] となった。これは文献⁽⁷⁾の定格容量 20 [MW] に対して MRE の平均 8.6 [%], $RMSE$ の平均 2.1 [MW] と比較すると、文献⁽⁷⁾に比べ精度よく予測できていることがわかる。また、 J_{rmse} に関しては文献⁽⁷⁾と比較して 66[%] 予測精度を向上させることができた。

Table 1 Result of Each Evaluation (Average)

	MRE	RMSE	J_{RMSE}	Rated Capacity
Proposed	5.95 [%]	10.85 [W]	38.7 [%]	55 [W]
Conventional ⁽⁷⁾	8.6 [%]	2.1 [MW]	105 [%]	20 [MW]

5. お わ り に

本稿では $\mathcal{H}_\infty$ とクラスタリングによる短期太陽光発電予測手法を提案した。予測は家庭などの小型太陽光発電を想定し、家庭内での電力の計画的な運用の為に発電波形と発電量を予測する。具体的には (2) 式の太陽光発電モデルを設計し、天候ごとに発電特性を考慮するためクラスタリングによってデータを判別し、 $\mathcal{H}_\infty$ フィルタを用いて未知パラメータを推定する。予測には過去 90 日間の発電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する。提案手法の特徴として、過去データや計算量が少なく、予測の信頼性を保証した予測手法を提案している。予測結果から、提案法では文献⁽⁷⁾と比較して精度のよい予測手法であることを確認した。今後の課題として、実際に想定した予報データを用いて予測をすると共に、さらなる予測精度の向上を図っていきたい。




Fig. 4 Parameter Estimation Result




Fig. 5 Example of Rainy Day




Fig. 6 Example of Cloudy Day




Fig. 7 Example of Sunny Day




Fig. 8 Result of MRE for a Month




Fig. 9 Result of RMSE for a Month

文 献

- (1) 滑川徹, 細田康彦, ”需要曲線の特徴を考慮した $\mathcal{H}_\infty$ フィルタによる短期電力需要予測”, 電学論 C, Vol. 132, No. 9, (2012). (掲載決定)
- (2) 沈浩洋, 日野英逸, 村田昇, 若尾真治, ”JIT モデリングによる太陽光発電量予測とその信頼性評価”, 情報処理学会研究会資料, (2011).
- (3) A. Yona, T. Senjyu, A. Yousuf Saber and T. Funabashi, ”Application of Neural Network to 24-hour-Ahead Generating Power Forecasting for PV System”, *Power and Energy Society General Meeting Conversion and Delivery of Electrical Energy in the 21st Century, IEEE*, pp.281-297, 2008.
- (4) A. Mellit and A. M. Pavan, ”A 24-h of solar irradiance using artificial neural network: Application for Performance prediction of a grid-connected PV plant at Trieste, Italy”, *ELSEVIER. Solar Energy*, pp. 807-821, 2010.
- (5) 鈴木孝宣, 後藤悠主, 寺園隆宏, 若尾真治, 大関崇, ”Just-In-Time Modeling に基づく日射量予測手法の開発”, 電学論 B, Vol. 114, No. 11, pp.912-919 (2011)
- (6) 嶋田尊衛, 黒川浩助, ”天気予報と天気パターンを用いた日射予測”, 電学論 B, Vol. 127, No. 11, pp.1219-1225 (2007)
- (7) J. Shi, W. J. Lee, Y. Liu, Y. Yang and P. Wang, ”Forecasting Power Output for Photovoltaic Systems Based on Weather Classification and Support Vector Machine”, *IEEE Transaction on Industry Applications*, Vol. 48, No. 3, pp.1064-1069, 2012.
- (8) G. S. Kinsey, K. Stone, J. Brown and V. Garboushian, ”Energy prediction of amonix cpv solar power plants”, *Press in Photovoltaics: Research and Application*, 2010.
- (9) H. Tsai, C. Tu, and Y. Su, ”Development of Generalized Photovoltaic Model Using MATLAB / SIMULINK”, *Proceedings of the World Congress on Engineering and Computer Science*, pp. 22-24, 2008.
- (10) D. Steinley and M. J. Brusco, ”Initializing k-means Batch Clustering: A Critical Evaluation of Sev-eral Techniques”, *Journal of Classification*, Vol.24, No.1,pp.99-121, 2007.
- (11) J.B.MacQueen, ”Some methods of classification and analysis of in multivariate observations”, *Proc. of 5th Berkley Symposium on Math. Stat. and Prob*, pp.281-297, 1967.