

メモリベースパーティクルフィルタに基づく 太陽光発電予測モデルの提案

吉村 卓也^{4,a)} 金森 亮^{1,b)} 伊藤 孝行^{2,3,c)}

概要: 効率的なエネルギー利用の実現に向けて、再生可能エネルギーや蓄電制御を行うためのエネルギー管理システム (EMS) が注目されている。特に日本においては家庭への太陽光発電の導入が推進されており、家庭単位での EMS が必要となっている。太陽光発電は天候によって短い時間間隔で発電量が大きく変動することから、精度の高い発電量予測を組み込んだ EMS が研究されているが、本研究ではパーティクルフィルタに基づく太陽光発電量予測モデルを検討する。パーティクルフィルタは動的に大幅に変化する値の予測・追跡に有効な時系列フィルタリングであり、本研究ではメモリベースパーティクルフィルタ (Memory-based Particle Filter: M-PF) に基づいた太陽光発電予測モデルを提案する。適切な発電量パターンについて過去の発電実績を参照して予測分布を生成し、その予測分布を用いて太陽光発電量を予測できる特徴を有する。単純な天候別平均値と M-PF 導入時との比較実験から、時々刻々と変化する太陽光発電量予測手法として提案モデルの有用性を示す。

キーワード: パーティクルフィルタ, メモリベースパーティクルフィルタ, 太陽光発電予測, エネルギー管理システム

1. はじめに

電力使用量の監視や、再生可能エネルギー、蓄電池機器などの制御はエネルギー管理システム (EMS) において重要視されてきており、今後のエネルギー有効活用の観点から研究が盛んに行われている。EMS では需要や発電量の予測の高制度化はシステム全体でのエネルギー運用効率を向上させることに直結し、重要な機能として位置づけられている。特に、日本では PV による再生可能エネルギーの発電に注力しており、普及率を向上させるために国や自治体等の助成金による政策が行われており^{*1}、家庭単位での PV の予測が必要とされている。一般に、PV システムは天候などの環境によって発電量が大きく左右されてしまうため、短い時間間隔で出力が不安定である。

本研究では、パーティクルフィルタを活用した太陽光発電の出力を短期間予測可能な手法を提案する。パーティクルフィルタ [1], [2] とは、時系列フィルタの一種で、非線形または非ガウス型のあらゆる状態空間型のモデルに適用可能なフィルタリング手法で、多目的最適化によるアプローチ [3]、ガウス型のあらゆる状態空間型のモデルに適用可能なフィルタそして電力売買や価格決定に対するアプローチ[?]として活用されている。また、文献 [4] では、過去の履歴を元に多次元マルコフ過程に基づきサンプリングによるメモリベースパーティクルフィルタについて述べられており、メモリベースパーティクルでは、過去に起きた事象は再び発生することを前提として、メモリに記録された過去のデータを元に次に発生する値を予測する。予測では、過去のデータを元に確率分布を生成して、その確率分布を用いてフィルタリングが行われている。本研究では、文献 [4] で提案される過去の事象は繰り返し発生する仮定に則り、メモリベースパーティクルフィルタでの太陽光発電予測を行う。実験では、メモリベースパーティクルフィルタに必要な履歴のデータのサイズによる感度分析を行い、太陽光発電の特性に適する予測機能を実装する。更に、予測制度を評価し、本研究で提案する手法の有用性について述べる。

¹ 名古屋工業大学
Nagoya Institute of Technology, Nagoya, Aichi, Japan

² 名古屋工業大学情報工学科
, Nagoya Institute of Technology, Nagoya, Aichi, Japan

³ 名古屋工業大学産業戦略専攻
, Nagoya Institute of Technology, Nagoya, Aichi, Japan

⁴ 名古屋工業大学大学院情報工学専攻
, Nagoya Institute of Technology, Nagoya, Aichi, Japan

a) yoshimura.takuya@itolab.nitech.ac.jp

b) kanamori.ryo@nitech.ac.jp

c) ito.takayuki@nitech.ac.jp

*1 平成 25 年度補助金制度の概要 J-PEC 太陽光発電普及拡大センター

2. 関連研究

次世代電力網としてスマートグリッドと呼ばれる構想が注目を集められている背景から、電力利用の効率化のためのマネジメントや蓄電池制御などの研究が盛んに行われてきている。太陽光発電の発電量予測に関する研究では、文献 [5] や, [6], [7], [8] が挙げられる。文献 [5] は, 24 時間先までの発電量予測を太陽光発電の発電特性を考慮した予測モデルを構築し, スwitchingカルマンフィルタを活用した発電量予測の手法について述べられている。文献 [8] は, 太陽光発電で得られる発電量を蓄電池の利用と共に効率的に利用する手法を, 発電パネルの温度や発電出力を最適化問題を解くアプローチによって提案している。特に曇りなどの最も発電量が不安定になる時に有効であり, 発電量の利用効率が 64% まで向上する結果が得られている。文献 [7] では, 太陽光発電の発電量予測のためには天候の予測が重要となることが述べられており, SVM による天候判別を行い, 実際の過去の発電量のデータをベースとした発電モデルを SVM によって設計している。中国の発電所に適用して, 効果的な結果が得られている。マルチエージェントによるアプローチから電力マネジメントの提案を行う研究が行われており [3], [9], [10], [11], [12], [13], [14], [15], [16], [17], [18], エージェントの技術を用いた電力マネジメントエージェントによるアプローチから電力取引の制御や管理を行うための研究として, ゲーム理論を用いた経済分野からのアプローチ [11], [13], 多目的最適化によるアプローチ [3], [19], そして電力売買や価格決定に対するアプローチ [12], [14], [15], [16], [18], [20] などがある。電力マネジメントエージェントとは, 太陽光発電パネルと蓄電池を備えた住宅に対して電力マネジメントを行うエージェントを想定しており, スマートグリッドにおける需要家側の電力マネジメントの課題をエージェント技術を用いて解決を目指す。電力マネジメントエージェントは, 適切な定義により自律的に問題を解決する能力を備えるエージェントの特長から, スマートグリッドの問題解決手段として効果的であるとして用いられているアプローチである。

文献 [21] では, 日本の現実的な消費電力データの利用と太陽光発電の導入, そして学習を行うエージェントを用いた電力マネジメントについて提案している。特に, 需要家における次世代型の電力マネジメントに着目しており, 次世代型の電力マネジメントは詳細な需要情報の収集と需要に即した最適な電力制御できるため, スマートハウスの実現において有効である。基本的に電力マネジメントエージェントは可能な限り電力購入量を少なく抑えて, 家庭によって利益となる行動を取ることを目的とする。つまり, エージェントの戦略としては, 家庭の蓄電状況や昼間の太陽光発電による余剰電力を有効活用することが重要となる。設

置料を除けば, 比較的安価に入手可能な太陽光発電によるエネルギーを利用することで, 家庭の電力購買量を抑えることができるため, 消費者側は総合的な電気料金を低価格にできるメリットがある。また, 購買量を減少させることで, 電力網への負担が軽減したり, ピークが分散されることから電力会社にとってもリスク回避や安定供給の実現に繋がるメリットがある。

本研究では, 太陽光発電設備を備える家庭において, より蓄電池や発電量の監視及び制御を行うための管理機能として高精度の予測機能について着目し, 高精度化のための予測モデルを提案する。

3. パーティクルフィルタ

ある状態の確率分布を多数のサンプル値で近似的に計算する。ある状態の事後分布を求める際は, 定義した観測値によって定まり, それぞれの粒子の尤度を用いる。粒子フィルタの基本的な考え方は, 与えられた観測値を条件付き分布から多数の粒子のサンプル値に近似表現していくことで, 近似された値(粒子)は状態予測モデルに基づき予測が行われる。予測には, 粒子の観測値からの尤度計算によって行われる。尤度計算では, 尤度の高い粒子は分裂し, 新しい粒子が発生して, 尤度が小さければ粒子が消滅していく。問題に応じて状態予測モデル及び観測モデルを定義する必要があり, 以下に非線形かつ非ガウス型の状態空間型モデルの関数を示す。

$$\mathbf{x}_t = f(x_{t-1}, \theta_t u_t) \quad (1)$$

$$\mathbf{y}_t = h(x_t, \eta_t, v_t) \quad (2)$$

(1 式) と (2 式) について説明する。 \mathbf{x}_t は時刻 t の k 次元の状態ベクトル, \mathbf{y}_t は時刻 t の l 次元の観測ベクトル, θ_t, η_t はパラメータベクトル, u_t, v_t はそれぞれガウス分布に限らない確率密度関数に従うシステムノイズと観測ノイズで, 白色ノイズとする。 f, h は非線形関数であり, (1 式) は状態ベクトルの時間ステップを表す状態方程式, (2 式) は観測方程式である。

一期先の状態 \mathbf{x}_t の予測の確率分布(事前確率)は

$$p(\mathbf{x}_t | \mathbf{y}_{1:t-1}) = \int p(\mathbf{x}_t | \mathbf{x}_{t-1}) p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1}) dx_{t-1} \quad (3)$$

と表される。時刻 t までの観測ベクトル $\mathbf{y}_{1:t}$ が得られた後に, フィルタリングされた状態 \mathbf{x}_t の確率分布(事後確率)はベイズの定理より,

$$p(x_t | \mathbf{y}_{1:t}) = \frac{p(\mathbf{y}_t | \mathbf{x}_t) p(\mathbf{x}_t | \mathbf{y}_{1:t-1})}{p(\mathbf{y}_t | \mathbf{y}_{1:t-1})} \quad (4)$$

となる。これらの (3), (4) 式の条件付き確率を独立した多数の粒子を用いて近似を行う。(3) 式の前確率を用いて,

$$p(\mathbf{x}_t | \mathbf{y}_{1:t-1}) \approx \frac{1}{N} \sum_{i=1}^N \delta(\mathbf{x}_t - \mathbf{x}_{t|t-1}^{(i)}) \quad (5)$$

と近似する. N は粒子数, δ はディラックのデルタ関数, $\mathbf{x}_{t-1}^{(i)}$ は時刻 t の i 番目の粒子の事前推定値である. (5) 式を (4) 式に代入して, 観測値 \mathbf{y}_t を加えた事後確率が次の式になるように粒子 $\mathbf{x}_{t|t}^{(i)}$ を求める.

$$p(\mathbf{x}_t|\mathbf{y}_{1:t}) \approx \frac{1}{N} \sum_{i=1}^N \delta(\mathbf{x}_t - \mathbf{x}_{t|t}^{(i)}) \quad (6)$$

(5) 式, (6) 式の粒子 $\mathbf{x}_{t|t-1}^{(i)}, \mathbf{x}_{t|t}^{(i)}$ は (1) 式, (2) 式に従って以下の手順で求めていく.

(1) 初期化

時刻 $t-1$ として, i 番目の粒子 ($i = 1, \dots, N$) についてフィルタリング後の状態値 $\mathbf{x}_{t-1|t-1}^{(i)}$ が与えられる (図1の第一列目の粒子集合).

(2) 予測

状態方程式 (1) 式により i 番目の粒子 ($i = 1, \dots, N$) の予測値を求める. 従って, 事前確率が (5) 式によって求められる (図1の第二列目の粒子集合).

(3) フィルタリング

(4) 式の $p(\mathbf{y}_t|\mathbf{x}_t)$ は状態 \mathbf{x}_t の時に観測 \mathbf{y}_t が得られる尤度であり, 観測式 (2) 式から定まる $R(\mathbf{y}_t|\mathbf{x}_{t|t-1}^{(i)})$ によって得られる. 図1の第三列の粒子集合の大きさは尤度の大小を表しており, 観測値との適合度を計算して, 高い粒子ほど尤度が大きいことを示す. (4) 式の分母の $p(\mathbf{y}_t|\mathbf{y}_{1:t-1})$ は

$$p(\mathbf{y}_t|\mathbf{y}_{1:t-1}) = \int R(\mathbf{y}_t|x_t)p(x_t|\mathbf{y}_{1:t-1})dx_t \approx \frac{1}{N} \sum_{i=1}^N R(\mathbf{y}_t|x_{t|t-1}^{(i)}) \quad (7)$$

となり, (5) 式, (7) 式を (4) 式に代入すると事後確率として以下の式が得られる.

$$p(\mathbf{x}_t|\mathbf{y}_{1:t}) \approx \sum_{i=1}^N w_t^{(i)} \delta(x_t - x_{t|t-1}^{(i)}) \quad (8)$$

$w_t^{(i)}$ は正規化された尤度である.

$$w_t^{(i)} = R(\mathbf{y}_t|x_{t|t-1}^{(i)}) / \sum_{i=1}^N R(\mathbf{y}_t|x_{t|t-1}^{(i)}) \quad (9)$$

(4) リサンプリング

正規化された尤度(重み) $w_t^{(i)}$ に比例して $\mathbf{x}_{t|t-1}^{(i)}$ を復元抽出して, 抽出された粒子を $\mathbf{x}_{t|t}^{(i)}$ とする (図1の第四粒子集合). 抽出した粒子の合計を N 個とする. 粒子の重みは全て $1/N$ となり, 最終的に事後分布 (6) 式が得られる. さらに, リサンプリング後の各粒子の状態またはパラメータにランダムな攪乱を与えて, 特定の粒子のみが選択されない工夫を行う.

(5) 更新

時間を更新して 1 に戻る.

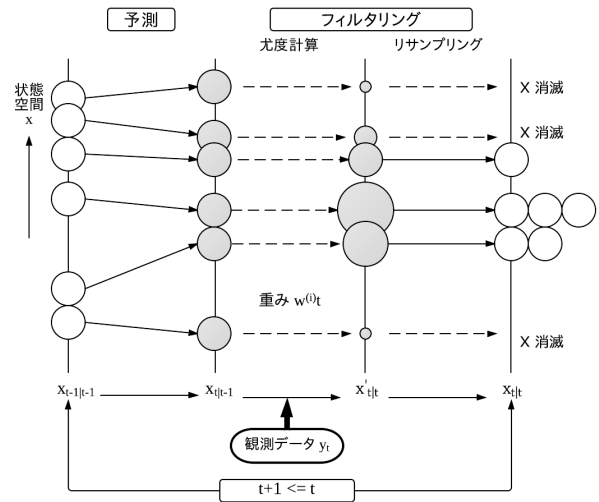


図1 粒子フィルタの概念図

以上により, x_t の最適推定量 \hat{x}_t と推定誤差分散 $\hat{\sigma}_t$ は次の (10), (11) 式によって求めることができる.

$$\hat{x}_t = E[x_t] \approx \frac{1}{N} \sum_{i=1}^N x_{t|t}^{(i)} = \sum_{i=1}^N w_t^{(i)} x_{t|t-1}^{(i)} \quad (10)$$

$$\hat{\sigma}_t^2 = \frac{1}{N} \sum_{i=1}^N (x_{t|t}^{(i)} - \hat{x}_t)^2 = \sum_{i=1}^N w_t^{(i)} (w_t^{(i)} (x_{t|t-1}^{(i)} - \hat{x}_t)^2) \quad (11)$$

3.1 メモリベースパーティクルフィルタ

メモリベースパーティクルフィルタ (Memory-based Particle Filter: M-PF) とは, 複雑なダイナミクスを持つ対象の動きに対して追跡を可能とするパーティクルフィルタの手法である [4]. 一般的なパーティクルフィルタの性質として, 急激な動きに対する頑健性や, 遮蔽などによる追跡対象を見失った場合に対して迅速に追跡再開が挙げられるが, M-PF では追跡対象のダイナミクスのマルコフ性の制約を取り払い, 過去の長期のダイナミクスに基づいた状態を基に追跡を実現していく. 本研究では, 文献 [4] で述べられる過去に発生する事象は再び起こる可能性が高いという M-PF の仮定に則り, M-PF に基づく太陽光発電予測モデルを提案する.

4. 太陽光発電予測モデルへの適用

4.1 問題設定

太陽光発電は, 天候に大きく左右されることや, 時間帯によって発電出力が大きく変化する. また, 季節によっても発電量も変わるため, これらの特性を考慮する必要がある. そこで, 本研究で設計する予測モデルでは先に述べた3つの特性を考慮して以下の3つの処理を行う.

- (1) 天候毎によるパターンの識別
- (2) 過去のデータから類似性の高いパターンを検索
- (3) 蓄積データの周期性による季節変動の考慮

(1)では、家庭のエージェントが保持している蓄積データとして天気予報別で分けて記憶する。(2)では、追跡してきた発電量の推移を特徴ベクトルとみなして、過去の履歴のデータから類似した波形を検索して調整してく。(3)では、過去の履歴から検索するデータの範囲を指定する処理をする。現在追跡している時期が何時ごろの季節化によって検索場所を動的に変動させ、季節による変動影響を考慮する。

4.2 メモリベースパーティクルフィルタに基づく予測モデル

本研究では、メモリベースパーティクルフィルタに基づく太陽光発電予測モデルを設計する。パーティクルの値の更新は、現在のパーティクル値の状態から状態方程式を適用して新しいパーティクル値を推定していく。式(12)パーティクルフィルタによって生成されるパーティクルの次の状態を表す。

$$x_{t+1} = f(x_t) + w_t \quad (12)$$

関数 f は状態遷移を表し、次の状態の推定値を表す。 w_t は正規分布に基づく一様乱数である。次に、関数 f について詳しく述べる。本研究では、関数 f を M-PF の考えに則り、過去の履歴を参照して尤もらしい次の状態値を検索する仕組みを取り入れる。履歴から類似した状態値遷移のパターンを検索していき、状態分布を生成する。図2は類似する状態の参照を表しており、 Δt の間隔における状態変化を特徴ベクトルとして、現在時刻 t から Δt 前の状態変化の特徴ベクトル(検索ベクトル)と、過去の履歴から取得できる Δt 間隔の任意の特徴ベクトル(履歴ベクトル)との類似性を計算して検索を行う。検索ベクトルと履歴ベクトルの類似性を示す式は、式(13)によって与えられる。




図2 履歴から類似の状態変化のパターンを検索

$$\pi_t(\mathbf{v}(t), \mathbf{v}(t-n)) = C(\mathbf{v}(t), \mathbf{v}(t-n)) + U(\mathbf{v}(t), \mathbf{v}(t-n)) \quad (13)$$

$v(t)$ は検索ベクトル、 $v(t-n)$ は履歴ベクトルを表し、 π_t は検索ベクトルと履歴ベクトルの類似度を表す。関数 C は2つのベクトル $\mathbf{v}(t), \mathbf{v}(t-n)$ のコサイン類似度を表しており、コサイン類似度により2つのベクトルの向き

の類似性を考慮する。次に、関数 U はベクトル $\mathbf{v}(t), \mathbf{v}(t-n)$ のユークリッド距離から得られる距離の類似性を表す。距離と向きの特徴を考慮することで、過去の履歴で出現したパターンの波形と状態遷移時の変化量の特徴量を抽出することができるため、より類似するパターンを過去の履歴から検索することができる。また、ユークリッド距離から計算される距離の類似性の計算式は次の式(14)によって与えられる。

$$U(\mathbf{v}(a), \mathbf{v}(b)) = \frac{1}{1 + \sqrt{\sum_{i=1}^N (\mathbf{v}_i(a) - \mathbf{v}_i(b))^2}} \quad (14)$$

検索される類似したベクトルの上位 N 位のベクトルの次の状態値を、新しいパーティクルの値として更新する。式15がパーティクルの更新式を表す式である。

$$x_{t+1} = \frac{\sum_{n \in R} v(n)}{N} + w(t) \quad (15)$$

R は類似するベクトル上位 N 位の履歴ベクトルの集合を表す。 $w(t)$ は正規分布に従う乱数項である。また、集合 R の履歴ベクトルから得られる次の値の推定値 \hat{x}_{t+1} として、式16で表すことができる。

$$\hat{x}_{t+1} = \sum_{n \in R} v(n) \quad (16)$$

パーティクルの尤度計算では次の値の推定値 \hat{x}_{t+1} からの距離によって計算し、図1でのリサンプリングのフェーズで尤度(重み)に基づいてパーティクルのリサンプリングを行う。

図3に、本研究で提案する予測モデルを用いたときの実測値、予測値及び平均的な発電モデルを示したある1日のグラフである。グラフは天候が晴れの時の発電量の推移を示しており、横軸は1目盛は15分のタイムステップの時間軸を表し、縦軸は太陽光発電によって発電される電力 W 数である。

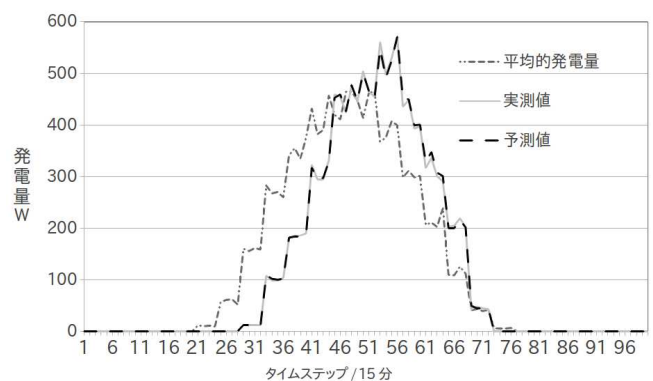


図3 パーティクルフィルタによる太陽光発電量予測

平均的な天候の発電曲線のモデルは、気象庁が提供する晴れ日数、曇り日数及び雨日数から定義する。太陽光発電量のモデルは日本気象協会の太陽光発電用標準気象データ

METPV-11*2を用いている。グラフから、本研究で提案する予測モデルのグラフと実測値の予測値が限りなく近い値で追従できていることがわかる。実験では、パラメータとして履歴として蓄積しておく過去のデータ量(メモリのサイズ)と、検索ベクトルの次元数について具体的な数値を示した結果を示し予測精度の評価を行い、提案する手法の有用性について示す。

5. 評価実験

5.1 実験設定

本研究で提案する太陽光発電予測モデルでは、以下のパラメータを調整して、最適な予測モデルを設計する。

- メモリの蓄積サイズ: M
- 検索ベクトルの次元数: D

本研究での実験ではメモリの蓄積サイズ M を 365 日、次元数 D を 3 とし、3 年間のシミュレーション実験を行った。実験では平均的な予測曲線のモデルと、本研究で提案するパーティクルフィルタに基づく太陽光発電予測モデルの比較実験を行う。平均的な予測曲線は気象庁データの 1 年間での晴れ日数、雨日数、及び曇り日数と METPV-11 で提供される日射量データを元に、各天候の 1 日の時間別太陽光発電量の平均値を曲線モデルとして扱う。また、扱うデータ(気象庁の天候の日数及び METPV-11 の日射量データ)は日本の愛知県名古屋市のもの採用する。比較には 1 日のグラフの各時間帯での平均二乗誤差を指標として、実測値との誤差を計測して評価する。

5.2 実験結果

実験設定から、3 年間のシミュレーションを行った結果をまとめる。まずはじめに、540 日目まで得られる図 4 の 10 日間のパーティクルフィルタによる予測結果を示すグラフについて述べる。グラフで示される 1 日目から 10 日目の天候をそれぞれ、曇り、晴れ、曇り、晴れ、雨、晴れ、晴れ、曇り、晴れそして雨の順で示されている。グラフから、10 日間の予測と実測値は殆ど一致していることが分かり、提案する予測モデルは正しく予測ができていることがわかる。また、図 5 は 1081 日目から 10 日間の予測結果を示しており、同様に予測値は実測値に追従できていることがわかる。以上の結果から、季節に対する変動に対しても対応できている。

次に、1080 日以降の実験結果の中から、曇、晴れ、及び雨の日の結果について比較する。1080 日以降を選択した理由は、シミュレーション実験を回す期間の設定を 3 年間とし、設定するメモリのサイズを校了しても十分な蓄積データが得られていると判断できるからである。1088 日

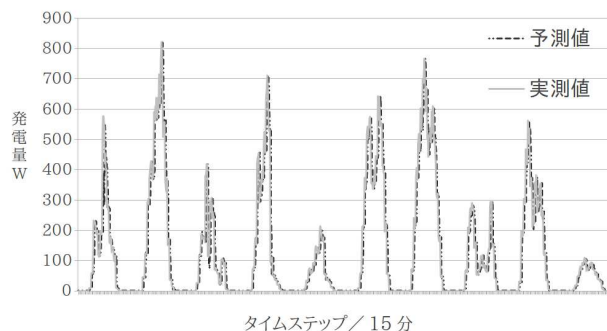


図 4 曇りの日の太陽光発電量推移




図 5 曇りの日の太陽光発電量推移

目の曇りの時の予測結果のグラフを 6 に示す。縦軸は発電量で、横軸が 1 日盛り 15 分刻みのリタイムステップを表す。グラフから予測モデルの方が平均的な予測モデルよりも追従していることがわかる。また、平均的なモデルが低いのは、曇りの時に発電量のむらが多いためであり、とりわけ予測機能が必要となってくる。本研究で提案する予測モデルは十分に予測ができていることがグラフから見て取れる。次に、1089 日目での晴れの時の予測結果のグラフを 7 に示す。縦軸は発電量で、横軸が 1 日盛り 15 分刻みのリタイムステップを表す。グラフの結果から、予測モデルによる結果がより実測値に追従していることがわかる。次に、1090 日目で得られた天候雨の予測結果のグラフを 8 に示す。縦軸は発電量、横軸が 1 日盛り 15 分刻みのリタイムステップを表す。グラフから、実測値の発電推移は M 字型となっており、時間による変動が発生していることがわかる。予測モデルの結果を見ると、急激な変化にも対応して実測値に追従できていることがわかる。

表 5.2 は、図 7 と図 8 で得られた平均的な曲線モデルと提案する予測モデルの実測値からの平均二乗誤差を示した表である。表の結果から、雨及び晴れの療法で予測モデルの平均二乗誤差が低いため、提案する予測モデルは正確に予測できていることが分かる。

6. まとめ

家庭に設置される太陽光発電は様々な環境に応じて出力が大きく変動するため、それらの環境状態に応じた高精度

*2 日射量データベース, NEDO, 新エネルギー産業技術総合開発機構, 独立行政法人, <http://www.nedo.go.jp/library/nissharyou.html>




図 6 曇りの日の太陽光発電量推移

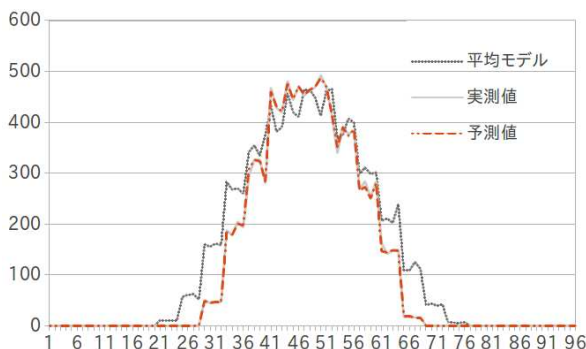


図 7 晴れの日の太陽光発電量推移




図 8 雨の日の太陽光発電量推移

表 1 各天候の平均モデルと予測モデルの平均二乗誤差

	平均二乗誤差
平均モデル(晴れ)	44.458
提案モデル(晴れ)	3.171
平均モデル(曇り)	149.059
提案モデル(曇り)	2.938
平均モデル(雨)	32.127
提案モデル(雨)	1.479

の予測機能を実装することが重要視されており、本研究では太陽光発電予測の高精度化のためのパーティクルフィルタを用いた予測モデルを提案した。また、蓄積された過去の履歴のデータを元に予測モデルを生成し予測を行うメモリベースパーティクルフィルタに基づく、より複雑なダイナミクスを持つ対象の動きに対応可能な予測モデルを実

装した。実験では、平均的な天候別の予測曲線モデルと本研究で提案する予測モデルによる予測精度の比較を行った。実験結果から、両モデルの実測値との平均二乗誤差の数値から示す値が、提案する予測モデルが最も低く実測値との誤差が低いことが分かり、予測精度の高い太陽光発電予測モデルを実装することができた。

参考文献

- [1] 樋口知之: 粒子フィルタ, 電子情報通信学会誌, Vol. 88, No. 12, pp. 143-148 (2005).
- [2] 加藤丈和: “パーティクルフィルタとその実装方(チュートリアル)”.
- [3] Sathyanarayana, B. R. and Heydt, G. T.: A Roadmap for Distribution Energy Management via Multiobjective Optimization (2010). Power and Energy Society General Meeting.
- [4] 三上弾, 大塚和弘, 大和淳司: メモリベースパーティクルフィルタ: 状態履歴に基づく事前分布予測を用いた頑健な対称追跡, 電気情報通市学会論文誌, Vol. J93-D, No. 8, pp. 1313-1328 (2010).
- [5] 細田康彦, 滑川徹: スイッチングカルマンフィルタとクラスタリングによる短期太陽光発電予測, 第55回自動制御連合講演会, Vol. 51, No. 1, pp. 1446-1453 (2012).
- [6] Shi, J., Lee, W.-J., Liu, Y., Yang, Y. and Wang, P.: Forecasting Power Output of Photovoltaic Systems Based on Weather Classification and Support Vector Machine, *IEEE Transactions on Industry Applications*, Vol. 48, No. 3 (2012).
- [7] Shi, J., Lee, W.-J., Liu, Y., Yang, Y. and Wang, P.: Forecasting Power Output of Photovoltaic Systems Based on Weather Classification and Support Vector Machine, *IEEE Transactions on Industry Applications*, Vol. 48, No. 3 (2012).
- [8] Powell, K. M., Hedengren, J. D. and Edgar, T. F.: Dynamic Optimization of a Solar Thermal Energy Storage System over a 24 Hour Period using Weather Forecasts, *American Control Conference (ACC)* (2013).
- [9] Perukrishnen V, Thomas D. Voice, S. v. D. R. A. R. and Jennings, N. R.: AgentBased Control for Decentralised Demand Side Management in the Smart Grid (2011). Proc. of the 10th International Joint Conference on Autonomous Agents and Multi-agent Systems (AAMAS-2011).
- [10] Perukrishnen V, Thomas D. Voice, S. v. D. R. A. R. and Jennings, N. R.: Agentbased Micro-Storage Management for the Smart Grid (2010). Proc. of the 9th International Joint Conference on Autonomous Agents and Multi-agent Systems (AAMAS-2010).
- [11] 畑中健志藤田政之: システム科学技術のための分散協調最適化とポテンシャルゲーム, 計測と制御, Vol. 50, No. 1 (2012).
- [12] Thomas D. Voice, Perukrishnen Vytelingum, S. D. R. A. R. and Jennings, N. R.: Decentralized Control of Micro-Storage in the Smart Grid (2011). Proc of the Twenty-Fifth Conference on Association for the Advancement of Artificial Intelligence (AAAI-2011).
- [13] 谷口忠大, 高木圭太, 榎原一紀, 西川郁子: 地産地消型電力ネットワークの為に Natural Actor-Critic を用いた自動取引エージェントの構築, 日本知能情報ファジィ学会ファジィシステムシンポジウム講演論文集, Vol. 25, pp. 229-229 (2009).
- [14] Nabona, N. and Pages, A.: A three-stage short-term

- electric power planning procedure for a generation company in a liberalized market, *International Journal of Electrical Power and Energy Systems*, Vol. 29, No. 5, pp. 408 – 421 (online), DOI: 10.1016/j.ijepes.2006.10.004 (2007).
- [15] Sichao, K., Yamamoto, H. and Yamaji, K.: Evaluation of CO2 free electricity trading market in Japan by multi-agent simulations, *Energy Policy*, Vol. 38, No. 7, pp. 3309 – 3319 (online), DOI: 10.1016/j.enpol.2010.02.002 (2010). Large-scale wind power in electricity markets with Regular Papers.
- [16] Gnansounou, E., Pierre, S., Quintero, A., Dong, J. and Lahlou, A.: A multi-agent approach for planning activities in decentralized electricity markets, *Knowledge-Based Systems*, Vol. 20, No. 4, pp. 406 – 418 (online), DOI: 10.1016/j.knosys.2006.06.004 (2007).
- [17] Bunn, D. W. and Oliveira, F. S.: Agent-based analysis of technological diversification and specialization in electricity markets, *European Journal of Operational Research*, Vol. 181, No. 3, pp. 1265–1278 (online), DOI: 10.1016/j.ejor.2005.11.056 (2007).
- [18] Pinto, T., Morais, H., Oliveira, P., Vale, Z., Praa, I. and Ramos, C.: A new approach for multi-agent coalition formation and management in the scope of electricity markets, *Energy*, Vol. 36, No. 8, pp. 5004 – 5015 (online), DOI: 10.1016/j.energy.2011.05.045 (2011). PRES 2010.
- [19] Azadeh, A., Skandari, M. and Maleki-Shoja, B.: An integrated ant colony optimization approach to compare strategies of clearing market in electricity markets: Agent-based simulation, *Energy Policy*, Vol. 38, No. 10, pp. 6307 – 6319 (online), DOI: 10.1016/j.enpol.2010.06.022 (2010). The socio-economic transition towards a hydrogen economy - findings from European research, with regular papers.
- [20] Prashant P. Reddy, M. M. V.: Learned Behavior of Multiple Autonomous Agents in Smart Grid Markets (2011). Proc of the Twenty-Fifth Conference on Association for the Advancement of Artificial Intelligence (AAAI-2011).
- [21] 川口将吾, 金森亮, 伊藤孝行: エージェントシミュレーションによる電力売買における価格変動制導入の影響分析 (2012). 情報処理学会研究報告 IPSJ SIG Technical Report.