

PV 発電量予測に基づくマイクログリッドの 確率的モデル予測制御

○竹田 皓貴 (立命館大学), 鷹羽 浄嗣 (立命館大学, JST-CREST)

Stochastic Model Predictive Control for Microgrid Management based on PV Power Prediction

*K. Takeda (Ritsumeikan University), K. Takaba (Ritsumeikan University, JST-CREST)

Abstract— This paper is concerned with a stochastic model predictive control (SMPC) method for power management of a microgrid with large scale PVs. Recently, PV power generation in total energy supply of electric power grids has been increasing. For the management of microgrids, it is important to explicitly take account of the prediction of PV power generation because it heavily depends on the weather and hence is unstable. We propose a method for microgrid management by combining the SMPC and the PV power prediction. In our method, the PV power is predicted by Just-In-Time modeling based on the weather forecast data. We demonstrate the effectiveness of the proposed method by a numerical simulation.

Key Words: microgrid, stochastic model predictive control, solar photovoltaics, Just-In-Time modeling

1 はじめに

環境問題やエネルギー問題の観点から、再生可能エネルギーの増加が期待される。再生可能エネルギーとは、風力発電、地熱発電や太陽光発電などの自然から得られるエネルギーをもとに発電して得られるエネルギーの総称である。再生可能エネルギーの中でも太陽光発電は、他の再生可能エネルギーに比べて発電機である太陽光発電機 (PV) の設置が容易であり、安価であるという点から大量導入が期待される。

本研究では、PV の大量導入に備えて、電力の需給制御問題を考える。PV は、発電量が天気に依存するため扱いが難しい。大きな問題点としては、供給が不安定であるため電力系統に直接接続してしまうと系統電力の品質低下の恐れがある。そこで本研究では、PV を直接系統に接続するのではなく、PV の電力を地産地消し優先的に利用するマイクログリッドを構築しその制御を考える。マイクログリッドは Fig.1 のような小規模な電力網の総称である。また、効率的なマイクログリッド運用のために天気を考慮した PV 発電量予測に基づいて制御を行う。PV 発電量予測については、Just-In-Time モデリングを用い、この予測に基づいた確率的モデル予測制御 (SMPC) によってマイクログリッド運用する。




Fig. 1: A microgrid model

2 PV 発電量予測

本研究では、PV 発電量予測に基づいた制御を行うが、序説で述べたように PV 発電量は天気に依存するため予測が難しい。そこで、鈴木ら¹⁾によって提案された、気象庁の MSM-GPV による気象予報に基づいた

Just-In-Time モデリングによる日射量予測および日射量と PV 発電量の関係式を用いることにより予測を実現する。

2.1 Just-In-Time(JIT) モデリング

PV 発電量予測の流れは次のようになる。

- 1) 予測日の気象予報データを取得する。
- 2) 予測日に類似しているデータを過去データを蓄積したデータベースより選択する。
- 3) 選択したデータの実測日射量をもとに予測日の日射量を予測する。
- 4) 予測日射量をもとに PV 発電量を予測する。

取得した気象予報データから過去のデータをもとにして予測日の日射量を得るために次節で述べる JIT モデリングを用いる。Just-In-Time(JIT) モデリングはブラックボックスモデリングの一種である²⁾。Fig.2 のように、一般的なモデリングでは、入出力データに基づいてモデリングを行う。出力を予測するためには、得られた物理モデルに直接入力すれば良い。一方、JIT モデリングでは、入出力データをデータベースに蓄積する。出力を予測するためには、今回の入力データとデータベース内の入力データを比較する。入力が類似しているデータの出力と今回の出力は近いという考えの下で出力を予測する。

2.2 データベース

JIT モデリングでは予測のためにデータベースが必要となる。本研究では、気象庁の MSM-GPV データおよび日射量データをデータベースとして利用した。MSM-GPV とは、日本の気象を 5km ごとに 3 9 時間後までのシミュレーションを行う数値予測モデルである。内容としては、気圧、風 (南北/東西)、気温、湿度、時間降水

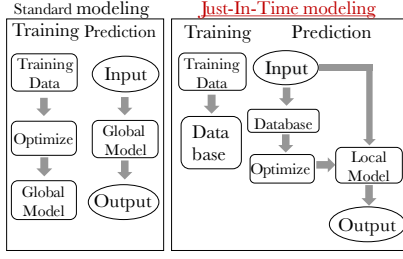


Fig. 2: Just-In-Time Modeling

量, 雲量 (高層/中層/低層) などがあり, 1日に8回更新されている.

本研究では, 上記の9つの気象情報に日射量に影響すると思われる太陽高度および日照時間の理論値を加えた11データの0時における1日分(0時から23時)を入力およびデータベースとし, 出力としては水平面日射量の実測値1日分(0時から23時)を利用した.

2.3 類似データ選択

JITモデリングにおいて精度の高い予測を行うためには, 適切なデータをデータベースより選択することが不可欠である. 本研究では, K -近傍法により入力データとデータベースの類似度を計算し, 類似度が高いデータを適当な数だけ取り出す. 類似度を計算するために, 次式の重み付きフロベニウスノルムを用いる.

$$d_j^{fro} = \sum_{h=0}^{23} \sum_{k=1}^{11} w_k |x_k^q(h) - x_k^j(h)|^2 \quad (1)$$

$$= \text{Tr}(X^q - X^j)^T W (X^q - X^j)$$

$$\mathbf{x}^j = \begin{bmatrix} x_1^j \\ x_2^j \\ x_3^j \\ x_4^j \\ x_5^j \\ x_6^j \\ x_7^j \\ x_8^j \\ x_9^j \\ x_{10}^j \\ x_{11}^j \end{bmatrix} = \begin{bmatrix} \text{DL}^j \\ \text{SA}^j \\ \text{Atm}^j \\ \text{Tem}^j \\ \text{Wew}^j \\ \text{Wsn}^j \\ \text{Hum}^j \\ \text{LC}^j \\ \text{MC}^j \\ \text{UC}^j \\ \text{RF}^j \end{bmatrix} \quad (2)$$

Table 1: Weather factors

DL : Day Length	日照時間
SA : Sun Altitude	太陽高度
Atm : Atmosphere	気圧
Tem : Temperature	気温
Wew : Wind (East - West)	風速 (東西成分)
Wsn : Wind (South- North)	風速 (南北成分)
Hum : Humidity	湿度
LC : Lower Cloudiness	雲量 (下層)
MC : Middle Cloudiness	雲量 (中層)
UC : Upper Cloudiness	雲量 (高層)
RF : Rain Fall	時間降水量

ここでの d_j^{fro} が入力データとデータベース内の j 番目データとの類似度, w_k が各気象要素と日射量の関連性を表す重みである. 行列 X^q, X^j は, それぞれの列ベ

クトル $x^q(h), x^j(h), (h = 0, 1, \dots, 23)$ からなる行列, 対角行列 W は要素 $w_k (k = 1, \dots, 11)$ を対角成分にもつ重み行列である. なお, x_k^q は入力データの k 番目成分, x_k^j はデータベース上の比較データ j の k 番目成分を示す.

本研究では, 日射量を目的変数, 気象要素を説明変数とした重回帰分析の偏回帰係数を重みとして利用している. 今回は, 最適な説明変数を赤池情報量基準 (AIC) に基づく変数減少法により決定し, その係数を利用した.

2.4 発電量予測

K -近傍法によって得られた近傍データの添え字を, $d_{j_1}^{fro} \leq d_{j_2}^{fro} \leq \dots \leq d_{j_K}^{fro}$ となるように, j_1, j_2, \dots, j_K とする. 類似データを選択後, 式 (3) の重み付き線形平均化 (LWA) により日射量を予測する.

$$y_p^{\text{JIT}} = \sum_{k=1}^K a_{j_k} y^{j_k}, \quad a_{j_k} = w_{j_k}^{\text{LWA}} / \sum_{l=1}^K w_{j_l}^{\text{LWA}} \quad (3)$$

y_p^{JIT} は予測値, y^j は K -近傍法によって得られた j 番目の近傍の日射量データ, w_j^{LWA} は j 番目の近傍の重みである. 重みは, 式 (4) の tri-cube 関数に基づく重みを採用する.

$$w_{j_k}^{\text{LWA}} = \left(1 - \left(\frac{d_{j_k}^{fro}}{d_{j_K}^{fro}} \right)^3 \right)^3 \quad (4)$$

JITモデリングによる予測誤差を補正するために, 本研究では K -近傍法によって得た近傍データを利用した AR モデルによる補正を行う. 日射量は次式で仮定される.

$$y_p = y_p^{\text{JIT}} + y_p^{\text{AR}} \quad (5)$$

本稿では, 予測誤差日射量が TAR 次の AR モデル (Autoregressive Model: 自己回帰モデル) で表されると仮定し次式で定義する.

$$y_p^{\text{AR}}(t) = a_1 \bar{y}(t-1) + a_2 \bar{y}(t-2) + \dots + a_{\text{TAR}} \bar{y}(t-\text{TAR}) + w_{\text{PV}} \quad (6)$$

ここで, $a_i (i = 1, 2, \dots, \text{TAR})$ は回帰係数であり, $\bar{y}(t)$ は時刻 t における JIT による予測と実測値との差, w_{PV} は平均 0, 分散 ρ のガウス白色雑音である.

回帰係数は, K -近傍法によって得られたデータを用いて最小 2 乗法により決定する.

$$(a_1, \dots, a_{\text{TAR}}) = \text{argmin} \sum_k |\bar{y}_{\text{KAR}}(k) - \bar{y}(k)|^2 \quad (7)$$

$\bar{y}_{\text{KAR}}(k)$ は時刻 k における, K -近傍 (KAR 個) それぞれの日射量と実測値との差を表す.

以上より, 予測日射量 \hat{y}_p は次式で定義される.

$$\hat{y}_p = y_p^{\text{JIT}} + \hat{y}_p^{\text{AR}} \quad (8)$$

$$\hat{y}_p^{\text{AR}}(t) = a_1 \hat{y}_p^{\text{AR}}(t-1) + a_2 \hat{y}_p^{\text{AR}}(t-2) + \dots + a_{\text{TAR}} \hat{y}_p^{\text{AR}}(t-\text{TAR}) \quad (9)$$

式 (9) の初期値は実測値より計算する.

JITモデリングで得られる日射量予測 \hat{y}_p は水平面日射量の予測であるため, PV 斜面の角度に応じて PV 発

電量予測に変換する必要がある。水平面日射量と PV 発電量との関係を線形モデル

$$P_{PV} = W_{nmo} \cdot PR \cdot y_{PV} \quad (10)$$

$$y_{PV} = \alpha \cdot y_p \quad (11)$$

で近似し、PV 発電量予測を

$$\hat{P}_{PV} = W_{nmo} \cdot PR \cdot \hat{y}_{PV} \quad (12)$$

により行う。ここで、 P_{PV} と \hat{P}_{PV} は PV 発電量とその予測値、 W_{nmo} は公称最大出力、PR(Performance Ratio) は PV の性能比、 α は水平面日射量を PV 斜面日射量 y_{PV} に変換する係数である³⁾。

以上によって求めた PV 発電量予測に基づいて、マイクログリッドの確率的モデル予測制御を行う。

3 マイクログリッド制御

3.1 マイクログリッドモデル

本研究では、一般的なマイクログリッドモデルを簡略化した Fig.3 のマイクログリッドモデルを考える⁵⁾ 6)。図中の矢印は電力の流れる方向を示している。本研

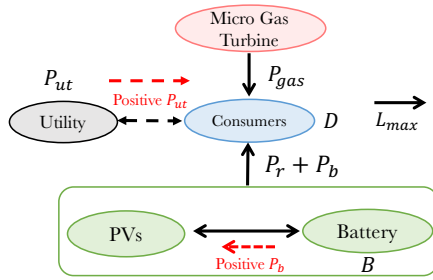


Fig. 3: Microgrid Model

究では、マイクログリッドの制御目標を次のように設定する。

- 1) グリッド内の需給バランスを保つ。
- 2) バッテリーの充電量をできるだけ高い状態に保つ。
- 3) マイクロガスタービンの供給電力を減らす。

制御目標 1) は、マイクログリッドの制御問題において最重要となる目標である。目標 2) は、災害などによってグリッドが系統から切断された場合や PV の発電量が急激に低下した場合に備えるためである。目標 3) は、補助電源としてのマイクロガスタービンよりも PV による発電電力を優先的に使うためである。Fig. 3 よりマイクログリッドモデルの関係式は次のようになる。

$$B(t+1) = B(t) - P_b(t), \quad (13)$$

$$0 \leq B(t) \leq B_{max}, \quad (14)$$

$$0 \leq P_{gas} \leq L_{max}^{gas}, \quad (15)$$

$$0 \leq P_r + P_b \leq L_{max}^{pvbat}. \quad (16)$$

式 (13) はバッテリーの充電量に関する式であり、式 (14) は容量の制約に関する式である。 $B(t)$ はバッテリーの充電量、 P_b はバッテリーの供給電力、 B_{max} はバッテ

リーの最大容量を示す。

式 (15)、(16) はマイクロガスタービンの供給電力に関する制約、PV およびバッテリーの供給電力に関する制約である。 P_{gas} はマイクロガスタービンの供給電力、 P_r は PV の発電量、 L_{max} は電線の送電最大容量を示す。

本研究では、マイクログリッド内での電力の地産地消を目指しており、電力系統からの電力融通は電力の過不足が起きた場合のみとするため、定式化に含めていない。

3.2 マイクログリッド制御

マイクログリッドの制御目標 1) に関して、式 (17) の等式制約を課す。

$$D(t) = P_{gas}(t) + \hat{P}_r(t) + P_b(t), \quad \forall t \geq 0. \quad (17)$$

$D(t)$ は需要電力量、 $\hat{P}_r(t)$ は前節で求めた PV 発電量予測値である。ここでの、 $D(t)$ は既知とする。

本稿では、予測量を扱うため式 (17) を式 (18) のように書き換える。

$$D[k] = P_{gas}[k] + \hat{P}_r[k] + P_b[k]. \quad (18)$$

$P_b[k]$ は時刻 t までの情報に基づく時刻 $t+k$ における値 $P_b(t+k)$ の予測値を表す。

制御目標 2) と 3) を達成するために式 (19) のようなコスト関数 J を導入する。

$$J = \frac{1}{2}P(B_{max} - B[T])^2 + \frac{1}{2} \sum_{k=0}^{T-1} (Q(B_{max} - B[k])^2 + RP_{gas}[k]^2). \quad (19)$$

ここでの T は予測ホライズン長、 P, Q, R は重み係数を示す。

以上の定式化により、マイクログリッドの運用を行うが、評価関数および制約条件に確率変数が含まれているためこの 2 次計画問題を解くことができない。そのため、評価関数に関しては期待値を考えることで、制約条件に関しては式 (20)-(21) のようにハード制約をソフト制約に置き換えることにより解決する。

$$\Pr\{\mathbf{w}_{PV} \in \mathbb{R}^T | F(\mathbf{w}_{PV}, P_b) \leq 0\} \geq 1 - \epsilon. \quad (20)$$

$$F(\mathbf{w}_{PV}, P_b) \leq 0 \Leftrightarrow \begin{cases} 0 \leq B[k] \leq B_{max}, \\ 0 \leq D[k] - \hat{P}_r[k] + P_b[k] \leq L_{max}, \\ 0 \leq \hat{P}_r[k] + P_b[k] \leq L_{max}, \\ k = 0, 1, \dots, T-1. \end{cases} \quad (21)$$

\hat{P}_r は時間相関を持つ確率変数であるから、式 (20)、(21) をそのまま扱うことは難しい。そのため、式 (20) を式 (22) に書き換え、式 (23) のようなサンプル数 n を考えることによって確定的な制約に書き換える⁴⁾。

$$\Pr\{\Pr\{\mathbf{w}_{PV} \in \mathbb{R}^T | F(\mathbf{w}_{PV}, P_b) \leq 0\} \geq 1 - \epsilon\} \geq 1 - \delta, \quad (22)$$

$$n \geq \frac{\log \frac{1}{\delta}}{\log \frac{1}{1-\epsilon}} \quad (23)$$

式 (22) は、有意水準 δ での対立仮定

$\Pr\{\mathbf{w}_{PV} \in \mathbb{R}^T | F(\mathbf{w}_{PV}, P_b) \leq 0\} \geq 1 - \epsilon$ の仮説検定を意味している。

以上より、マイクログリッドの確率的モデル予測制御問題は次のような 2 次計画問題に帰着する。

$$\begin{aligned} & \min_{P_b[0], \dots, P_b[T-1]} \mathbb{E}[J] \\ & \text{subject to} \quad B[k+1] = B[k] - P_b[k], \quad (24) \\ & \quad B[0] = B(t), \quad k = 0, 1, \dots, T-1, \\ & \quad F(\mathbf{w}_{PV}^i, P_b) \leq 0, \quad i = 1, 2, \dots, n. \end{aligned}$$

式 (24) において \mathbf{w}_{PV}^i は \mathbf{w}_{PV} のサンプルである。この 2 次計画問題の解は、マイクログリッド内のバッテリーの充電方策となる。これらの定式化は、マイクログリッド内での電力の地産地消を前提としており PV 発電量の予測と実測の差異は考慮されていない。本研究では、この差異については全て接続された系統との電力融通によって解決し、電力の不足分を補う系統からの買電を P_{ut} のプラス値、電力の過剰分を減らす系統への売電を P_{ut} のマイナス値として扱う。

4 シミュレーション

4.1 条件設定

シミュレーション環境を Table.2 に示す。

Table 2: Simulation Setting

Database	Jun. 1, 2011 to Dec. 31, 2015 (5years)
Input Data	Aug. 14, 2016 (a sunny day)
Area	Osaka, Japan (lat.35°40.9'N, long.125°31.1'E)
K-NN	K:20points
Software	MATLAB/Simulink R2016a
Solver	Sedumi 1.3
PC	OS: Windows10 64bit CPU: Intel® Core™ i7-5820@3.30GHz RAM: 32.00GB

SMPC の予測ホライズン長などのパラメータを Table.3 に示す。

Table 3: Simulation Parameters

TAR/KAR	3[steps]/10[Points]
Predictive Horizon	T=3 [steps]
Sample Time	0.5[h]
α	1.3
W_{nmo}	10[kWh]
PR	0.80(=80%)
D_{max}	7.5 [kWh]
B_0 / B_{max}	7 / 10 [kWh]
L_{max} (Gas/PV&Bat)	6 / 7 [kWh]
(P, Q, R)	(10, 10, 100)
(δ, ϵ, n)	(0.001, 0.01, 668)

求めた式 (1) の重み行列の各要素を Table.4 に示す。

本稿では、提案手法である PV 発電量予測を用いてシミュレーションを行った場合と JIT モデリングによ

Table 4: The factors of Weighting Matrix; W

Component	Weight
Day Length	0.54
Sun Altitude	0.86
Atmosphere	0.26
Temperature	0.68
Wind (East - West)	0.05
Wind (South- North)	0.006
Humidity	0.24
Lower Cloudiness	0.07
Middle Cloudiness	0.04
Upper Cloudiness	0.03
Rain Fall	0.01

る予測を用いずに予測ホライズン中に $k = 0$ における PV 発電量の値をホールドし、発電量としてシミュレーションした場合を比較して、予測に基づいた SMPC による制御の有用性を示す。

4.2 シミュレーション結果




Fig. 4: PV Power Prediction

Fig. 4 に示すように、JIT モデリングだけの予測 (青) よりも AR モデルによる誤差補正を行った場合 (黄) の方が、実測値 (赤) に近い予測となっていることがわかる。




Fig. 5: Supply and Demand

Fig. 5 に示すように、PV の予測と実測の差異により需要と供給のバランスが崩れている点があるがこれらの点に関しては電力系統より電力の融通が行われている。




Fig. 6: Micro Gas Turbine Power




Fig. 7: Battery State of Charge

Fig.6 に示すように提案手法 (青) では制約以下に収まっているが、予測を用いていない場合 (赤) では制約を破った実行不可能な解が出ている。これは Fig. 7 に示すように、単純に放電するだけでなく、予測を用いることによって計画的なバッテリーの充放電の方策を決定し、制約を十分に考慮した運用ができていたためだと考えられる。

5 おわりに

本稿では、PV の発電量予測に基づいたマイクログリッドの確率的モデル予測制御の手法とその有効性を示した。シミュレーション結果より予測を用いることによって制約を十分に考慮したバッテリーの充放電方策およびマイクロガスタービンの発電計画を立てることが可能であることを示した。

今後の課題として、需要家やバッテリーなどが多数に存在するような現実的なマイクログリッドモデルの制御問題を考えることなどが挙げられる。

謝辞 本研究に関して有益なご助言を頂いた京都大学太田快人教授に謝意を表します。

参考文献

- 1) 鈴木, 後藤, 寺園, 若尾, 大関 : “Just-In-Time Modeling に基づく日射量予測手法の開発”, IEEJ Transaction on Power and Energy, Vol. **131** No.11 912/919 (2011).
- 2) 牛田, 木村 : “Just-In-Time モデリング技術を用いた非線形システムの同定と制御”, 計測と制御, Vol. **44**, No. 2 102/105 (2005).
- 3) 新太陽エネルギー利用ハンドブック編集委員会編 : “新太陽エネルギー利用ハンドブック”, 日本太陽エネルギー学会 (2000).
- 4) 藤崎, 大石 : “ランダムイズドアルゴリズムによる制御システムの解析と設計”, システム・制御・情報, Vol. **53**, No. 5 189/196 (2009).
- 5) 竹山, 鷹羽 : “確率的モデル予測制御に基づくマイクログリッドの需給制御”, 第 60 回システム制御情報学会研究発表講演会 (SCI'16), Kyoto, May. 25-27 (2016).
- 6) A. Hooshmand, M.H. Poursaeidi, J. Mohammadpour, H. A. Malki, K. Grigoriadis: “Stochastic Model Predictive Control Method for Microgrid Management”, Proc. of 2012 IEEE PES Innovative Smart Grid Technologies Conference (ISGT2012) pp.1-7, (2012).