

スマートエネルギーシステムにおける太陽光発電予測

小 関 由 明 小 野 島 一 藤 田 尚 志
(本社技術本部) (本社建築本部)

小 島 義 包 小 山 岳 登
(本社設計本部) (本社設計本部)

Prediction of Photovoltaic Power Generation in Smart Energy System

Yoshiaki Ozeki Hajime Onojima Hisashi Fujita
Yoshikane Kojima Taketo Koyama

Abstract

Obayashi installed a smart energy system consisting of various distributed energy resources (a photovoltaic power generation system, micro-combined power generators, large-capacity batteries) in its technical research institute. To effectively utilize photovoltaic power generation, which is derived from renewable energy, and to control the distributed energy resources, a technique for predicting electric energy from the photovoltaic power generation system with high accuracy is necessary. In the smart energy system, multiple methods of predicting photovoltaic power generation are adopted for improving accuracy. It is also confirmed that even if the weather forecast is inaccurate, the electric energy from the photovoltaic power generation system for the next 30 - 60 minutes can be predicted with reasonable accuracy by an additional method of predicting photovoltaic power generation independent of weather forecast.

概 要

大林組は、種々の分散型電源(太陽光発電、マイクロコンバインド発電、大型蓄電池)から成るスマートエネルギーシステムを技術研究所内に構築した。再生可能エネルギー由来である太陽光発電を効果的に活用し分散型電源を制御するには、精度の高い太陽光発電予測技術が必要である。構築したスマートエネルギーシステムでは、精度向上を目指して複数の太陽光発電予測手法を採用した。また、天気予報に依存しない太陽光発電予測手法で補正することで、天気予報が外れた場合でも分散型電源制御に用いる太陽光発電電力量を実用的な精度で予測できることを確認した。

1. はじめに

スマートシティに要求される電力供給の安定性や自立性、及び環境適合性の実証を行うことを目的として、東京都内に位置する大林組技術研究所の構内に、スマートエネルギーシステム(以下「本システム」)を構築し、2015年2月より本格的に運用を開始した¹⁾。本システムは太陽光発電(以下「PV発電」)、マイクロコンバインド発電、大型蓄電池から成る分散型電源を有し、PV発電による再生可能エネルギーを最大限有効活用することを特徴とする。これら分散型電源を用いて電力需給制御を行うには、構内の電力需要予測のみならず、PV発電予測を精度良く行う必要がある。天気予報を基にした従来のPV発電予測では、予報が外れた場合の発電量予測精度が課題であった。そこで「天気予報に基づく事前のPV発電予測が100%的中することはなく必ず限界があるため、直前のPV発電実測値を基に補正して予測精度の向上を図る。」という発想に転換し、本システムのPV発電予測では、複数のPV発電予測手法を採用し、それらを組み合わせることで予測精度の向上を図った。本報では、本システムを支える

PV発電予測手法の概要と運用実績について報告する。

2. スマートエネルギーシステムの概要

大林組技術研究所に構築した本システム(Fig. 1参照)は、敷地面積約7万m²の構内にある約10棟の研究施設を電力網でつなぎ、分散型電源としてPV発電設備(約820kW)、マイクロコンバインド発電設備(ガスエンジン発電機200kW×2台+バイナリー発電機45kW×1台)、大型蓄電池であるレドックスフロー電池(出力500kW、容量3,000kWh)を有している。また電力の需給予測を基に、これらの分散型電源をエネルギーマネジメントシステム(以下「EMS」)によって統合的に制御・監視を行う。EMSの電力需給管理フロー(Fig. 2参照)に示すように、EMSの機能は需要計画・予測、需給計画・制御、見える化及び需給ひっ迫時のデマンドレスポンスから構成される。天気予報やビッグデータを活用したベース需要電力量とPV発電電力量の予測、実験装置の稼働予定などの電力ユーザーから得られる情報、及びリアルタイムの需給の把握に基づいて、本システムの統合管理を行うことを特徴

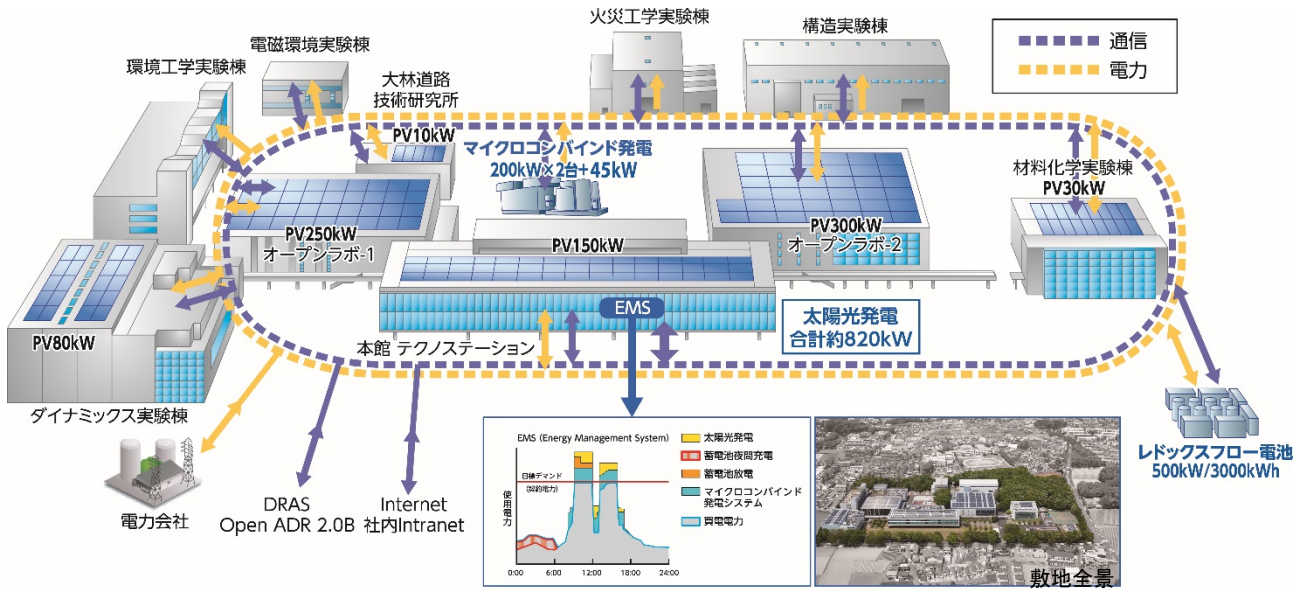


Fig. 1 スマートエネルギーシステム構成図
Smart Energy System Diagram

とする。

3. 太陽光発電予測手法

3.1 概要

本システムは30分先～1週間先(168時間後)まで30分刻みの電力需給計画を立案し、さらに30分毎に随時更新し、マイクロコンバインド発電電力・レドックスフロー電池充放電電力・受電電力で最適に分担する。PV発電設備容量は820kW(契約電力の1/2に相当)と比較的大きいため、PV発電量の予測精度が電力需給管理に大きく影響する。そこでPV発電電力量の予測手法として、ロングレンジ(以下「LR」)予測モデル及びショートレンジ(以下「SR」)予測モデルを用意し、組み合わせた(Fig. 3参照)。現時点から1週間先までを時系列天気予報を基に予測するLR予測モデルがおおまかに予測し、直前の実績値を基に直近30分先及び60分先をSR予測モデルが補正する。両予測モデルを組み合わせることで、天気予報が外れた際にも最適に需給計画ができる。なお、LR予測モデルは、後述する2種類のどちらかを選択できる仕組みとしている。PV発電予測を翌日のみではなく1週間先まで行うことで、例えば、休日に余剰となる電力量を天気に応じて平日のピークカットに利用するなど、蓄電池の充放電計画を効率よく行うことが可能となる(Fig. 4参照)。

3.2 ロングレンジ予測モデル(天気・発電係数法)

3.2.1 方法 LR予測モデルのうち、天気・発電係数法によるPV発電予測手法をFig. 5に示す。まず、雲一つない快晴時における水平面全天日射量(以下「計算日射量」)をブーゲの式及びベルラーゲの式を用いて計算により求める。それに天気予報から得られる天気毎に決定する天気係数を乗じて水平面全天日射量を予測する。さらに、水平面全天日射量とPV発電電力量の相関から求められ

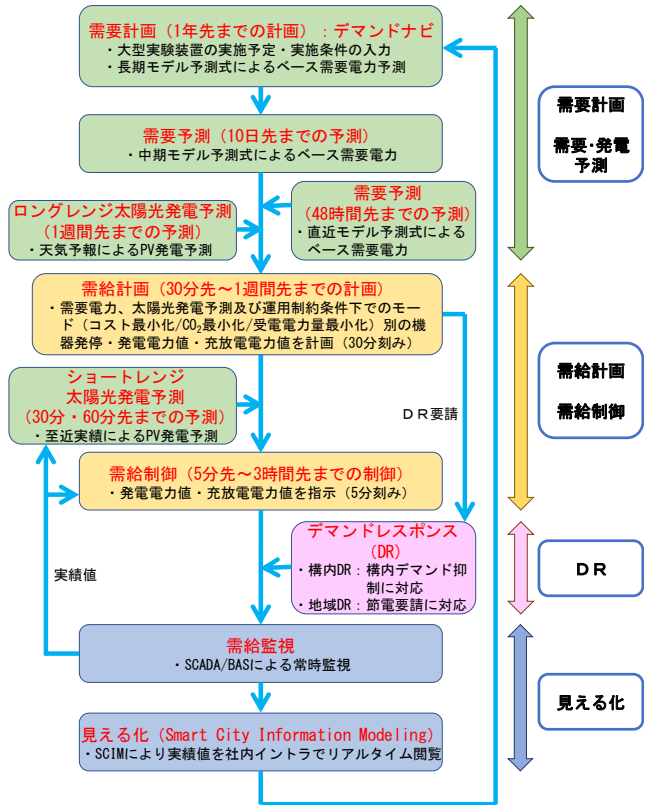


Fig. 2 EMSの電力需給管理フロー図
Power Demand and Supply Management Flow of EMS




Fig. 3 太陽光発電予測手法
Three Methods of Predicting Photovoltaic Power Generation




Fig. 4 余剰電力量の蓄電池充放電制御例
Example of Battery Charge and Discharge Control for Surplus PV Energy

る発電係数を乗じてPV発電電力量を予測する。

3.2.2 発電係数 発電係数を求めるため、技術研究所構内で計測された1年間の毎時実測データ(2014年3月～2015年2月, PV発電設備約700kW)を用いて、水平面全天日射量, PV発電電力量の分析を行った。その結果をFig. 6に示す。発電係数は水平面全天日射量からPV発電電力量に換算するための係数であるため、水平面全天日射量とPV発電電力量との相関を分析し、その近似式の傾きから求まる。分析の結果、水平面全天日射量とPV発電電力量は相関が非常に強く、季節を問わず相関係数Rは約1となった(Fig. 6上段)。また発電係数を月毎に比較すると、5～8月は0.171～0.173と小さく、逆に12～3月は0.185～0.187と大きくなる(Fig. 6下段)。これは気温の高低に伴う発電効率の変動が要因と考えられる。なお、本システムでは発電係数を月毎に分けて設定可能としている。

3.2.3 天気係数 天気係数を求めるため、気象庁の東京(大手町)における1年間の毎時計測データ(2012年)を用いて、計算日射量と計測日射量との相関の分析を行い、月毎、天気毎に分類した。但し、観測された天気は15種類であるのに対し、天気予報で使用する種類は4種類(晴, 曇, 雨, 雪)であるため、PV発電予測に天気予報を利用することを想定し、15種類を4種類に振り分けて集計・分析した。そのうち1月, 7月における晴, 曇の結果をFig. 7に示す。天気係数は近似式の傾きから求まり、晴の場合は両月とも0.87、曇の場合は0.44と0.47であった。両月共に晴の相関係数は0.9以上で相関が高いが、曇の場合は0.8とやや低下する。これは雲量の違いによるばらつきと考えられる。1月と7月では、晴, 曇共に7月の方がばらつきが大きい。これは、1月は安定した天気の日が多く、逆に7月は梅雨の時期で不安定な日が多く、雲量のばらつきが大きいと考えられる。なお、本システムは天気係数を月毎、天気毎の計48(=12×4)に分けて設定可能としている。

3.3 ロングレンジ予測モデル〈機械学習法〉

予測精度向上を目的とし、過去の天気実績情報やPV発電実績等のビッグデータを基に機械学習(異種混合学習

$$\begin{matrix} \text{雲一つない} \\ \text{快晴時における} \\ \text{水平面全天日射量} \\ \text{(日別・時刻別)} \end{matrix} \times \begin{matrix} \text{天気係数} \\ \text{(例) 晴} = 1.0 \\ \text{曇} = 0.5 \\ \text{雨} = 0.1 \text{等} \end{matrix} \times \begin{matrix} \text{発電係数} \end{matrix} = \begin{matrix} \text{時刻別} \\ \text{太陽光発電} \\ \text{発電電力量} \end{matrix}$$

※ 計算日射量・・・雲一つない快晴時における水平面全天日射量を下式より算出


$$\text{水平面全天日射量 [W/m}^2\text{]} J_h = J_{dn} \times \sin \delta + J_{sh}$$

$$\text{法線面直達日射量 [W/m}^2\text{]} J_{dn} = J_o \times P^{\cos \theta_z} \dots (\text{ブーゲの式})$$

$$\text{水平面天空日射量 [W/m}^2\text{]} J_{sh} = J_o \times \frac{\sin \delta}{2} \times \frac{1 - P^{\cos \theta_z}}{1 - 1.4 \times \log_e P} \dots (\text{ペルラーゲの式})$$

δ : 太陽高度[度] P : 大気透過率 J_o : 太陽定数[W/m²]

Fig. 5 天気・発電係数法
Long Range Prediction Method ①



水平面全天日射量と太陽光発電電力量の相関




Fig. 6 発電係数
Coefficient of Photovoltaic Power Generation

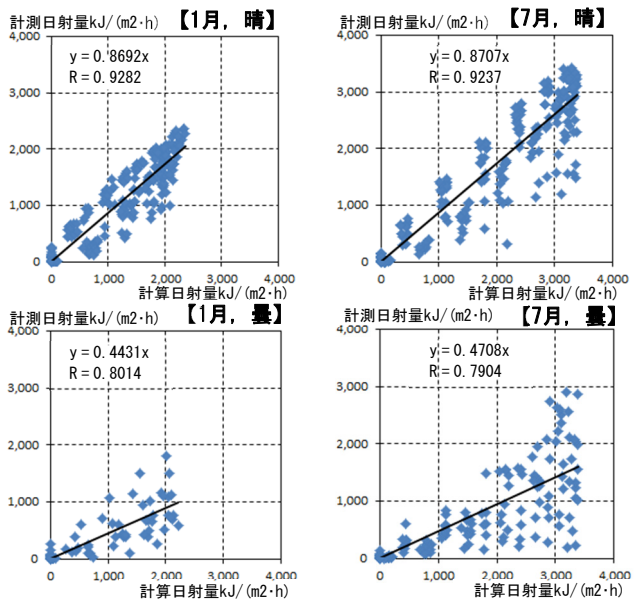


Fig. 7 計算と計測による水平面全天日射量の相関
Correlation of Horizontal Solar Radiation between Calculation and Measurement

2)により予測式を作成し、天気予報等を用いてPV発電電力量を予測する方法(以下「機械学習法」)について検討した。機械学習法の概要をFig. 8に示す。この方法は天気・発電係数法と比較し、天気予報や計算日射量等を基に予測する点は同じだが、予測式の作成方法、太陽光パネルの傾斜毎の計算日射量を説明変数としている点が異なる。

3.4 ショートレンジ予測モデル

前節のLR予測モデルは、天気予報が外れた場合や同じ曇りの予報でも雲量等の違いによりPV発電電力量を精度よく予測できないことが懸念される。そこでLR予測モデルによる直近30分先及び60分先の予測を、天気予報に依存せず現在の天気状況を反映する方法で補正することとした。直前のPV発電電力量実績値と計算日射量との比率である直近係数を算出し、これに30分先及び60分先の計算日射量を乗じて新たに直近30分先及び60分先のPV発電電力を予測する(Fig. 9参照)。即ち、直近係数が雲量等の現在の天気状況を加味し、これが直近30分先及び60分先まで継続されるであろうという考え方に基づいている。なお、本システムでは30分毎にPV発電電力を予測するため、60分先の予測値は30分後に再び補正され、最新の天気状況が反映されることとなる。このように予測された2つのPV発電電力の値を線形補間し、その30分間を6等分して5分毎のPV発電電力量に展開し、分散型電源の需給計画・制御に用いる。

4. 太陽光発電予測手法の検証

4.1 ロングレンジ予測モデル〈天気・発電係数法〉

本システム構築後約10ヶ月間のデータ(2015年5月～2016年2月、PV発電設備820kW)を用いて、LR予測モデルの天気・発電係数法によるPV発電予測の運用状況を分析した。一例としてFig. 10に10月16～19日のPV発電予測状況について示す。終日晴天あるいは雨天の場合は精度よく予測できているが、雨→曇り→晴れと天気に移り変わる時間帯は概ね予測できているものの、雲量の影響で約100～200kWの誤差が生じる。また、天気予報が外ればそのまま誤差も大きくなる。

次に、30分毎のPV発電電力量予測値と実績値の相関を分析した。そのうち6月、1月の結果をFig. 11上段に示す。予測が的中し斜め45度の線上に載ることが理想であるが、実際には予測誤差、天気予報精度の影響で季節を問わずばらつきが見られた。一方、Fig. 11下段に示す1日の積算発電電力量で見るとばらつきは小さく、10ヶ月間のデータでは相関係数0.85となり、相関が高い。このことから、週間予測において、PV発電電力量の日積算量としては概ねLR予測モデルの天気・発電係数法で予測可能であり、再生可能エネルギーを最大限活用するための蓄電池の充放電計画が十分可能と言える。

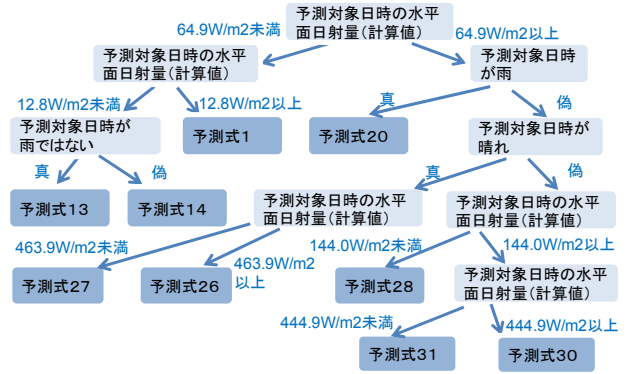
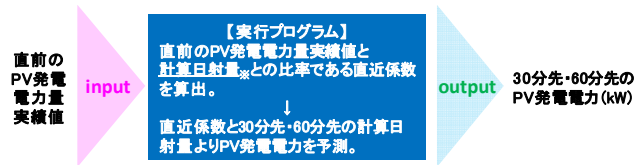


Fig. 8 機械学習法(予測式の選択条件例)
Long Range Prediction Method ②



※ 計算日射量・・・曇一つない快晴時における水平面全日射量をFig. 5の式より算出

Fig. 9 ショートレンジ予測モデル
Short Range Prediction Model




Fig. 10 太陽光発電予測の状況(LR予測モデル)
Trend of Prediction of Photovoltaic Power Generation
(Long Range Prediction Model)

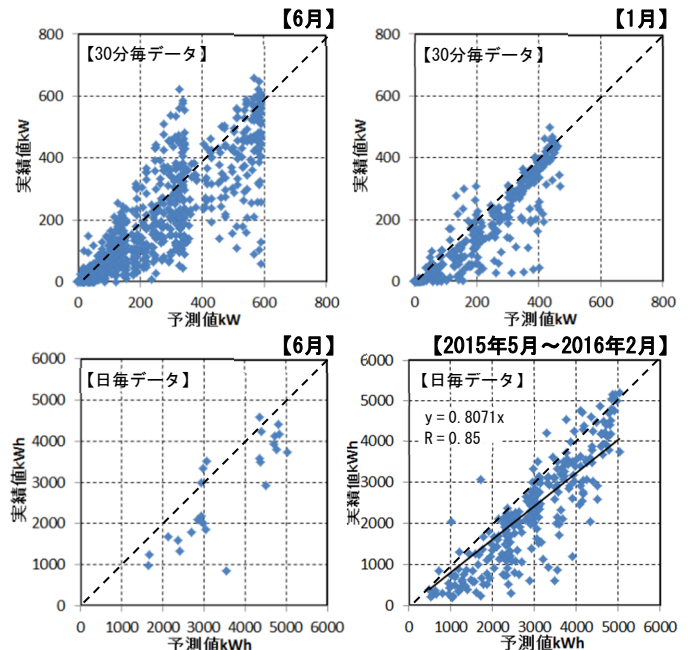


Fig. 11 天気・発電係数法による太陽光発電の
予測と実績の相関

Correlation of Photovoltaic Power Generation by Long Range Prediction Method ① between Prediction and Measurement

4.2 ロングレンジ予測モデル〈機械学習法〉

前節の天気・発電係数法と同様に、LR予測モデルの機械学習法によるPV発電予測の運用状況を分析した。機械学習法の予測状況はFig. 10に示すように、天気・発電係数法とほぼ同様のカーブを描くものの、実績値にやや近い値を示す。これは天気・発電係数法の予測式が水平面の計算日射量のみを利用しているのに対し、機械学習法は設置された太陽光パネルの傾斜毎の計算日射量を加味していることの影響と推測される。次に、4.1節と同様に30分毎及び1日積算のPV発電予測値と実績値の相関を分析したところ、Fig. 12に示すように天気・発電係数法とほぼ同様の傾向となった。但し、機械学習法の予測値がわずかに小さい傾向を示すため、散布全体の傾きが大きくなり、相関係数もわずかではあるが0.85から0.86に向上した。

Fig. 13に月毎の平均絶対誤差(MAE)及び誤差率を示す。なお誤差率は図中の式で定義した。MAEは各月とも天気・発電係数法に比べ機械学習法の方が1.7~23.4kW小さい値を示している。誤差率も機械学習法の方が5月を除き2.9~13.1ポイント減少している。

4.3 ショートレンジ予測モデル

3.4節のようにSR予測モデルは、LR予測モデルによる1週間先までのPV発電予測のうち、直近30分先及び60分先の予測を天気予報に依らず補正・代用する。Fig. 14に実運用時の予測状況の一例(2016年10月、11月)を示す。この時期は、LR予測モデルとして天気・発電係数法を用いて運用している。天気予報が的中し終日晴れの場合(10月26日)は、LR予測のみでも実績に近い予測ができていた。また、雲量の影響(同13日、18日)や天候が不安定(同8日)でLR予測が外れた場合でも、SR予測がうまく補正し、実績値に近い値を予測していることがわかる。また、このSR予測は、積雪がPVパネルによる発電を妨げる場合にも対応可能である(11月24~26日)。

次に1年間(2016年)のデータを用いて、30分毎のPV発電電力量予測値と実績値の相関を分析した。一例として、6月における30分毎のPV発電電力量予測値と実績値の相関をFig. 15上段に示す。予測が的中し斜め45度の線上に載ることが理想であるが、LR予測モデル(Fig. 15上段左参照)は予測誤差、天気予報精度の影響でばらつきが見られた。これに比べ、SR予測モデル(Fig. 15上段右参照)は近似線の傾きが1に近づき(0.89→0.99)、相関係数も向上(0.90→0.97)し、ばらつきが抑制された。また、天候が安定する1月(Fig. 15下段参照)はさらにSR予測の精度が向上する(傾き1.0、相関係数0.99)。

Fig. 16にLR及びSR予測モデルの月毎の平均絶対誤差(MAE)及び誤差率を示す。なお、誤差率は前節と同様に図中の式で定義した。MAEは各月ともLR予測モデルに比べSR予測モデルの方が23~53kW小さい値を示している(機械学習法と比較した場合)。誤差率も同様にSR予測モデルの方が小さい値を示し、11~31ポイント減少してい

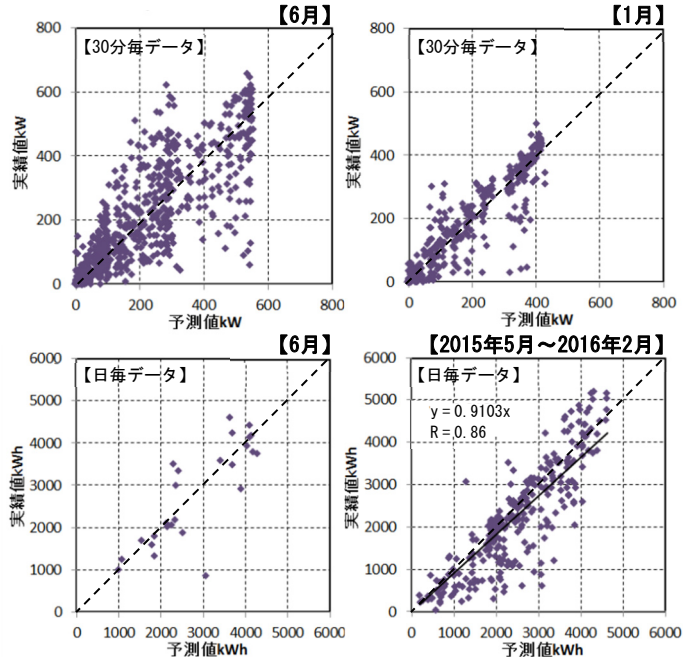


Fig. 12 機械学習法による太陽光発電の予測と実績の相関 Correlation of Photovoltaic Power Generation by Long Range Prediction Method ② between Prediction and Measurement

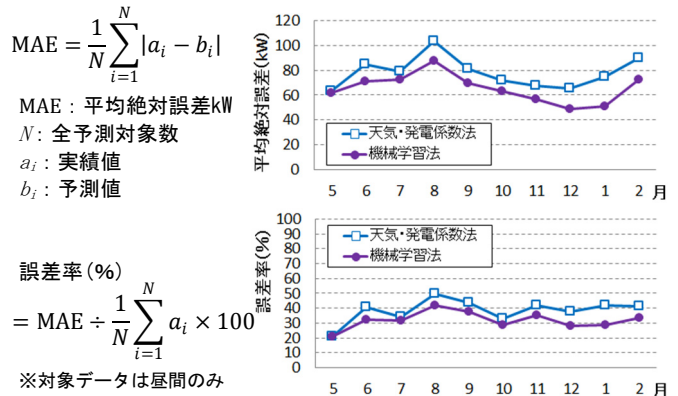


Fig. 13 各LR予測モデルの平均絶対誤差(MAE)と誤差率 MAE and Error Rate of Long Range Prediction Model

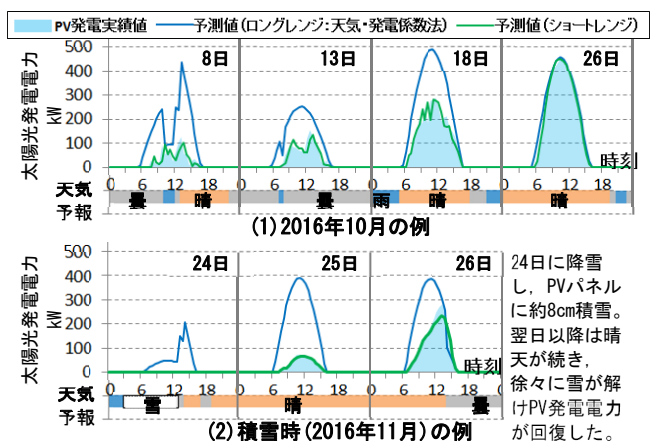


Fig. 14 太陽光発電予測の状況(SR予測モデル) Trend of Prediction of Photovoltaic Power Generation (Short Range Prediction Model)

る。Fig. 17に誤差(=予測値-実績値)のデュレーションカーブを示す。PV発電設備容量の10%に相当する±82kW以内の誤差の発生頻度は、LR予測モデルの場合は約7割(天気・発電係数法は66.5%、機械学習法は71.2%)であるのに対し、SR予測モデルを組み合わせることで約9割にまで向上した。一方、誤差(絶対値)の最大値は、0.1~1割程度の削減に留まった。これは、非常に激しい天気変動が年間に一度(7/14, 14~14時半)だけ発生したことにより、SR予測モデルの誤差(絶対値)の最大値が455.7kWとなったためである。これを除けば、SR予測モデルの二番目に大きい誤差(絶対値)は363.1kWであり、LR予測モデルに比べ誤差(絶対値)の最大値は2~3割減少しており、設備容量の半分以下までに抑えることが可能となった。このように天気変動により予測が左右されることは皆無にならないため、これらを考慮したスマートエネルギーシステム的设计、制御が必要となる。

5. まとめ

本報では、大林組技術研究所構内に構築したスマートエネルギーシステムの分散型電源の需給計画・制御において、その重要な役割の一端を担う太陽光発電予測について報告した。採用した複数の太陽光発電予測手法による予測と実績を検証し、以下の結論を得た。

- 1) ロングレンジ予測モデルにおいて未来の30分毎のPV発電電力量の予測精度は天気予報的中率に左右されるものの、日積算量の予測精度は概ね良好で、週間の需給計画に利用可能である。
- 2) ロングレンジ予測モデルと直前の実績値を基に補正するショートレンジ予測モデルを組み合わせることで、誤差をPV発電設備容量の10%の範囲内に抑える予測が、年間の約9割の期間で可能である。

このように、スマートエネルギーシステムにおいて実用的な精度で太陽光発電予測ができることを実運用の中で確認し、その有効性を示した。このたび開発した太陽光発電予測手法を用いることで今後、太陽光発電設備を利用するスマートシティやZEB(ネット・ゼロ・エネルギー・ビル)の普及の一助としたい。

謝辞

異種混合学習について、日本電気株式会社殿のご協力に謝意を表す。

参考文献

- 1) 小島義包, 他: 技術研究所におけるスマートエネルギーシステム, 大林組技術研究所報, No. 80, 2016.12
- 2) 藤巻遼平, 他: ビッグデータ時代の最先端データマイニング, NEC技報, Vol. 65, No. 2, pp. 81-85, 2012.9

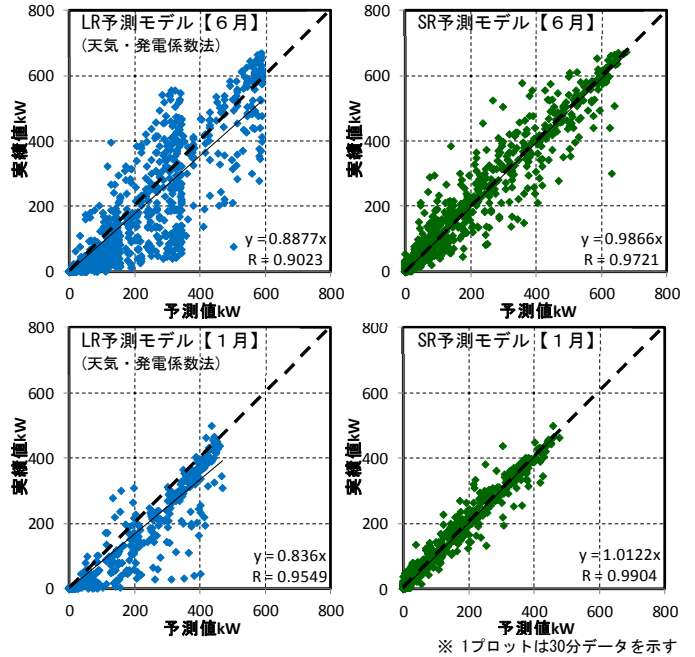


Fig. 15 SR予測モデルによる太陽光発電の予測と実績の相関 Correlation of Photovoltaic Power Generation by Short Range Prediction Model between Prediction and Measurement




Fig. 16 LR及びSR予測モデルの平均絶対誤差(MAE)と誤差率 MAE and Error Rate of Long Range and Short Range Prediction Model




Fig. 17 誤差(=予測値-実績値)のデュレーションカーブ Duration Curve of Error