

気象データを利用する太陽光発電量予測手法の実証実験

Demonstration Experiment of Photovoltaic Power Generation Prediction Method using Weather Data

堀 崎 峻

要 約 日本ユニシスでは、2014年度から太陽光発電量予測手法の開発を進めている。当該の手法は、日射量の予測と、予測した日射量の発電量への変換という二つの段階を踏む間接予測方式を採用している。さらに、日射量の予測については、数時間先の予測に強いとされる衛星データを利用した手法と、それよりも長い時間の予測に強いとされる気象データを利用した手法の二つを開発している。

気象データを利用した日射量予測手法と、予測した日射量から発電量を予測する手法の二つについて、コストを抑えながら正確に予測するモデルを明らかにするために、2016年度に実証実験を行った。その結果、前者には学習期間が2年で気象データ数を制限しないモデルが、後者には特定の組み合わせのデータの学習と発電量予測を1ヶ月ずつ繰り返すモデルが該当した。

Abstract We have been developing photovoltaic power generation prediction method since 2014. This method in question adopts the method which is to forecast the budget of power generation indirectly. In solar irradiance prediction, we have two different methods, first one is the method based on satellite image and second one is the method based on weather data. First one is suitable for prediction for several hours after. Second one is suitable for longer time prediction compared to first one.

We conducted a demonstration experiment in FY2016 on solar radiation forecasting method using meteorological data and on production of electricity forecasting method based on forecasted solar radiation to clarify the model that predicts accurately while keeping costs low. As a result, the former corresponds to a model in which the learning period is two years and the number of weather data is not limited, the latter corresponds to a model in which learning of specific combination data and generation forecast of power generation are repeated one month at a time.

1. はじめに

太陽光発電は、天候によって発電量が左右されるため、需給運用が複雑である。たとえば、系統電力では、同時同量の原則を満たすために、太陽光発電の出力を抑制したり、逆に代替電力で補うといった対策が必要となる。太陽光発電を大量導入する場合の対策として、需給運用のコスト低減と、電力供給の安定化を図るために、太陽光発電の発電量予測が試行されている^[1]。

日本ユニシス株式会社（以降、日本ユニシス）は、2014年度から太陽光発電量予測手法の開発を進めている。2014年度に衛星データを利用した日射量推定手法^{[1]*1}を開発し、2015年度には、衛星データを利用した日射量予測手法*2、気象データを利用した日射量予測手法と、それらを使って得た日射量から発電量を予測する手法の三つを開発した。そして、2016年度は、その実証実験を実施した。本稿にはそのうち二つの実験結果を記載する。2章で太陽光発電量

予測手法の概要、3章で気象データを利用した日射量予測手法の実証実験について、4章で日射量から発電量を予測する手法の実証実験について述べ、5章で結論と今後の課題を述べる。

2. 太陽光発電量の予測手法

太陽光発電量の予測には二つの手法が知られている。一つは、気象情報等の測定データから、直接、発電量を予測する直接予測であり、もう一つは、気象情報等の測定データから日射量を予測し、その日射量から発電量を予測する間接予測である^[2]。直接予測は、モデルはシンプルだが別設備への応用が困難なのに対し、間接予測は、モデルは複雑だが別設備への応用が容易である^[3]。太陽光発電の需給運用では複数の設備を管理するので、日本ユニシスは間接予測を採用した。

日本ユニシスの太陽光発電量の（間接）予測手法は、二つの日射量予測手法を用いる。数時間先予測に強いとされる衛星データ^[4]を利用した手法（以下、衛星予測モデル）と、それよりも長い時間の予測に強いとされる気象データ^[4]を利用した手法（以下、気象統計モデル）である。図1に日本ユニシスの太陽光発電量予測手法の概要図を記載する。

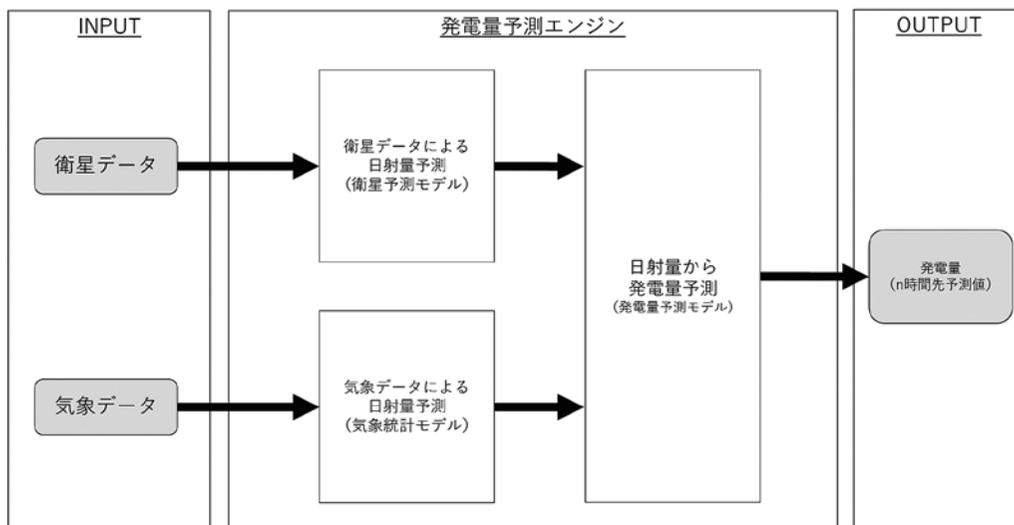


図1 日本ユニシスの太陽光発電量予測手法の概要図

2016年度の実証実験では、衛星予測モデル、気象統計モデル、発電量予測モデルについて、実証実験を実施した。本稿では、データ入手コストと予測精度の相関関係の有無を明らかにするため、データ入手コストが一定の衛星予測モデルを除き、気象統計モデルと発電量予測モデルについての実証実験の内容と実験結果を記載する。

3. 気象統計モデルの実証実験

太陽光発電量予測のサービス化には、イニシャルコストやランニングコストを見積もる必要があるため、満足できる予測精度を実現するのに最低限必要なデータ量および種類を明らかにすることを本実証実験の目的の一つとした。具体的には、気象統計モデルの学習期間が長いほど、学習用データの購入費用が増えるため、実環境において学習に必要となる期間の長さを調

べる実験を実施した (3.2 節). さらに, 気象統計モデルが利用する気象データの種類が多いほど, 学習用データと予測用データの購入費用が増えるため, 利用する気象データの組み合わせを変える実験を実施した (3.4 節).

また, 2015 年度は利用することができなかった実際の太陽光発電設備で測定されたデータを利用して, 2015 年度に開発した気象統計モデルを実環境に適したモデルへと改良することも目的の一つとした. このため, 季節の影響の有無 (3.3 節), 気象データの組み合わせ (3.4 節, 上記の一つ目の目的としても実施) の二つについて, 実験を実施した.

本章の各節において, これらの実験内容の詳細と実験結果, 改良後のモデルの予測性能について記載する.

3.1 気象統計モデルの概要

2015 年度に開発した気象統計モデルは, 気象データを説明変数^{*3}, 日射量を目的変数^{*4}として重回帰分析^{*5}を行い, 日射量を予測するモデルである. 具体的には, 気象データをある条件にしたがって分類した後, それぞれの分類について重回帰分析を行い, 複数のモデルを得る. 予測においては, 気象データを分類したのと同じ条件にしたがって, 気象データの予報値を分類し, それぞれの分類に対応するモデルに予報値を入力することで, 日射量の予測値を得る仕組みとなっている.

3.2 気象統計モデルの学習に必要となる期間の長さの実験

学習期間の長さを変えてモデルの学習を行い, 得られたモデルの予測性能を評価することで, 気象統計モデルの学習に必要となる最短期間を調査する実験を行った. 実験は表 1 に示す三つのパターンで実施した. 番号 1-2 と番号 1-3 は, 学習を行う期間の長さを同じにして, 学習を行う時期を変えている. これは, 同じ学習期間の長さでも, 時期によって予測性能にどの程度の差が出るのかを確認するためである.

実験結果を表 2 に示す. 表 2 では, 39 時間先まで^{*6}の予測値すべてをまとめて RMSE^{*7}を計算した結果を記載している. 結果を見ると, 晴れ, 晴れ以外を合計した全体の RMSE はどのパターンでも同じ結果となった. また, 晴れと晴れ以外とで分けて RMSE を見てみると, パターンごとに違いが見られるが, 学習期間が 12 か月分か 24 か月分かよりは, 学習した時期による違いのほうが, 予測性能に与える影響が大きいことが, 番号 1-2 と番号 1-3 の比較から見て取れる. 以上の結果から, 気象統計モデルの学習に必要となる期間の長さは, 1 年分あればまずは十分と考えられる.

表 1 学習期間の長さの実験パターン

番号	学習期間		予測期間	
	月数	期間	月数	期間
1-1	24	2013/12 - 2015/11	8	2015/12 - 2016/07
1-2	12	2013/12 - 2014/11	20	2014/12 - 2016/07
1-3	12	2014/12 - 2015/11	20 (12 + 8)	2013/12 - 2014/11 ^{*8} 2015/12 - 2016/07

表2 39時間先までの予測値のRMSE

番号	RMSE		
	晴れ	晴れ以外	全体
1-1	115	145	128
1-2	116	144	128
1-3	112	150	128

3.3 季節ごとの気象統計モデルの学習による性能差の実験

季節ごとに学習と予測を行うことで、通年で学習を行った場合と比べてモデルの予測性能にどの程度の差が生じるのかについて実験した。季節は、1-3月、4-6月、7-9月の3パターンとした(表3)。10月-12月は、データの計測期間の関係で実験対象から外した。番号2-3では、データ量の関係で一か月分のみとなっている。

実験結果を表4に示す。表4では、39時間先までの予測値すべてをまとめてRMSEを計算した結果を記載している。また、比較用として、通年で学習を行った場合のモデル(表1の番号1-1)の同じ予測期間のRMSEを併記する。

表4を見ると、晴れ以外の場合のRMSEについては、通年で学習したほうが、季節ごとに学習するより、予想性能がよい場合があったが、全体としては、予測性能に大きな違いは見られなかった。また、全体の傾向として、天候が安定している1-3月に比べて、4-6月や7月など天候が晴れ以外になりやすい時期では予測性能が悪化することが見て取れる。

表3 季節による影響の実験パターン

番号	学習期間		予測期間	
	月数	期間	月数	期間
2-1	6	2014/01 - 2014/03 2015/01 - 2015/03	3	2016/01 - 2016/03
2-2	6	2014/04 - 2014/06 2015/04 - 2015/06	3	2016/04 - 2016/06
2-3	6	2014/07 - 2014/09 2015/07 - 2015/09	1	2016/07 ※データ量の関係で 一か月分のみ

表4 季節ごとに学習した場合の39時間先までの予測値のRMSE

番号	各番号のRMSE			番号1-1の同一予測期間のRMSE		
	晴れ	晴れ以外	全体	晴れ	晴れ以外	全体
2-1	96	152	114	95	149	112
2-2	128	149	137	132	141	136
2-3	124	143	135	123	149	138

3.4 気象統計モデルの説明変数の実験

気象データの組み合わせを変えて^{*9}気象統計モデルの学習を行い、その結果を評価すること

で、実環境において最適な説明変数（気象データ）を調査する実験を行った。実験したパターンを表5に示す。なお、番号3-3は、表1の番号1-1と同一条件（気象データの組み合わせ変更なし）である。

実験結果を表6に示す。表6では、39時間先までの予測値すべてをまとめてRMSEを計算した結果を記載している。実験結果を見ると、番号3-1は晴れの場合の性能は良いが、晴れ以外の場合の性能が悪く、全体として最も悪い結果となった。反対にもっとも性能がよかったのは、番号3-3であった。また、番号3-2は番号3-3よりも、説明変数を減らしたモデルであり、性能の低下が予見されていたが、性能の低下の程度は少なく、コストを減らしたい場合には、十分に選択肢に含まれるモデルであることが分かった。

表5 説明変数の実験パターン

番号	学習期間		予測期間		補足
	月数	期間	月数	期間	
3-1	24	2013/12 - 2015/11	8	2015/12 - 2016/07	一部の気象データの分類方法を変えて説明変数としたもの
3-2					番号3-3よりも説明変数を減らしたもの
3-3 (1-1)					番号1-1と同じ条件

表6 説明変数を変えた場合の39時間先までの予測値のRMSE

番号	RMSE		
	晴れ	晴れ以外	全体
3-1	115	151	131
3-2	117	146	130
3-3 (1-1)	115	145	128

3.5 まとめ

本章の実験を通じて、最も性能が良かったモデル（学習期間24ヶ月、気象データ制限なし、3.4節表5の番号3-3のモデル）を利用して、2015年12月から2016年07月の日射量予測を行い、評価した結果を図2に示す。晴れの場合、3時間先程度までRMSEは100前後、晴れ以外の場合は、7時間先までRMSEが130前後となった。

また、イニシャルコスト、ランニングコストの見積もりに必要となる情報については、学習期間は1年分あればまずは十分であること、説明変数（気象データ）は、最良の予測性能となったのは3.4節表5の番号3-3（データ数制限なし）であったが、説明変数を減らした番号3-2でも大きな性能の低下はないため、コストを減らしたい場合には選択肢となり得ることが分かった。

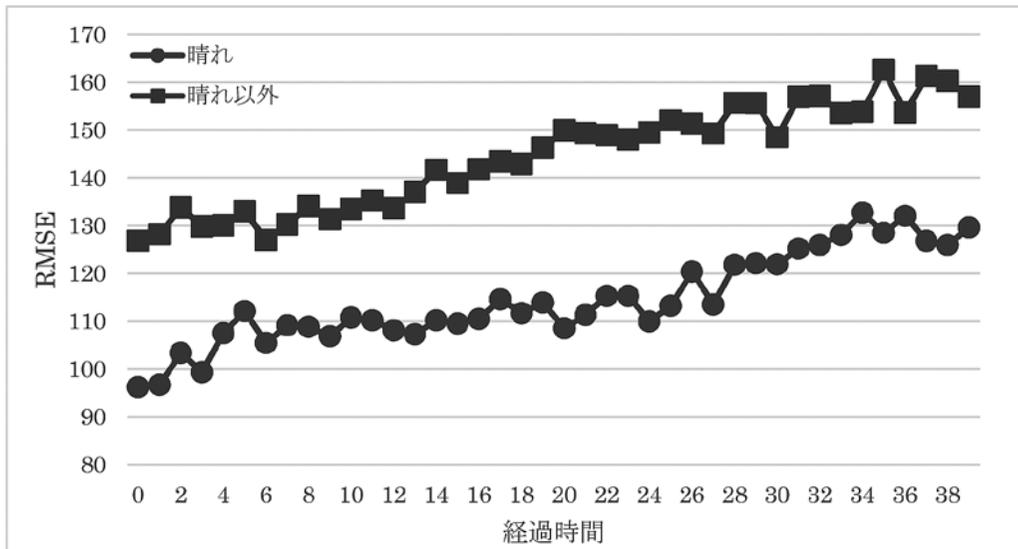


図2 日射量予測結果 (N 時間先の日射量予測の RMSE)

4. 発電量予測モデルの実証実験

太陽光発電量予測のサービス化には、サービス導入から開始までの期間を見積もる必要があるため、その期間の算定を実証実験の目的の一つとした。具体的には、日射量と発電量について、太陽光発電設備での実測値の蓄積が必要となるため、その実測期間を調べる実験を実施した^{*10}(4.2節)。

また、実際の太陽光発電設備で測定されたデータを利用して、2015年度の発電量予測モデルを改良することも目的の一つとした。そのため、時期の影響の有無(4.3節)、利用する日射量その他データの組み合わせ(4.4節)の二つについて、実験を実施した。

本章の各節において、これらの実験内容の詳細と実験結果、改良後のモデルの予測性能について記載する。

4.1 発電量予測モデルの概要

2015年度に開発した発電量予測モデルは、日射量その他を説明変数、発電量を目的変数として重回帰分析を行い、発電量を予測するモデルである。日射量は、気象統計モデルにより得られた予測値を利用する。

4.2 発電量予測モデルの学習に必要となる期間の長さの実験

3.2節の気象統計モデルの実験と同様に、発電量予測モデルについても、学習期間の長さを変えてモデルの学習を行い、得られたモデルの予測性能を評価することで、発電量予測モデルの学習に必要となる最短期間を調査する実験を行った。実験は表7に示す三つのパターンで実施した。また、発電量の予測には、各々の基準時刻から39時間先までの気象統計モデルによる日射量予測値を利用した。

実験結果として、39時間先までの予測値すべてをまとめてRMSEを計算した結果を表8に記載している。RMSEの算出では、発電設備の最大発電可能量による予測値の正規化を行っ

ている。結果を見ると、どの学習期間でも、予測性能にほぼ差がないことが分かった。したがって、発電量予測モデルの学習に必要な期間は半月分あれば十分と考えられる。

表7 学習期間の長さの実験パターン

番号	学習期間		予測期間	
	月数	期間	月数	期間
4-1	3	2015/09 - 2015/11	8	2015/12 - 2016/07
4-2	1	2015/11		
4-3	0.5	2015/11 の 2 週間		

表8 39時間先までの予測値のRMSE

番号	RMSE (予測値正規化済)
4-1	0.106
4-2	0.107
4-3	0.107

4.3 時期ごとの発電量予測モデルの学習による性能差の実験

予測対象期間を1ヶ月単位で分割し、その直近の数ヶ月のデータを利用してモデルの学習を行い、その学習を基に予測を行うことを、1ヶ月単位で順次繰り返していく場合(図3)と、単純に、任意の期間のデータを利用してモデルの学習を行い、予測対象期間を予測する場合を比べて、モデルの予測性能にどの程度の差が生じるのかについて実験した。

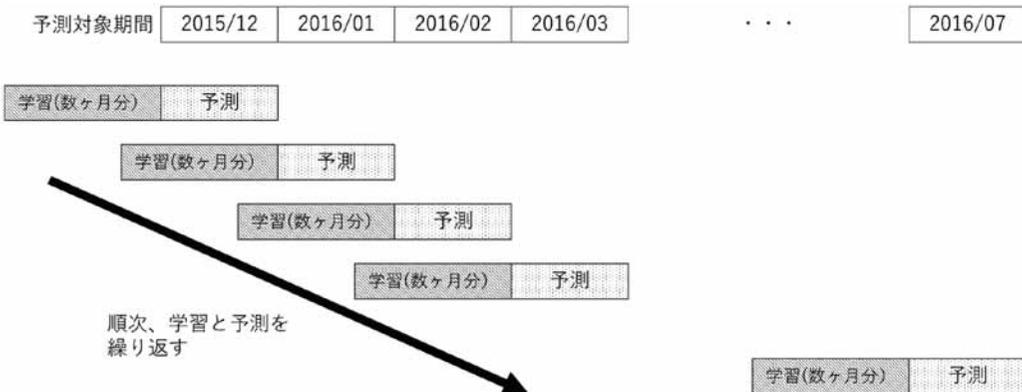


図3 学習と予測を繰り返す場合の概略図

実験のパターンを表9に示す。また、発電量の予測には、各々の基準時刻から39時間先までの気象統計モデルによる日射量予測値を利用した。

実験結果を表10に示す。月毎に学習と予測を繰り返していく方法であるため、RMSEも月毎に計算している。また、任意の期間のデータを利用してモデルの学習を行い、予測対象期間を予測するモデルとして、学習期間が3ヶ月の番号4-1(4.2節表7)と、学習期間が1ヶ月

の番号 4-2 (同) の月毎の RMSE を併記する。この他、4.2 節と同様に本実験でも、39 時間先までの予測値すべてをまとめて RMSE を計算した結果を記載している。これらの RMSE は発電設備の最大発電可能量による予測値の正規化を行っている。結果を見ると、わずかな違いではあるが、1 ヶ月ごとに学習を行う番号 5-2 が最も良い結果となる月が多いことが分かった。

表 9 時期ごとのモデル学習の実験パターン

番号	学習期間		予測期間	
	月数	期間	月数	期間
5-1	3	予測期間直前の 3 ヶ月	8	2015/12 - 2016/07 ※ 1 ヶ月ずつ実施
5-2	1	予測期間直前の 1 ヶ月	8	2015/12 - 2016/07 ※ 1 ヶ月ずつ実施

表 10 時期ごとに学習した場合の 39 時間先までの予測値の RMSE

番号	月ごとの RMSE (予測値正規化済)							
	201512	201601	201602	201603	201604	201605	201606	201607
5-1	0.085	0.072	0.106	0.113	0.106	0.103	0.124	0.110
5-2	0.085	0.071	0.105	0.113	0.106	0.101	0.122	0.110
4-1	0.085	0.073	0.107	0.114	0.104	0.101	0.125	0.110
4-2	0.085	0.071	0.106	0.113	0.106	0.104	0.127	0.111

4.4 発電量予測モデルの説明変数の実験

日射量その他の組み合わせを変えて^{*11} 発電量予測モデルの学習を行い、その結果を評価することで、実環境において最適な説明変数（日射量その他）を調査する実験を行った。実験したパターンを表 11 に示す。番号 6-2 は、前節表 9 の番号 5-2 と同一条件（説明変数の組み合わせ変更なし）である。発電量の予測には、各々の基準時刻から 39 時間先までの気象統計モデルによる日射量予測値を利用した。

実験結果を表 12 に示す。4.2 節、4.3 節と同様に、本実験でも、39 時間先までの予測値すべてをまとめて RMSE を計算した結果を記載している。RMSE は発電設備の最大発電可能量による予測値の正規化を行っている。結果を見ると、全体として、番号 6-1（説明変数の組み合わせ変更あり）の結果のほうが、性能が良くなる月が多いという結果となった。ただし、その差はわずかであった。

表 11 説明変数の実験パターン

番号	学習期間		予測期間		補足
	月数	期間	月数	期間	
6-1	1	予測期間直前の 1 ヶ月	8	2015/12 - 2016/07 ※ 1 ヶ月ずつ実施	番号 5-2 と同じ条件
6-2 (5-2)					

表 12 説明変数を変えた場合の 39 時間先までの予測値の RMSE

番号	月ごとの RMSE (予測値正規化済)							
	201512	201601	201602	201603	201604	201605	201606	201607
6-1	0.085	0.073	0.104	0.112	0.102	0.101	0.121	0.110
6-2 (5-2)	0.085	0.071	0.105	0.113	0.106	0.101	0.122	0.110

4.5 まとめ

4.2 節の結果より、サービスの導入から開始までに必要な学習期間は、半月でよいことが分かった。また、期間の工夫による発電量予測モデルの改良を目的とした 4.3 節では、予測対象期間を 1 ヶ月単位で分割し、その直近の 1 ヶ月のデータを利用してモデルの学習を行い、予測を 1 ヶ月単位で順次繰り返していく方法が、最良の RMSE となった。さらに、説明変数の組み合わせによる発電量予測モデルの改良を目的とした 4.4 節では、4.3 節の中で最良となった学習方法を採用し、表 11 の番号 6-1 で利用した説明変数の組み合わせの場合に RMSE が最も良くなる結果が得られた。このモデルでは、1 月など天気安定している時期は、RMSE が 0.073 程度、6 月の梅雨の時期など予測がしにくい時期は RMSE が 0.121 程度という結果となった。

5. 結論および留意点と今後の改善点

本稿では、気象統計モデルについて、実環境で測定されたデータを用いて、モデルの改良と、サービス化におけるインシャルコスト、ランニングコストの見積もりに必要となる情報の取得を行った。結果として、実証実験を通して、晴れの場合、3 時間先程度まで RMSE は 100 前後、晴れ以外の場合は、7 時間先まで RMSE が 130 前後となるモデル（学習期間 = 2 年で気象データ数を制限しない、3.4 節表 5 の番号 3-3 のモデル）を得ることができた。また、インシャルコスト、ランニングコストを抑えるモデル（学習期間 = 2 年で気象データ数を減らした、3.4 節表 5 の番号 3-2 のモデル）も特定することができた。

発電量予測モデルでも、同様に、実環境で測定されたデータを用いて、複数のモデルを比較し、その中で RMSE が最も良くなるモデル（日射量その他の組み合わせを変えた^{*11} 発電量予測期間直前の 1 ヶ月のデータを用いて学習し、1 ヶ月分の予測をひと月ずつ繰り返していくモデル、4.4 節表 11 の番号 6-1）を特定したほか、サービス導入から開始までの期間は半月で十分であることが分かった。

留意点として、気象統計モデルの地域に対する汎用性については未評価であることが挙げられる。これは今後の課題として、検証を行う必要がある。

今後の改善点として、発電量予測モデルは、実際の測定データに基いて予測を行うため、発電設備の異常検知といった用途には不向きであることが挙げられる。異常検知にも適用できるように、今後、発電量予測モデルの更なる改良が必要である。また、たとえば太陽光発電設備の価値を算出するシステムを考えた場合、現在の日本ユニシスの太陽光発電量予測手法には、月単位や年単位での発電量を予測するモデルがないため、新たなモデルの追加も必要になる。

6. おわりに

本稿を執筆するにあたりアドバイスを下さった方々、実証実験にご協力いただきました企業

様、団体様、ならびに、衛星予測モデル、気象統計モデル、発電量予測モデル、それぞれを担当していただいたプロジェクトメンバ、その他、本プロジェクトに協力していただいた多くの方々に感謝の意を表する。

-
- * 1 衛星データを利用した日射量推定手法：衛星画像から任意の地点の日射量を得る手法。
 - * 2 衛星データを利用した日射量予測手法：過去と現在の衛星画像から雲の移動方向を判断して未来の衛星画像を求め、求めた衛星画像に*1の日射量推定手法を適用することで、未来の日射量を得る手法。
 - * 3 説明変数：目的変数を説明するための変数のこと。気象統計モデルでは、気象データ、発電量予測モデルでは日射量その他が説明変数となる。
 - * 4 目的変数：注目している変数のこと。気象統計モデルでは、日射量が目的変数となる。発電量予測モデルでは、発電量が目的変数となる。
 - * 5 重回帰分析：説明変数と目的変数の関係を表す式を統計的手法によって推定する手法のこと。気象統計モデルでは、気象データと日射量の関係を表す式を推定する。発電量予測モデルでは、日射量その他と発電量の関係を表す式を推定する。
 - * 6 実験に利用した気象データの予報値が39時間先までのため。なお、予報値は1時間間隔である。
 - * 7 RMSE (Root Mean Squared Error)：予測値が実測値からどのくらい外れるかの誤差の程度を表し、値が小さいほど、誤差が少ないことを示す。
 - * 8 重回帰分析は、説明変数と目的変数の関係のみに注目するため、学習期間と予測期間が時間的に前後していても問題はない。
 - * 9 気象データの組み合わせ変更のパターンは、諸般の事情により本稿では伏せている。
 - * 10 気象統計モデルでも学習において日射量の実測値が必要となるが、気象統計モデルの場合は、別の地点で作成したモデルを流用できる可能性があるため、必ずしもサービス提供までのタイムラグにならない。
 - * 11 日射量その他のデータの組み合わせ変更のパターンは、諸般の事情により本稿では伏せている。

- 参考文献**
- [1] 斉藤 功樹, 衛星画像データを利用した日射量推定モデル, ユニシス技報, 日本ユニシス, vol.36 No.2 通巻 129号, 2016年9月, P39 ~ 50
 - [2] 石橋 直人, 飯坂 達也, 勝野 徹, 太陽光発電の発電量予測技術, 富士電機技報, 富士電機, 第86巻第3号, 2013年9月, P51 ~ 54
 - [3] 荻本 和彦, E-0903 再生可能エネルギーの大規模導入を可能とする自律協調エネルギーマネジメントシステム, 環境省地球環境研究総合推進費 H22 年度終了予定研究課題成果発表会, 環境省, 2011年3月, P.10
https://www.env.go.jp/policy/kenkyu/special/houkoku/data_h22/E-0903.html (URL参照確認日: 2017年10月24日)
 - [4] 大関 崇, 太陽光発電の発電予測技術概要, 東京大学 CEE ワークショップ, 産業技術総合研究所, 2014

執筆者紹介 堀 崎 峻 (Shun Horizaki)

2011年日本ユニシス(株)入社。サービスインダストリー事業部にて、通信事業者向けの基幹システム開発に従事。2016年より、公共システム本部にて新たな事業に向けたPoCやビジネス実証実験を担当している。

