

衛星画像データを利用した日射量推定モデル

A Satellite-based Estimation Model of Solar Irradiance

齊藤 功 樹

要 約 太陽光発電量の予測方式は二つあり、そのうちの一つである間接予測では実況の日射量の把握を目的とした日射量推定、日射量予測、日射量から発電量への変換の三段階を経て、太陽光発電量を予測する。間接予測の入力データとしては数値予報モデル、衛星画像データ、天空画像の三つが用いられ、衛星画像データを用いた手法では、数時間先の発電量を精度高く予測できることが分かっている。衛星画像データを利用した従来の日射量推定手法は、快晴や雲種等の各条件を定義し、各条件における大気外日射量から地上日射量への低減率を補正係数として用い、日射量を推定するものであるが、曇天時の雲種で補正係数の不確かさが大きいことが分かっている。

本稿では、補正係数算出のためのサンプル数を増加させ、雲種を判別する式に対して変数を追加し、機械学習を行うことで従来の日射量推定手法を改良した。気象庁の日射量観測値を用いて手法を評価した結果、提案した日射量推定手法は従来の日射量推定手法より高い推定精度を示した。太陽光発電量予測において、予測開始時の観測値を取り込むことで、予測精度の改善が期待できるといわれている。観測値が不足する場合において、提案した日射量推定手法を用いて算出された推定日射量を観測値の代わりに利用することで、太陽光発電量予測の更なる精度向上が期待できる。

Abstract There are two methods to forecast the electricity generated by the photovoltaic generation. One of them is to forecast the budget of power generation indirectly through three stages, the first stage is to estimate the amount of solar radiation for the purpose of understanding live solar radiation; the second stage is to forecast the amount of solar radiation; the third stage is to convert the amount of solar radiation into photovoltaic generation. Three types of data such as numerical forecast model, satellite image and sky image are used as input data of this method. It is known that the method based on satellite image can precisely forecast the production of electricity by photovoltaic generation in several-hours-ahead accuracy. In conventional model they define an expression of clear sky and cloud type classification and estimate the amount of solar radiation to attenuate solar radiation outside the Earth's atmosphere by using the correction coefficient. It is known that the conventional model has a large uncertainty of the correction coefficient in the cloudy weather.

In this paper, we improved the conventional model by increasing the number of samples, adding a variable for expressions to determine a cloud type classification, applying the machine learning. Validation of this model was conducted with Japan Meteorological Agency's actual measurement value. The results indicate that this model can estimate the amount of solar radiation with high accuracy as compared to the conventional model. It is generally agreed today that improvement can be expected in prediction accuracy by fetching the actual measurement value at prediction start time in forecasting the production of electricity by photovoltaic generation. When the actual measurement value is insufficient, improvement in accuracy of forecasting the electricity generated by photovoltaic generation can be expected by utilizing the estimated amount of solar radiation calculated by our proposed method.

1. はじめに

持続可能性の観点から化石燃料に代わるエネルギーとして再生可能エネルギーに対する期待は高い。2011年の東日本大震災における事故を契機に原子力発電所が段階的に停止され、代替する電力供給として化石燃料を用いた火力発電への依存度が上がっている日本では、特にそうである。

再生可能エネルギーの筆頭である太陽光発電は、天候に依存して発電量が大きく変動するため、需給バランスの調整が困難であるという課題がある。系統電力では周波数を安定させるために、需要と供給が常に一致していなければならないという同時同量の原則があるため、太陽光発電による電力供給が不安定になる場合、太陽光発電の出力抑制や蓄電池の併設、代替電力による出力調整等の対策が必要となり、調整コストがかかる。太陽光発電が大量に導入された場合の対策として、電力需給の調整コストを抑え、電力需給の安定化を図るために、気象観測情報や気象モデルに基づく太陽光発電量予測の導入が検討されている^[1]。

太陽光発電における発電量の予測方式は二つある。気象情報等からの直接予測と、日射量^{*1}推定・予測データを利用して発電量に変換する間接予測である。間接予測は、汎用的に予測できる方式として主流となっており^[2]、本稿では間接予測を対象とする。両方式共に入力データは主に数値予報モデル^{*2}、衛星画像データ、天空画像の三つが用いられる。入力データごとに発電量を精度高く予測できる時間スケールが異なり、数日先から週間予測では数値予報データを用いた手法が、数時間先予測では衛星画像データを用いた手法が、短時間先予測では天空画像を用いた手法が、発電量予測の精度が高いことが分かっている^[3]。

本稿では、当日の数時間先予測に着目して、太陽光発電量予測技術開発のための第一段階として、気象庁の静止衛星であるひまわり7号の衛星画像データを利用した従来の日射量推定手法の改良を行った。従来の日射量推定手法および改良した日射量推定手法を用いて算出した日射量の推定値と観測値を比較することで、改良した日射量推定手法の有効性を評価する。

まず、2章で従来の日射量推定手法の概要と課題について述べる。3章では2章で述べた課題解決のために行った改良手法について説明し、4章で改良手法の評価について、5章で今後の取り組みについて述べる。

2. 従来の日射量推定手法の課題

本章では、衛星画像データを利用した日射量推定について述べ、参考とした従来の日射量推定手法の概要と課題について述べる。

2.1 日射量推定について

間接予測では、実況の日射量の把握を目的とした日射量推定、数時間先の日射量予測、日射量から発電量への変換の三段階を経て、太陽光発電量を予測する。太陽光発電量予測において、予測開始時の観測値を取り込むことで、予測精度の改善が期待できるといわれている。衛星画像データを利用することで、日本全域の任意の地点での日射量推定ができれば、観測値の不足を補い、発電量予測の精度向上が期待できる。

衛星画像データの可視画像と赤外画像を利用した日射量推定は古くから行われている。日射量推定手法として大気の散乱・吸収を考慮した物理モデルがあるが、エアロゾル^{*3}やオゾン分布等の大気の状態を観測する困難さから推定結果には不確かさが含まれる。Dedieu^[4]は日射量

推定においては大気の影響より雲の影響の方が大きいことを指摘し、可視画像データより日射量を推定するシンプルな推定手法を提案した。本稿では、Dedieuの手法を参考とし、衛星画像データを用いて雲を判別して雲による影響を考慮した日射量推定手法に対して改良を行った。

2.2 従来の日射量推定手法の概要

衛星画像データを利用した日射量推定手法^[5](以下「従来手法」)では、ひまわり7号の赤外画像(IR1, IR2)^{*4}から快晴や雲種等の各条件を定義し、各条件における大気外日射量と可視画像(VIS)から地上日射量への低減率を補正係数として用い、日射量を推定する。

従来手法の雲種条件(以下「雲種類判別式」)を図1に示す。従来手法の雲種類判別式では、赤外画像データ(IR1)、赤外画像データ(IR2)から得られるIR1の輝度温度と、IR1の輝度温度からIR2の輝度温度を引いた輝度温度差を利用して雲種類判別を行い、快晴・曇天の気象状況を良好に判別している。輝度温度は雲頂高度の指標であり、輝度温度が低い場合は雲頂高度が高く、輝度温度が高い場合は雲頂高度が低くなる。輝度温度差は光学的厚さの指標であり、光学的に厚い雲は輝度温度差が小さくなり、巻雲のような氷で構成されている雲は輝度温度差が大きくなる。

輝度温度 (IR1)	253K	6: 巻雲	4: 厚い巻雲	2: 積乱雲
		5: 薄い巻雲	3: N型雲	1: 積雲
			2.5K	1.0K
				0K
		輝度温度差 (IR1-IR2)		

図1 従来手法の雲種類判別式

また、従来手法の地上での全天日射量 $S(W/m^2)$ の推定式には、電力中央研究所がDedieuの考案した推定式を参考に設定した式(2.1)を用いた。雲種類判別式を考慮した補正係数を加えることで、大気の補正係数のみを用いた推定結果に対して誤差を低減させている。

$$S = \alpha \times \beta \times S_0 \times \left(\frac{1-A}{1-A_s} \right) \tag{2.1}$$

α : 快晴時の大気の補正係数

β : 雲の種類ごとの補正係数

S_0 : 大気上端の水平な単位面積に入射する水平面日射量

A : 雲アルベド^{*5}

可視画像データ (VIS) の反射率から変換

$$A = Ref_{vis} / \cos \theta$$

Ref_{vis} : 可視画像データ (VIS) の反射率

A_s : 地表面アルベド

過去20日間における各時刻での雲アルベドの最低値

2.3 課題

従来手法では、快晴・曇天の気象状況を良好に判別しているが、曇天時の雲種（たとえば、図1の1：積雲，3：N型雲）において、補正係数 β の不確かさが大きく、日射量推定の過大傾向がある。また、上下に隣り合った雲種において補正係数の差が大きく、この雲種判別結果の違いにより日射量推定結果に影響を及ぼしている傾向がある。

3. 日射量推定手法の改良

本章では、従来手法の課題を解決する改良手法について説明する。3.1節で補正係数 $\alpha \cdot \beta$ の算出において入力データとなるサンプル数の増加、3.2節と3.3節で雲種類判別式の改良について述べる。雲種類判別式の改良は2種類あり、3.2節で従来の雲種類判別式に新しい変数を追加することによる改良手法、3.3節でクラスタリング手法適用による改良手法について述べる。日射量推定に使用したデータを表1に示す。

表1 日射量推定に使用したデータ

データの種類の	データ詳細		場所	期間	備考
衛星画像データ	MTSAT-2 (ひまわり7号)	可視画像 (VIS)	つくば(館野)	2013年11月～ 2014年10月	反射率情報を取得
		赤外画像 (IR1)			輝度温度情報を取得
		赤外画像 (IR2)			輝度温度情報を取得
日射量観測過去データ	気象庁日射量データ				気象庁のデータを利用

3.1 サンプル数の増加

式(2.1)における補正係数 $\alpha \cdot \beta$ の算出において、従来手法ではサンプル数が少なく同雲種で補正係数のばらつきが大きいいため、衛星画像データのサンプル数を増加させた（従来手法：20日間，改良手法：1年間）。ただし、従来手法と同様に、対象地点の真上からの雲による低減を考慮し、太陽天頂角 θ について $\cos \theta \geq 0.7$ を満たす衛星画像データ^{*7}のみ利用する。

上記の衛星画像データを用いた補正係数 $\alpha \cdot \beta$ の算出には、クロスバリデーション手法^{*8}を適用した。具体的には、推定対象月以外の観測値を用いて補正係数を算出し、算出した補正係数の平均値により推定対象月における補正係数を決定した。

3.2 雲種類判別式の改良

従来手法の雲種類判別式で、曇天時の雲種（たとえば、図1の1：積雲，3：N型雲）において補正係数 β の不確かさが大きい理由は、同雲種にて補正係数のばらつきが大きいことである。従来の雲種類判別式では、同雲種内に異なる特徴を持つ雲種が包括されており、6種類では日射量推定に必要な雲種類を表現することができていない。改良手法では、雲の厚みや雨粒密度に着目し、従来手法の雲種類判別式に雲の厚みや雨粒密度の影響を受ける変数（以下「変数X」）を加えた。変数Xと補正係数の関係には、層化傾向があるため、変数Xの大小でさらに分割した雲種類判別式（雲種類）に基づいた補正係数を用いることで、日射量推定結果の改善が期待できる。変数Xの境界値は過去の観測値を基に機械学習を行い、算出した。

従来手法の雲種類判別式に基づく補正係数 α 、 β の算出結果の平均値 \pm 標準偏差を表2に、

改良した雲種類判別式に基づく補正係数 α , β の算出結果の平均値 \pm 標準偏差を表3に示す。表2, 表3から, 従来手法および改良した雲種類判別式に基づく補正係数 α , β ともに月による大きな偏りがなく, 快晴・曇天による日射量に与える影響は月ごとに大きく変化しない。

表2 従来の雲種類判別式に基づく補正係数 $\alpha \cdot \beta$

補正係数	雲種類	3月以外	4月以外	5月以外	6月以外	7月以外	8月以外	9月以外	平均
α	快晴	0.73 \pm 0.04	0.74 \pm 0.04						
	雲なし	0.96 \pm 0.12	0.95 \pm 0.13	0.95 \pm 0.13	0.96 \pm 0.12	1.01 \pm 0.07	0.96 \pm 0.12	0.95 \pm 0.14	0.96 \pm 0.12
β	1: 積雲	0.62 \pm 0.33	0.71 \pm 0.35	0.72 \pm 0.37	0.74 \pm 0.34	0.71 \pm 0.36	0.74 \pm 0.36	0.70 \pm 0.36	0.71 \pm 0.35
	2: 積乱雲	0.45 \pm 0.20	0.44 \pm 0.20	0.46 \pm 0.21	0.47 \pm 0.25	0.45 \pm 0.22	0.40 \pm 0.18	0.44 \pm 0.20	0.45 \pm 0.21
	3: N型雲	0.75 \pm 0.28	0.74 \pm 0.28	0.73 \pm 0.28	0.79 \pm 0.26	0.77 \pm 0.27	0.80 \pm 0.26	0.78 \pm 0.27	0.77 \pm 0.27
	4: 厚い巻雲	0.51 \pm 0.22	0.48 \pm 0.22	0.50 \pm 0.22	0.50 \pm 0.23	0.48 \pm 0.22	0.49 \pm 0.22	0.50 \pm 0.21	0.50 \pm 0.22
	5: 薄い巻雲	0.89 \pm 0.18	0.89 \pm 0.18	0.88 \pm 0.18	0.89 \pm 0.18	0.89 \pm 0.17	0.90 \pm 0.18	0.89 \pm 0.18	0.89 \pm 0.18
	6: 巻雲	0.67 \pm 0.28	0.68 \pm 0.27	0.61 \pm 0.28	0.66 \pm 0.28	0.63 \pm 0.30	0.69 \pm 0.28	0.63 \pm 0.27	0.65 \pm 0.28

表3 改良した雲種類判別式に基づく補正係数 $\alpha \cdot \beta$

補正係数	雲種類	枝番	3月以外	4月以外	5月以外	6月以外	7月以外	8月以外	9月以外	平均
α	快晴	—	0.73 \pm 0.04	0.74 \pm 0.04						
	雲なし	—	0.96 \pm 0.12	0.95 \pm 0.12	0.95 \pm 0.12	0.96 \pm 0.12	1.01 \pm 0.12	0.96 \pm 0.12	0.95 \pm 0.12	0.96 \pm 0.12
β	1: 積雲	1	0.96 \pm 0.21	0.99 \pm 0.21	1.02 \pm 0.14	1.01 \pm 0.21	1.04 \pm 0.14	1.01 \pm 0.21	1.01 \pm 0.21	1.01 \pm 0.19
		2	0.50 \pm 0.28	0.56 \pm 0.32	0.49 \pm 0.31	0.52 \pm 0.29	0.50 \pm 0.31	0.53 \pm 0.32	0.48 \pm 0.30	0.51 \pm 0.30
	2: 積乱雲	1	0.78 \pm 0.13	0.75 \pm 0.14	0.78 \pm 0.13	0.84 \pm 0.06	0.78 \pm 0.13	0.72 \pm 0.15	0.78 \pm 0.15	0.78 \pm 0.13
		2	0.41 \pm 0.17	0.41 \pm 0.18	0.42 \pm 0.18	0.41 \pm 0.22	0.41 \pm 0.19	0.38 \pm 0.16	0.41 \pm 0.18	0.41 \pm 0.18
	3: N型雲	1	0.88 \pm 0.20	0.87 \pm 0.21	0.86 \pm 0.21	0.90 \pm 0.19	0.89 \pm 0.20	0.89 \pm 0.19	0.90 \pm 0.19	0.88 \pm 0.20
		2	0.50 \pm 0.24	0.50 \pm 0.24	0.50 \pm 0.24	0.53 \pm 0.19	0.50 \pm 0.24	0.49 \pm 0.23	0.49 \pm 0.23	0.50 \pm 0.23
	4: 厚い巻雲	1	0.74 \pm 0.15	0.73 \pm 0.16	0.75 \pm 0.15	0.73 \pm 0.16	0.75 \pm 0.14	0.73 \pm 0.15	0.73 \pm 0.14	0.74 \pm 0.15
		2	0.44 \pm 0.18	0.41 \pm 0.18	0.44 \pm 0.19	0.43 \pm 0.19	0.41 \pm 0.18	0.42 \pm 0.19	0.44 \pm 0.18	0.43 \pm 0.18
	5: 薄い巻雲	1	0.90 \pm 0.16	0.90 \pm 0.16	0.89 \pm 0.16	0.90 \pm 0.16	0.90 \pm 0.15	0.91 \pm 0.16	0.91 \pm 0.16	0.90 \pm 0.16
		2	0.68 \pm 0.33	0.68 \pm 0.33	0.65 \pm 0.30	0.68 \pm 0.35	0.71 \pm 0.34	0.66 \pm 0.33	0.68 \pm 0.24	0.68 \pm 0.32
	6: 巻雲	1	0.78 \pm 0.22	0.78 \pm 0.22	0.75 \pm 0.24	0.79 \pm 0.21	0.77 \pm 0.24	0.84 \pm 0.17	0.76 \pm 0.22	0.78 \pm 0.22
		2	0.40 \pm 0.21	0.42 \pm 0.21	0.35 \pm 0.10	0.40 \pm 0.21	0.36 \pm 0.23	0.40 \pm 0.21	0.39 \pm 0.20	0.39 \pm 0.19

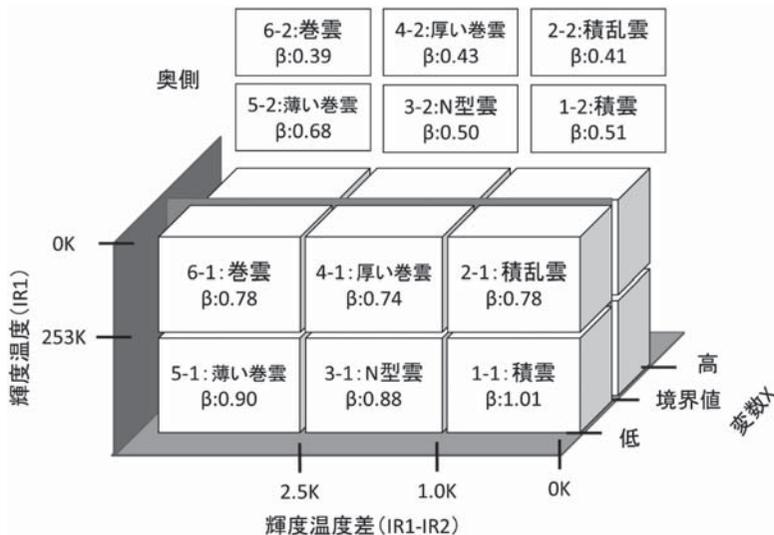


図2 改良した雲種類判別式

改良した雲種類判別式では変数 X が低い値の雲種類の場合（表 3 の枝番の 1）には補正係数が大きく、変数 X が高い値の雲種類の場合（表 3 の枝番の 2）には補正係数が小さくなっている。変数 X を加えたことにより、雲種類ごとに補正係数が 2 分され、補正係数のばらつきを抑えることができた。図 2 に改良した雲種類判別式を示す。

3.3 雲種類判別へのクラスタリング手法の適用

改良した雲種類判別式では、変数 X を加えることで従来手法と比べて、雲種内の補正係数のばらつきを抑えることができたが、補正係数のばらつきはまだ残っている。改良した雲種類判別式においても、従来手法と同様に境界値にて雲種類を判別しており、日射量推定に必要な雲種類を分類するという点で不十分である可能性がある。十分なサンプル数を入力データとし機械学習を行うことで、境界値による雲種類判別式より精緻に雲種類を分類できるという仮説のもと、クラスタリング手法を適用した。クラスタリング手法は教師なし機械学習の一つであり、特徴が似ているデータを自動的に分類することができるため、雲に関する知見を必要とせず雲種類を分類することができる。クラスタリング手法として、階層的クラスタリング手法（Ward 法^{*9[6]}）と非階層的クラスタリング手法（K-means 法^{*10[7]}）の二つを適用する。また、K-means 法のアルゴリズムは Hartigan-Wong^[8] を適用する。

各クラスタリング手法における、平均二乗誤差（以下、MSE）が最小となる最適なクラスタ数を算出した。K-means 法については初期クラスタがランダムに割り当てられるため、K-means 法を 3 回適用した結果の MSE の平均値とする。クラスタリング手法ごとのクラスタ数による MSE 変化を図 3 に、クラスタ数 10～50 を抽出した MSE の変化を図 4 に示す。MSE が最小値となるクラスタ数を表 4 に示す。

表 4 MSE が最小となるクラスタ数

クラスタリング手法	クラスタ数
Ward 法	29
K-means 法	32

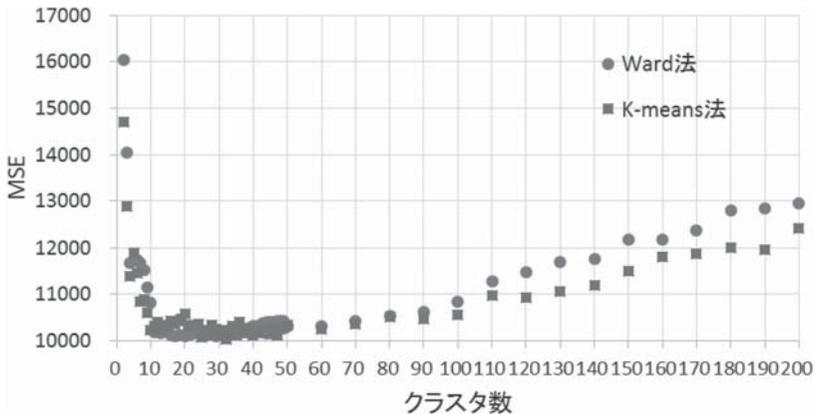


図 3 クラスタリング手法ごとの MSE 変化

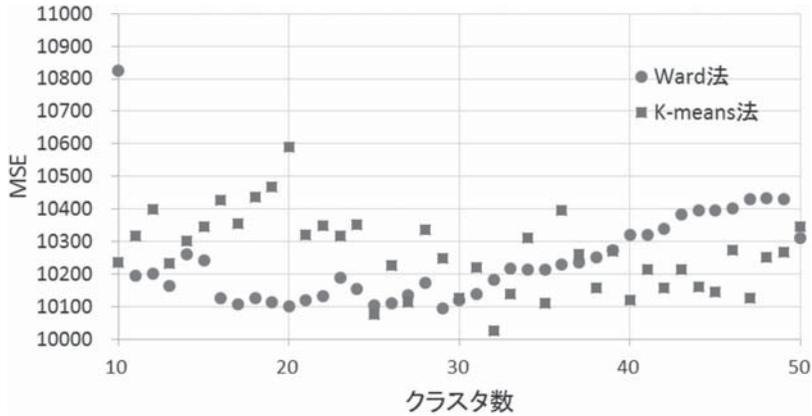


図4 クラスタリング手法ごとのMSE変化(クラスタ数10~50)

図4より、Ward法ではクラスタ数が20~30付近でMSEが低い値を示し、30を超えた付近からMSEが増加傾向にあり、K-means法ではクラスタ数が25~40付近でMSEが低い値を示し、40を超えた付近からMSEが増加傾向にある。したがって、最適なクラスタ数は20~40程度であり、改良した雲種類判別式よりも多くの雲種類へと分割される。

4. 日射量推定手法の評価

本章では、3章にて述べた改良した雲種類判別式およびクラスタリング手法による日射量推定手法の評価結果について述べる。

従来手法の雲種類判別式、改良した雲種類判別式、およびクラスタリング手法にて雲種類を推定し、式2.1の日射量推定式を用いて日射量を算出した(以下「推定日射量」)。推定日射量と観測値を比較することで、日射量推定手法の評価を行い、改良した雲種類判別式およびクラスタリング手法における日射量推定の精度向上を確認する。

従来手法の雲種類判別式、改良した雲種類判別式、およびクラスタリング手法(K-means法)による推定日射量と、観測値の時系列変化の一部(2014年8月18日~8月27日)を図5、図6、図7に示す。

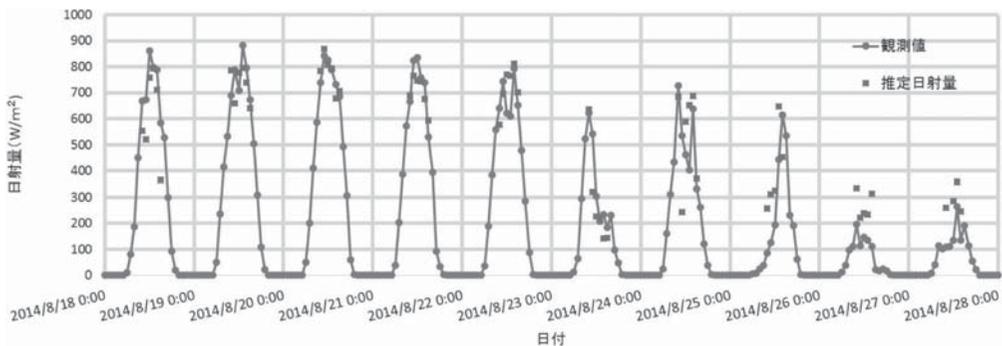


図5 従来手法の雲種類判別式による推定日射量の時系列変化

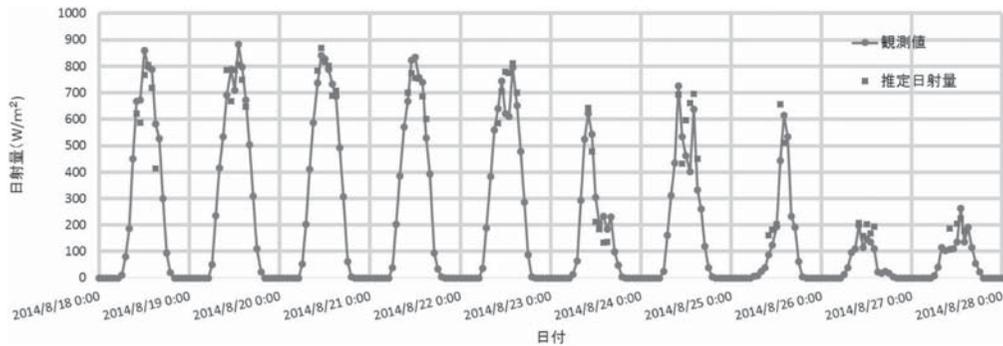


図6 改良した雲種類判別式による推定日射量の時系列変化

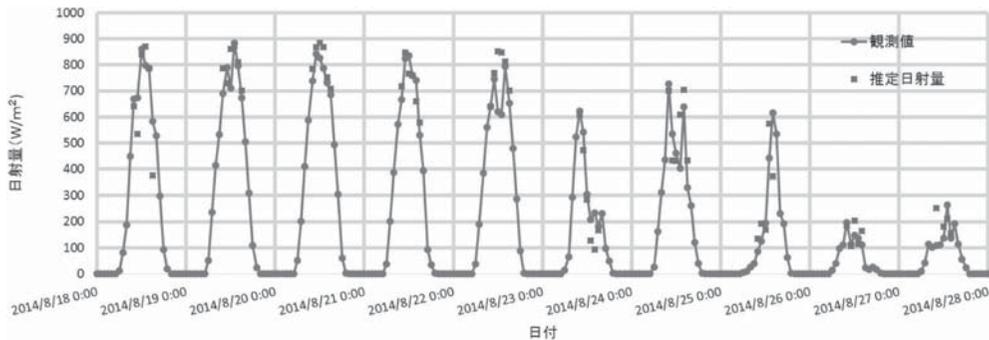


図7 クラスタリング手法 (K-means 法) による推定日射量の時系列変化

気象庁の天気概況によると、8月18日～8月22日の期間は晴天または雲が少なく、従来手法の雲種類判別式、改良した雲種類判別式、クラスタリング手法全てにおいて、図5～図7の8月18日～8月22日では観測値と推定日射量の差が小さく、晴天または雲が少ない日は推定日射量の精度が高い。また、8月23日～8月27日の期間は曇天または雨天であり、図5の従来手法の雲種類判別式において、8月25日～8月27日では推定日射量が観測値より過大となっているが、図6、図7の改良した雲種類判別式、クラスタリング手法においては推定日射量が観測値に近づいており、曇天の日は改良した雲種類判別式、クラスタリング手法による推定日射量の方が過大傾向を抑えられ、推定精度が高くなっている。

従来手法の雲種類判別式および改良した雲種類判別式を用いて、推定した雲種類ごとの推定日射量と観測値の差分を図8、図9、表5、表6に示す。ここで、観測値と推定日射量の差分は、ヒストグラムを用いて、ビンの数を7、ビンの幅を100として雲種類ごとの差分の分布を表現した。また、便宜的に従来手法の雲種類判別式の雲種類に合わせている。

表7に、従来手法と改良した日射量推定手法（以下「改良手法」）のMSEと二乗平均平方根誤差（以下、RMSE）を示す。

図8、図9から、従来手法および改良手法ともに、快晴と雲なしにおいては差分が $-50 \sim 50$ のデータが大半を占め、観測値と推定日射量の差分が小さく、推定精度が高い。しかし、従来手法では、図8の雲種類1、3において差分に偏りがあり（ $-50 \sim 50$ のデータ以外のデータが多く存在）、表7のMSEは雲種類1、雲種類3が高く、課題で挙げたとおり雲種類1、3の誤

差が大きい。一方、改良した雲種類判別式では、図9の雲種類1～4において差分の偏りが小さく(-50～50のデータを中心に分布)、表7のMSEは雲種類1～4で従来手法に比較して約42%～65%減少し、誤差が改善した。従来手法および改良した雲種類判別式ともに、雲種類判別式による雲種類の推定結果データ個数が少ない雲種類6では、図8、図9で差分に偏りが残っているが、表7の改良した雲種類判別式のMSEは従来手法に比較して約36%減少し、誤差が改善した。よって、改良した雲種類判別式では、雲種類1～4、6において日射量推定の精度向上を確認できた。

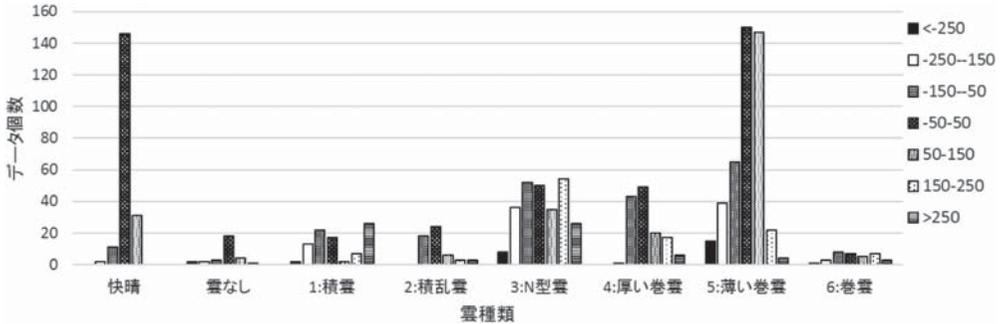


図8 従来手法の雲種類判別式による推定日射量と観測値の差分分布

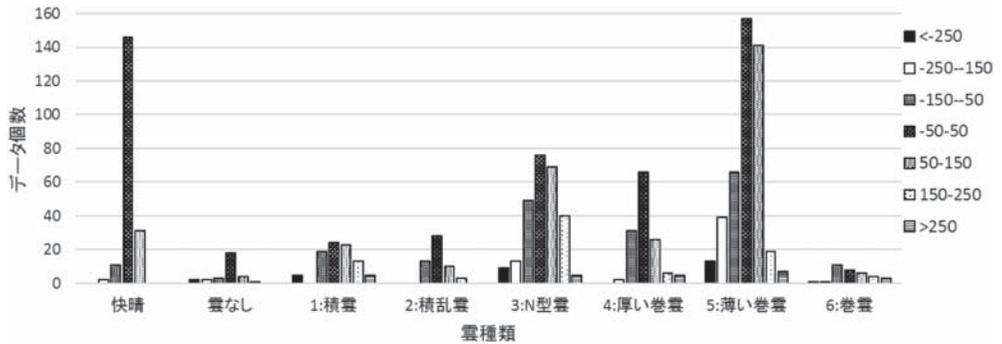


図9 改良した雲種類判別式による推定日射量と観測値の差分

表5 従来手法の雲種類判別式による推定日射量と観測値の差分のデータ個数

雲種類	差分ごとのデータ個数						
	～-250	-250～-150	-150～-50	-50～50	50～150	150～250	250～
快晴	0	2	11	146	31	0	0
雲なし	2	2	3	18	4	1	0
1:積雲	2	13	22	17	2	7	26
2:積乱雲	0	0	18	24	6	3	3
3:N型雲	8	36	52	50	35	54	26
4:厚い巻雲	0	1	43	49	20	17	6
5:薄い巻雲	15	39	65	150	147	22	4
6:巻雲	1	3	8	7	5	7	3

表6 改良した雲種類判別式による推定日射量と観測値の差分のデータ個数

雲種類	差分ごとのデータ個数						
	～ -250	-250 ～ -150	-150 ～ -50	-50 ～ 50	50 ～ 150	150 ～ 250	250 ～
快晴	0	2	11	146	31	0	0
雲なし	2	2	3	18	4	1	0
1：積雲	5	0	19	24	23	13	5
2：積乱雲	0	0	13	28	10	3	0
3：N型雲	9	13	49	76	69	40	5
4：厚い巻雲	0	2	31	66	26	6	5
5：薄い巻雲	13	39	66	157	141	19	7
6：巻雲	1	1	11	8	6	4	3

表7 従来手法と改良手法の統計量評価

評価指標	雲種類	従来手法	改良手法				
			改良した雲種類判別式	減少率	クラスタリング手法		減少率
					Ward法	K-means法	
MSE	全体	18008	11557	36%	10096	10027	44%
	1：積雲	48603	16854	65%	—	—	—
	2：積乱雲	9975	5546	44%	—	—	—
	3：N型雲	29443	15334	48%	—	—	—
	4：厚い巻雲	14312	8300	42%	—	—	—
	5：薄い巻雲	14273	1364	14%	—	—	—
	6：巻雲	27303	17497	36%	—	—	—
RMSE	全体	134	108	20%	100	100	25%

また、従来手法および改良した雲種類判別式ともに、差分に偏りが見られない雲種類5においては、改良した雲種類判別式を適用した場合にも、MSEはほとんど変化しておらず、他の雲種類と比べて推定精度が改善していない。これは雲種類5において変数Xの境界値以上のデータが少なく、改良した雲種類判別式の有効性を適用できなかったためである。

クラスタリング手法は従来手法と比較し、MSEが約44%減少し、改良した雲種類判別式と比較して誤差が改善した。クラスタリング手法を適用した場合の最適なクラスタ数は20～40程度となっており、従来手法および改良した雲種類判別式より大きな値である。クラスタリング手法は、雲に関する知見を用いた雲種類判別式と比較して雲ごとの特徴を精緻に捉えた分類ができ、日射量推定の精度がより向上している。

5. 今後の取り組み

5.1 ひまわり8号への対応

2015年7月よりひまわり8号の運用が開始され、ひまわり7号と比較し、観測頻度・水平分解能（解像度）が向上している。ひまわり8号の高頻度かつ高精度な衛星画像データを改良手法に適用することで、機械学習を行うためのサンプル数とサンプルの精度が向上し、日射量の推定精度の向上が期待できる。

5.2 雲移動予測

本稿では、従来手法より精度の高い雲種類推定および日射量推定ができた。今後は改良手法を用いて、日射量予測を目指す。日射量予測においては雲の種類判別だけではなく、雲の移動予測も重要となる。連続する2時刻の衛星画像データを基にして相互相関法を用いた画像解析を行い、雲の移動方向の予測を行う。

6. おわりに

本稿では衛星画像データを利用した従来の日射量推定手法を改良し、推定精度を向上した日射量推定手法を開発した。従来の雲種類判別式に新たな変数を追加し、雲分類を細分割することで補正係数のばらつきを抑えることができ、曇天時の推定精度の向上を確認できた。従来の日射量推定手法の課題を解決し、推定精度を向上させることができたことは有益である。

さらに機械学習のクラスタリング手法を適用することで、改良した雲種類判別式と比較して推定精度の向上を確認できた。また、雲に関する知見を必要とせず雲種類を精緻に分類でき、雲種類判別における機械学習の有効性を確認できた。日射量の推定精度の向上を達成し、改良した日射量推定手法により算出された推定日射量を利用することで、観測値の不足を補い、太陽光発電量予測の精度向上に貢献できる。

今後、本稿にて改良した日射量推定手法を利用し、雲の移動を予測することにより日射量の予測精度を向上させ、最終的には太陽光発電量予測の精度を高めて電力需給の安定化を図る。

最後に、本稿を執筆するにあたってアドバイスを下さった方々に感謝の意を表す。

-
- * 1 日射量は単位時間に単位面積が太陽から受ける放射エネルギーの量。本稿では (W/m^2) を単位として用いる。
 - * 2 数値予報モデルは大気を格子上に区切り、各格子点に大気状態を表す物理量 (気圧, 気温, 風速等) を与え、大気の状態変化を物理モデルに基づき計算し、将来の大気の状態を計算するモデルである。日本では主に気象庁が複数の数値予報モデルを運用しており、天気予報は数値予報モデルに基づくものである。
 - * 3 エアロゾルは大気中を浮遊する微小な液体または固体の粒子を表す。霧, もや, スモッグ, 粉塵等がエアロゾルに当たる。
 - * 4 ひまわり7号から得られる画像は可視画像と赤外画像の2種類があり、可視画像はVISの1種類がある。赤外画像はIR1~IR4の4種類があり、それぞれ観測する波長帯が異なる。
 - * 5 アルベドは反射率もしくは反射能、入射光に対する反射光の割合を表す。
 - * 6 太陽天頂角は観測地点の垂直方向 (天頂) からの太陽の入射光までの角度を表す。
 - * 7 太陽天頂角 θ について $\cos\theta \geq 0.7$ を満たすデータは、2月下旬~10月中旬までの昼間の時間帯のデータのみであるため、補正係数の算出には3月~9月のデータを利用した。
 - * 8 クロスバリデーションは標本データの一部のデータを解析して、残りの部分で解析結果のテストを行い、解析結果の妥当性の検証・確認を行う技法である。
 - * 9 Ward法はN個のデータが与えられた時に、1個のデータを含むN個のクラスタを作成し、クラスタ間の距離を計算し近いクラスタ同士で、クラスタを併合する。
 - * 10 K-means法はN個のデータに対して、指定したクラスタ数にて、クラスタをランダムに割振り、クラスタ内のデータを基にクラスタの中心点を計算する。計算した中心点を基にデータへのクラスタを割振りなおし、クラスタの中心点を再度計算する。データへのクラスタの割当てが変化しない場合に処理を終了する。

- 参考文献** [1] 滝谷 克幸, 「太陽光発電出力予測技術開発実証事業」太陽光発電出力予測・推定技術の開発, 平成25年電気学会全国大会シンポジウム, シンポジウム講演「H5スマートグリッド実証事業 現状と今後の展望 (経済産業省補助事業)」, 2013
- [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] 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
- [4] G. Dedieu, P. Y. Deschamps, Y. H. Kerr, Satellite Estimation of Solar Irradiance at the Surface of the Earth and of Surface Albedo Using a Physical Model Applied to Metcosat Data, *Journal of Climate and Applied Meteorology*, Vol. 26, 1987, pp 79-87
- [5] 橋本 篤, 小林 隆久, 田村 英寿, 平口 博丸, 太陽光発電出力予測のための衛星画像データを用いた日射量推定・予測モデルの開発, 電力中央研究所報告, N13003, 2013
- [6] Joe H. Ward, "Hierarchical grouping to optimize an objective function", *Journal of the American Statistical Association*, Vol. 58, 1963, pp 236-244
- [7] MacQueen, J. "Some Methods for Classification and Analysis of Multivariate Observations", *Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability*, University of California Vol. 1, 1967, pp 281-297
- [8] J. A. Hartigan and M. A. Wong, Algorithm AS 136: A K-Means Clustering Algorithm, *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, Vol. 28, No. 1, 1979, pp 100-108

執筆者紹介 斉藤 功樹 (Koki Saito)

2009年日本ユニシス(株)入社。金融機関向けのバックシステムの開発・保守を担当。2013年に総合技術研究所に異動。大規模データ処理技術に関する調査研究に従事し、現在は衛星画像のデータ処理・データ分析に関する研究に従事。

