論 文

衛星データによるソーラーパネル (Photovoltaic cell) 検出と 浸水・土砂災害リスク評価

嶌田将貴*^{1†}・竹内 渉*¹

Detection and Disaster Risk Evaluation of Solar Photovoltaic Cells in Satellite Remote Sensing Data

Shoki SHIMADA*1[†] and Wataru TAKEUCHI*1

Abstract

Due to the strong demand for renewable energy resources, the number of newly built photovoltaic cells has increased dramatically. However, these photovoltaic cells are sometimes subject to disasters such as floods and mudflow. To keep such facilities safe from disasters, a method that can monitor the locations and extent of photovoltaic cells in hazardous zones in cost-effective and less time-consuming ways is necessary. In this study, we developed a multi-temporal and multi-source machine -learning-based method for photovoltaic cell detection . The Sentinel-1 and Sentinel-2 datasets were used as data sources, and the random -forest classification method was applied to classify the land use and land cover (LULC) of the study area. Various combinations of inputs to the classifier were compared based on their performance of the LULC classification. After this process, the combination of optical -data, coherence -data, and the average of the coherence -data was selected as the best classification method. The photovoltaic cell detection process was carried out by combining the multi-temporal classification results to improve detection accuracy. This photovoltaic cell detection method achieved high -overall accuracy, high user accuracy, and a high-kappa coefficient.

Keywords : Photovoltaic panels, Sentinel-1, Sentinel-2, Random forest.

1. はじめに

ソーラーパネルの累積導入量は,2012年の固定価格買 取制度の制定後,急速に増加している¹⁾。しかしながら, ソーラーパネルは土砂災害や水害などにより破損・流出す る事例が報告されている²⁾。特に,水害で流出したソー ラーパネルは太陽光の存在の下で高電圧を生じることから, 流出対策等を適切に講じる必要がある。被災確率の高い ソーラーパネルの位置を判定する上では,ハザードマップ が良い指標となる。令和元年台風 19号におけるソーラー パネルの浸水被害状況では,浸水被害を受けた設備 16件 のうちの9件がハザードマップにおいて浸水被害想定区域 内に設置されていたことが報告されている³⁾。また,台風 等の接近前に必要な対策についての注意喚起が経済産業省 より行われている⁴⁾。しかしながら,これらは発電事業者 全体に対するものであり,被災確率の高い事業者に対して の積極的な注意等は現状では行われていないと言える。 また、林地を開発して造成されたソーラーパネルでは、 濁水の流出や自然環境への影響が懸念されている⁵⁾。した がって、必要な環境保全措置が取られているかについての 定期的なモニタリングの必要性が存在する。これに加えて、 固定価格買取制度終了後のソーラーパネルの放置や不法投 棄が懸念されていることから⁵⁾、メガソーラー発電所など の大規模施設に限定しないソーラーパネルの定期的なモニ タリングが環境保全の点からも重要であると考えられる。

これらの理由により,頻繁かつ低コストなソーラーパネ ル位置の検出手法の必要性は今後高まっていくと考えられ る。検出手法の一つとして,リモートセンシングの適用が 挙げられる。リモートセンシングはカメラやレーダーなど のセンサーを用いて対象の観測を行う手法の総称である。 センサー搭載プラットフォームとしてはドローン・航空 機・人工衛星などが広く用いられている。

これまでのソーラーパネル検出の試みには、主に機械学 習が用いられてきた。畳み込み深層学習(CNN)を用い た例として、高解像度衛星画像による全米規模でのソー

 ^{(2021.5.7}受付, 2021.12.10改訂受理)
*1東京大学生産技術研究所 〒153-8505東京都目黒区駒場4-6-1

 ^{*} 連絡著者 (Corresponding author)
E-mail : shokishimada@g.ecc.u-tokyo.ac.jp

^{*1} Institute of Industrial science, University of Tokyo, 4-6-1 Komaba Meguro-ku, Tokyo 153-8505, Japan

ラーパネル検出6).又は航空写真に基づいたソーラーパネ ル検出が挙げられる7)~10)。航空写真とランダムフォレス ト分類11),高解像度衛星画像とサポートベクターマシン (SVM)¹²⁾の組み合わせによるソーラーパネル検出手法に ついても研究が行われている。K-means セグメンテーショ ン, サポートベクターマシン, CNN の複合分類法¹³⁾, ハ イパースペクトル画像への Spectral unmixing の適応例も 存在する14)。しかしながら、先行研究の多くは主にアメリ カ合衆国を対象としており、これまでにリモートセンシン グ手法によって日本におけるソーラーパネルの検出を試み た先行研究は限られている。Landsat 衛星を用いてメガ ソーラー発電所の検出を試みた先行研究が存在するが15), 出力 5 MW 以上の発電施設のみが対象であり、より規模の 小さい発電施設については検討が行われていない。JAXA によって公開されている日本域高解像度土地利用土地被覆 図 ver 21.03 ではソーラーパネルが土地被覆クラスとして 新設されているものの、国土全体を対象とした作成者精度 (Producer's accuracy) は 66.3%と更なる向上が見込める段 階である。また土地被覆分類結果は 2018 年~2020 年の平 均的な状況であることから、ソーラーパネルの検出を任意 のタイミングで行う事はできない。また、先行研究の多く で用いられている高解像度衛星画像や航空写真は取得コス トが高く、頻繁なアップデートや広い領域への適用がコス トの点から困難である。

また、先行研究の殆どは光学衛星画像のみを用いている ものの、光学衛星画像は天候の影響を受け易く、気象条件 によっては利用可能な画像数が十分に得られない。合成開 ロレーダー (SAR) 画像は能動型センサーを用いる為,太 陽光や雲の有無に関わらないデータ取得が可能である¹⁶⁾。 SAR 画像を用いた物体認識の先行研究としては, SAR 画 像と画像・信号処理技術を用いた船舶検出¹⁷⁾¹⁸⁾, SAR 画像 と機械学習を用いた船舶検出19)など、主に船舶を対象と したものが多く存在する。船舶以外を対象とした陸上の物 体検出では、高解像度 SAR 画像と SVM を用いた航空機 検出²⁰⁾の試みが存在する。SAR 画像は土地被覆分類の特 徴量としても広く用いられており, RADARSAT-2 の偏波情 報を用いた土地被覆分類²¹⁾, 光学画像と SAR 画像の統合 による広域の土地被覆分類22),都市域の土地被覆分類23)24) などが行われている。しかしながら、先行研究の一部で用 いられている TerraSAR-X 等の高解像度 SAR 画像や, 偏 波解析に用いられる RADARSAT-2 のフルポラリメトリッ クデータは現在無償公開されておらず、高解像度の光学衛 星画像・光学航空画像を用いた手法と同様に、これらは広 域評価への適応性や、予算上の制約を伴うと考えられる。

ソーラーパネルは森林, 農地, 都市域と混在しており, これらと区別する為にはソーラーパネルの反射特性と, 植 生などと比較した際の時間的な安定性の両方を考慮するこ とが有用であると考えられる。2 組の SAR 画像から作成 されるコヒーレンスは植生・農地・都市域のそれぞれで異 なる特性を持つことが示されており²⁵⁾, ソーラーパネルを 含む複数の土地被覆クラスの区別に有用であると考えられ る。コヒーレンス特性を土地被覆分類の特徴量に用いるこ とで、土地被覆の区別を効果的に行える可能性が指摘され ているものの²⁶⁾、これまでにコヒーレンス特性を土地被覆 分類へ用いた先行研究の数は、後方散乱係数を用いた場合 と比較して少ない。

上記の課題解決へ取り組むため,以下を目的としたリ モートセンシング手法によるソーラーパネルの検出手法の 検討を行った。

- オープンアクセスな衛星画像とフリーソフトウェアの利用によって、広域を低コストかつ高頻度、任意の時期に解析可能であること。
- メガソーラー発電所と比べて規模の小さいソーラー パネルの検出が可能であること。
- ③ 日本域高解像度土地利用土地被覆図の最新版(バージョン 21.03)と比べて高いソーラーパネルの検出 精度を目指すこと。
- ④ 各種ハザードマップとソーラーパネル位置の比較に より、想定される災害の種類について検討すること。

2. デ ー タ

Sentinel-1 衛星と Sentinel-2 衛星は欧州宇宙機構(ESA) によって運用されている地球観測衛星であり,それらの データは無償で利用が可能である。Sentinel-1 衛星は合成 開口レーダー(SAR)を搭載しており,全天候型の観測能 力を持つ。Sentinel-2 衛星は光学センサーを搭載しており, 可視光域から赤外光域までの多様な観測能力と,比較的高 い分解能が特徴である。Open Access Hub ウェブサイト (https://scihub.copernicus.eu/dhus/#/home)よりこれらのデー タをダウンロードして利用した。データ解析には,QGIS 3.16.3, SNAP 8.0 及び Python 3.7 を利用した。

対象地域として,茨城県と千葉県の県境付近の領域(東 経 140.265 度~東経 140.657 度,北緯 35.805 度~北緯 36.003 度)の範囲を選定した。選定の理由としては,対象 地域において複数のメガソーラー発電所が既に開発済みで ある事,また利根川流域に存在しており,今後懸念される 水害被害を防ぐ為にソーラーパネルの検出を行う意義があ ること,市街地・森林・農地が混在しており,日本の平野 部で一般的と考えられる土地被覆を持つと考えられるため である。Fig. 1 に,対象地域の Sentinel-2 衛星によって撮 影された Natural Color 画像を示す。

利用したデータについて, Table 1 に示す。ここで Sentinel-1 プロダクト形式の SLC (Single Look Complex) は SAR データ形式の一つであり, 観測されたデータの位 相情報を利用可能な形式である。対象地域をカバーする Sentinel-1 観測データのうち, Sentinel-1 A は Descending 軌 道, Sentinel-1B は Ascending 軌道での画像が利用可能であ った。Sentinel-1B は Sentinel-1A よりも打ち上げ時期が遅 く, センサーの劣化等も少ないと考えたことから, 本研究



Fig. 1 The natural color image of the study site on 2020/11/13 (R/G/B=Band4/Band3/Band2).

Satellite	Acquisition date	Product type
Sentinel-1B	2020/11/11	VV polarization SLC
Sentinel-1B	2020/11/23	VV polarization SLC
Sentinel-1B	2020/12/05	VV polarization SLC
Sentinel-1B	2020/12/17	VV polarization SLC
Sentinel-1B	2020/12/29	VV polarization SLC
Sentinel-1B	2021/01/10	VV polarization SLC
Sentinel-1B	2021/01/22	VV polarization SLC
Sentinel-1B	2021/02/03	VV polarization SLC
Sentinel-1B	2021/02/15	VV polarization SLC
Sentinel-1B	2021/02/27	VV polarization SLC
Sentinel-1B	2021/03/11	VV polarization SLC
Sentinel-2B	2020/11/13	L2A
Sentinel-2A	2020/11/28	L2A
Sentinel-2A	2020/12/08	L2A
Sentinel-2B	2020/12/23	L2A
Sentinel-2B	2021/01/02	L2A
Sentinel-2A	2021/01/22	L2A
Sentinel-2A	2021/02/06	L2A
Sentinel-2B	2021/02/21	L2A
Sentinel-2B	2021/03/03	L2A

Table 1 A list of datasets

では Sentinel-1B にて取得された Ascending 軌道のデータ のみを利用した。Sentinel-2 プロダクト形式の L2A は大気 補正済み地表反射率データへ変換済みであることを示す。 Sentinel-2 プロダクトについては、雲の影響が 30%未満で あるものを選択して利用した。

3. 手 法

手法のフローチャートについて, Fig. 2 に示す。InSAR 処理は複数の SLC 画像に対して適用可能な手法である。



Fig. 2 The flowchart of methods.

対象領域を含むバーストの選択,衛星軌道情報の導入,マ スター画像とスレーブ画像の統合,Enhanced Spectral Diversity 処理,コヒーレンス計算,S1-TOPS Deburst 処理, Speckle filtering, Range-doppler terrain collection の順に InSAR 処理を SNAP ソフトウェアを用いて適用した。 SAR データから計算される物理量の代表的なものとして, 単位面積当たりの散乱断面積の値を示す散乱係数が挙げら れるが,本手法では散乱係数ではなく,コヒーレンスを SAR データの特徴量として用いた。コヒーレンスは2枚 の SLC 画像間の類似度(Correlation)の指標となるもので あり,以下の(1)式で定義される。

$$\gamma = \frac{|\langle e_1 e_2^* \rangle|}{\sqrt{\langle |e_1|^2 \rangle \langle |e_2^*|^2 \rangle}} \tag{1}$$

ここで、 e_1 , e_2 はそれぞれ一度目、二度目の SAR 観測 で得られたデータであり、複素数形式となっている。また、 e_2^* は e_2 の複素共役、<>の記号は対象ピクセル周囲で の空間平均を示している。空間平均の範囲内で画像が完全 に相関している場合にはコヒーレンスの値は1となり、統 計的な相関が全く見られない場合にはコヒーレンスの値は 0 となる。コヒーレンス値はノイズ、ベースラインの変化、 地表の時間的な安定性など様々な要因によって影響を受け るが、本研究では同一の衛星(Sentinel-1B)を使用してお り、またそれぞれの SAR 画像は同一個所のデータである ことから、コヒーレンス値は主に地表の時間的な安定性に よって決定されていると考えられる。地表の時間的な変化 の大きい植生や水域などの土地被覆ではコヒーレンス値は 小さくなり、ソーラーパネルを含む人工物や、露出した岩 石などではコヒーレンス値は高くなる。よって、コヒーレ ンス値の導入が人工物と自然物を区別する上で有用である ことが推察されたことから、土地被覆分類の特徴量として 導入を行った。本研究では Sentinel-1B データのうち、12 日間隔で取得されたデータについてコヒーレンスを計算し た。SNAP ソフトウェア上でコヒーレンスの適切な計算が 行われなかった 2020/12/29 に取得されたシーンと 2021/01/10 に取得されたシーン間のコヒーレンスを除いて、 対象期間中に合計で9シーンのコヒーレンス画像を作成し た。

それぞれのコヒーレンス画像について、マスター画像と スレーブ画像の取得期間内に撮影された Sentinel-2 画像を スタッキングし、特徴量として利用した。スタッキングに おいては位置精度の高い Range Doppler Terrain Collection 後の Sentinel-1 画像をマスター画像とし、Sentinel-2 画像 をスレーブ画像とした。スタッキング画像と Google Earth QGIS plugin の高解像度画像を重ね合わせて比較し、橋梁 などの Ground Control Point の位置がほぼ一致しているこ とを確認した。また、コヒーレンスの全期間における平均 値を計算し、特徴量として併せて利用した。

ランダムフォレスト分類は土地被覆分類の分野で深層学 習や SVM と並んで広く使われていることから、本手法に おいて土地被覆分類手法として採用した。Google Earth QGIS plugin にて表示された高解像度画像を参考としつつ, 対象領域からポリゴン形式で教師データを収集した。 SNAP 8.0 の Supervised classification 機能を用いたランダム フォレスト分類によって6クラス(裸地,都市域,農地, ソーラーパネル,森林,水域)の土地被覆分類を行い,分 類結果からソーラーパネルクラスのみを取り出すことによ ってソーラーパネルの検出を行った。SNAP ソフトウェア では、ポリゴン形式で教師データを与えることにより、指 定した教師点の数までポリゴン内の範囲を対象としたラン ダムサンプリングが行われる。本研究では、各土地被覆ク ラスに対して 5000 点の教師データを用いた。また、ラン ダムフォレストの number of trees パラメータはデフォルト 値の10とした。

特徴量の違いに伴う土地被覆分類精度の差異について検 討を行う為,2021/01/02から2021/03/11までの期間のデー タによって作成された5シーンの土地被覆分類結果につい ての『光学データのみ』、『光学データ+単時期コヒーレン ス』、『光学データ+単時期コヒーレンス+多時期コヒーレ ンスの平均値』のそれぞれを特徴量として利用した場合に ついて、精度検証及び比較を行った。この土地被覆分類の 精度検証では、600点のランダムサンプリングによる検証 点を取得した。ランダムサンプリングによる検証点は、裸 地が31点、都市域が81点、農地が281点、ソーラーパネ ルが10点、植生が128点、水域が69点となった。

上述の土地被覆分類の精度検証をふまえ, 全体精度とκ

係数を基準として最もよい分類精度を持つと考えられる特 徴量の組み合わせによる土地被覆分類の結果を用いて、対 象地域におけるソーラーパネルの検出を行った。単時期の 分類のみでは安定した検出が行えない可能性が存在するこ とから、全9シーンの土地被覆分類図のうち、4回以上 ソーラーパネルとして分類された箇所をソーラーパネルの 位置として選択した。ソーラーパネルが全体に占める面積 割合は微小であり、上述の 600 点のランダムサンプリング のみではソーラーパネル検出の精度検証に十分な検証点の 数が得られなかったため、土地被覆分類の教師データに用 いていないソーラーパネルを Google Earth OGIS plugin を 参考にしながら重複の無い様に 100 カ所選択し, 合計 700 点を用いて精度検証を行った。複数時期の土地被覆分類図 の組み合わせによるソーラーパネルの検出結果についての 検証データは、裸地が 31 点、都市域が 81 点、農地が 281 点, ソーラーパネルが 110 点, 植生が 128 点, 水域が 69 点となった。ソーラーパネルの検出結果の精度検証では, 検証点単位での検出の有無ではなく、その検証点を含んだ ソーラーパネルの区画単位での検出の可否を判定した。こ こで、ソーラーパネルの区画は以下の様に定義した。① ソーラーパネル群が周囲から独立し、明らかに単一の区画 となっている。② 複数のパネル群が近接しているものの. 道路などで明確な区画が分けられている。以下、この定義 に基づいて目視判読によって区別したソーラーパネルの一 群をソーラーパネル区画と呼称する。

区画単位での検出精度の検証を行った理由としては、区 画内のソーラーパネルは同一事業者に属している可能性が 高いことが想定され、災害対策などの活動はそれらの事業 者単位で実行されると考えられることから、点ではなく ソーラーパネル(事業者)区画単位での検出精度評価がよ り適していると考えられる為である。上述のソーラーパネ ル区画内の全てのソーラーパネルが検出されていない場合 についても、ソーラーパネルとして検出されたピクセルが ソーラーパネル区画内に2 個以上存在する際には、その ソーラーパネル区画の検出は成功したとして以降の検出精 度の検討を行った。

検出されたソーラーパネルの位置を浸水想定ハザードマ ップ及び土砂災害区域ハザードマップと比較することによ って、危険性の高い災害の種類についても検討を行った。

4. 結 果

2021/01/02 から 2021/03/11 までの期間について作成した 5 シーンの土地被覆分類精度検証結果について, Fig. 3 に 示す。また, Table 2 に各シーンにおける解析対象時期を 示す。土地被覆分類図の例について, 5 シーンのうち最も OA の高かった Period3 (2021/02/03~2021/02/15) につい て, Fig. 4 に示す。

全体精度及び κ 係数は skelearn ライブラリ中の confusion matrix 及び cohen kappa score を用いて計算を行



Fig. 3 The overall accuracy (Upper figure), The kappa coefficient (Lower figure). Opt … The classification results based on the optical data. Opt+Coherence … The classification results based on the combination of the optical data and the coherence data. Opt+Coherence+CoherenceAverage … The classification results based on the combination of the optical data, the coherence data, and the average of the coherence data.

Table 2 The scene names and target periods

Scene name	The target period	
Period1	2021/01/02~2021/01/22	
Period2	2021/01/22~2021/02/03	
Period3	2021/02/03~2021/02/15	
Period4	$2021/02/15 \sim 2021/02/27$	
Period5	2021/02/27~2021/03/11	

った。光学データによる土地被覆分類精度は安定しており, 光学データと単時期コヒーレンスによる土地被覆分類精度 は時期によって光学データによるものを上回るものの,時 系列的な精度の変化が激しい。光学データ,多時期コヒー レンスの平均値,単時期コヒーレンスを用いた場合の土地 被覆分類精度は光学データによるものと類似した時系列変 化を保ちつつ,常に光学データによる土地被覆分類精度, 及び光学データと単時期コヒーレンスによる土地被覆分類



Fig. 4 The land-use land-class (LULC) map produced by the data from 2021/02/03 to 2021/02/15.



Fig. 5 The distribution of the detected photovoltaic cells (red polygons) overlayed on the sentinel-2 image on 2020/11/13.

Table 3 The accuracy assessment results.

Overall accuracy	User accuracy	Producer accuracy		
97.1%	100.0%	81.8%		
κ coefficient=0.897				

精度を上回っている。

9 シーンの統合によるソーラーパネルの検出については, 上記の土地被覆分類精度の比較結果を踏まえて,精度が最 も安定して高いと考えられる『光学データ,多時期コヒー レンスの平均値,単時期コヒーレンス』による土地被覆分 類の結果のみについて行った。ソーラーパネルの検出の精 度検証結果について,Table 3 に示す。また,検出された ソーラーパネルの面的分布について,2020/11/13 の Sentinel-2 画像と重ね併せた図を Fig.5 に示す。

茨城県と千葉県の洪水想定浸水区域及び土砂災害警戒区

域を国土数値情報ウェブサイトからダウンロードし,検出 されたソーラーパネルの位置と重ね合わせることによって 被災リスクを検討した。以下の Fig. 6 に,洪水想定浸水区 域内に検出されたソーラーパネルの一例を示す。また, Fig. 7 に土砂災害警戒区域付近に検出されたソーラーパネ ルの一例を示す。ソーラーパネルの検出結果を WGS 84座 標系から UTM zone54N 座標系へと投影後, QGIS polygonize ツールを用いてポリゴンへ変換し、面積計算を行っ た。これらのうち、およそ 100kW 程度の発電規模となる 1000 m² 以上の面積であった 467 カ所について, 洪水想定 浸水区域及び土砂災害警戒区域に重なる数を QGIS select by location ツールの intersect オプションによって算出した。 検出されたソーラーパネルポリゴンのうち.茨城県に5カ 所,千葉県に1カ所が土砂災害警戒区域に含まれていた。 洪水想定浸水区域には,茨城県に54カ所,千葉県に33カ 所が含まれていた。



Fig. 6 An example of the detected solar panels inside the flood hazard map.



Fig. 7 An example of the detected solar panels near the landslide hazard map.

5. 考 察

光学データ、単時期コヒーレンスに加えて多時期コヒー レンスの平均値を用いた場合には、光学データを単独で用 いた場合よりも高く、かつ安定した分類を行えることが明 らかとなった。この理由としては、多時期コヒーレンス平 均値情報の導入によって人工物と農地の区別が容易となっ たことが考えられる。すなわち、単時期のコヒーレンスや 光学データが土壌水分量などによる一時的な影響を受けや すい一方で、多時期コヒーレンスの平均値は人工構造物で 高く、植生や農地では低いという安定した情報を持ってい ることが、これらの分類を容易にしたと推察される。この ことについては、農地が都市域として誤分類された数が、 光学データのみでは平均 71.2 点,光学データ・単時期コ ヒーレンスでは平均 73 点であったのに対して、光学デー タ・単時期コヒーレンス・多時期コヒーレンスの平均値を 用いた場合では平均 35 点であったことからも確かめられ る。

9 シーンの分類結果の統合によるソーラーパネルの検出 結果は、全体精度・使用者精度・κ係数のいずれも高い値 を示した。使用した 700 カ所の検証点についてはソーラー パネルの誤検出が生じていなかった。ソーラーパネルは安 定した構造物であり、平均して高いコヒーレンスを持つ。 駐車場や屋上などのソーラーパネルと類似した外観であり、 同様に高いコヒーレンスを持つ構造は都市域に多く存在す るものの、これらの構造とソーラーパネルを区別する上で は光学データが効果的に作用したと考えられる。また、複 数回の分類結果を統合して検出を行ったことも、誤検出を 低減する上で効果的であったと推察される。

検出結果の例として, Fig. 8 に 1000 m²(推定 0.1 MW 規 模)程度のソーラーパネルの検出結果を示す。Fig. 8 (b) の検出結果において, 黒に近いピクセルはソーラーパネル として検出される回数が多く,より確度が高いことを示し ている。

提案手法による作成者精度は 81.8% であり, これは国 土全体で評価された日本域高解像度土地利用土地被覆図 ver 21.03 のソーラーパネル検出の作成者精度 66.3% を上 回っていた。同一領域での検出精度について更に比較を行 う為, 日本域高解像度土地利用土地被覆図 ver 21.03 をダ ウンロードし,提案手法の精度検証に用いたものと同一の 700 カ所の検証点を用いてソーラーパネル検出の精度検証 を行った。同一領域内にて検出結果の比較を行った結果, 日本域高解像度土地利用土地被覆図 ver 21.03 による作成



Fig. 8 An example of the detected small-scale solar panels. (a): The google earth image of the solar panels. (b): The detected locations of solar panels. The darker a pixel is, it is more likely that there is a solar panel within the cell.

者精度は 89.1%となった。このことから,提案手法によ る作成者精度は対象領域において既存の土地被覆分類図に よる検出結果と比較して低い値となった。しかしながら, 提案手法による検出結果には含まれ,日本域高解像度土地 利用土地被覆図 ver 21.03 には含まれていないソーラーパ ネル区画が目視判読の結果として対象領域内に少なくとも 64 カ所存在した。また,提案手法による検出結果では都 市域におけるソーラーパネル区画の誤検出率が日本域高解 像度土地利用土地被覆図 ver 21.03 と比較して低い傾向が 見られた。Fig. 9 に,都市域におけるソーラーパネル区画 の誤検出についての比較例を示す。

ソーラーパネル検出の精度検証への追加データとして取 得した 100 カ所のソーラーパネル区画を用いて,ソーラー パネルの検出精度に影響を及ぼす要因について更に検討を 行った。100 カ所中 82 カ所は提案手法によって検出され, 18 カ所は検出されなかった。これら 100 カ所のソーラー パネル区画の検出結果図を WGS84 等緯度経度から UTM zone 54N に投影を行い,各ソーラーパネル区画を目視で ポリゴン化した。

提案手法によって検出されなかったこれら 18 カ所の ソーラーパネル区画について、いずれの土地被覆分類クラ

スへと誤分類されたのかについて検討を行った。全9シー ンの土地被覆分類図のうち、11カ所は都市域、6カ所は農 地として最も誤分類された。また、残りの1カ所は農地・ 裸地としてそれぞれ4回誤分類された。このことから、コ ヒーレンス特性の導入により、森林・水面のコヒーレンス の低い土地被覆クラスとの区別が行えているものの、比較 的コヒーレンスの高い土地被覆クラスとソーラーパネルの 間で誤分類が生じていることが推測される。Period3 (2021/02/03~2021/02/15) における土地被覆分類図上に提 案手法によって検出されなかったソーラーパネル区画の位 置を重ね合わせた図を Fig. 10 に示す。Fig. 10 において、 検出されなかったソーラーパネル区画の特定地域へのクラ スタリングは観察されず、対象地域に広く分布していた。 このことから、検出の可否に影響を与える要因は個々の ソーラーパネル区画の特性に由来するものと考えられる。 各ソーラーパネル区画の面積・地形要因・コヒーレンス特 性が検出の可否に影響を与えたかについて、統計学的指標 に基づいて検討を行った。

面積の小さいソーラーパネルは検出がより困難であるとの仮説を立て、QGIS 上で Field Calculator を用いて平方 メートル単位で各ソーラーパネル区画面積の計算を行った。



Fig. 9 The comparison of false alarms between the proposed method and the JAXA high-resolution land-use land-cover map version 21.03. The background is the high-resolution image on the Google Earth QGIS plugin. (a) The result of the JAXA high-resolution land-use land-cover map version 21.03. (b) The result of the proposed method.



Fig. 10 The spatial distribution of the un-detected solar panels. Each solar panel is labeled with the most frequently misclassified LULC class. The background image is the LULC map produced by the data from 2021/02/03 to 2021/02/15.

結果として、検出を行えなかったソーラーパネル区画の平 均面積が 12653 m²、検出を行えたソーラーパネル区画の 平均面積が 9304 m² となった。この事から、ソーラーパネ ル検出の可否はパネル区画の面積には影響されないと考え られる。ソーラーパネルの方向についても QGIS Google Earth plugin を用いて目視判読による定性的な評価を行っ た結果、いずれも南東から南西に対して設置されており、 検出されたソーラーパネル区画と検出されなかった区画の 間で明瞭な違いは認められなかった。

検出の可否に影響を与えうる地形要因としてソーラーパ ネル地点での Slope, Aspect, 標高を計算した。これらの地 形要因の値は、ソーラーパネル区画ポリゴンの中央付近から QGIS の Point sampling tool を使用して抽出した。また、 対象期間におけるコヒーレンス平均値を計算し、地形要因 と同様に各ソーラーパネル区画中央付近での値を QGIS point sampling tool で抽出した。検出されたソーラーパネ ル区画と検出されなかったソーラーパネル区画の間でこれ らの物理量の平均値に統計的な有意差があるかを検討した。 ここで、Slope、Aspect、標高は ALOS DSM: Global 30 m を 利用し、Google Earth Engine 上で計算を行った。

独立な集団の平均の差の t 検定を適用した結果,検出が 可能であったソーラーパネル区画の対象期間におけるコ ヒーレンス平均値(0.77)は、行えなかったソーラーパネ ル区画の対象期間におけるコヒーレンス平均値(0.59)と 比較して有意な差が存在した(p=3.5*10⁻⁵)。その他の物 理量の平均の差の検定結果については、5%有意水準の下 で有意差は存在しなかった。太陽光の入射量に影響する Slope, Aspect が検出の可否に有意な違いを持っていない ことから、太陽光の方向、及び太陽光の反射光を利用する 光学衛星の観測方向についても検出の可否に有意な影響が ないと推察される。

レーダー波の地面に対する照射方向の検出精度への影響 について、local incidence angle に基づいて検討を行った。 Local incidence angle は地表面の垂線に対してレーダー波 がなす角度であり、レーダー波の反射において重要な要素 となる。全9シーンのコヒーレンス画像について、SRTM 1Sec 及び SNAP 8.0 を用いて local incidence angle を計算し、 これらの平均値を算出した。地形要因と同様に各ソーラー パネル区画中央付近での値を QGIS point sampling tool で抽 出した。独立な集団の平均の差の検定を適用した結果、検 出されたソーラーパネル区画と検出されなかったソーラー パネル区画の間では、平均値に有意な差は存在しなかった (p=0.30)。このことから、レーダー波の地面に対する照 射方向は、検出の可否に有意な影響を持たないと考えられ る。

一部のソーラーパネル区画でコヒーレンスが低かった原 因について考察を進める為, QGIS Google Earth plugin にて 検出が行えていないソーラーパネル区画の外観について定 性的な検討を行った。結果として、検出されていないソー ラーパネル区画ではパネル間隔が広く, 地表が見えている 場合が多い事が分かった。現地調査を行っていないため地 表面積率の比較等の定量的な議論は困難であるものの、パ ネル間隔が広い設備では SAR シグナルが地表までより多 く到達している可能性がある。Sentinel-1 は C バンド SAR である為、数センチ~数十センチの草丈であってもコヒー レンス値が影響を受け得ることから、地表植生によってコ ヒーレンスが低下している可能性が考えられる。植生の存 在に加えて、ソーラーパネルは滑らかで平面的な構造であ ることから、個々のパネル表面に対する入射角・方向角に よってはセンサーからのエネルギーがセンサーと反対の方 向へと反射されることで、エネルギーの多くの割合がセン サーへ戻らず,受信シグナルに占めるノイズが支配的とな ることでもコヒーレンス値は低下する。センサーへ戻る レーダー波の程度は後方散乱係数の大きさによって示され ると考えられることから、検出されたソーラーパネル区画 と検出されなかったソーラーパネル区画の間で後方散乱係 数の平均値に有意な差があるか検討を行った。Table 1 に 示した Sentinel-1B プロダクトと同一日の全 11 シーンの GRD (Ground Range Detected) プロダクトを Open access hub からダウンロードし, SNAP 8.0 を用いて後方散乱係 数への変換を行った。後方散乱係数への変換のため、対象 領域へのサブセット, キャリブレーション, Lee-Sigma フ

イルタによるスペックル低減. SRTM 3Sec による Range Doppler Terrain Collection, デシベル変換の順に処理を適用 した。その後,得られた後方散乱係数の平均値を算出し, 地形要因と同様に各ソーラーパネル区画中央付近での値を QGIS point sampling tool で抽出した。独立な集団の平均の 差の検定を適用した結果、検出されたソーラーパネル区画 と検出されなかったソーラーパネル区画の間では、後方散 乱係数の平均値に有意な差が存在した(p=7.44*10⁻³)。 また、検出されたソーラーパネル区画では後方散乱係数の 平均値が-7.00 (dB) であり、検出されなかったソーラー パネル区画では-12.37 (dB) となった。このことから、 検出されなかったソーラーパネル区画ではセンサーへ戻る レーダー波がセンサーと反対方向へ反射されて低くなり, シグナルにしめるノイズの割合の増大によってコヒーレン ス値が低下したことが推察される。センサーへ戻るレー ダー波の程度は個々のソーラーパネルとレーダー波のなす 入射角・方位角や、支柱やパネルの数、パネル表面の粗さ など構造的な要因が関わると考えられる。これらの詳細な 構造要因の後方散乱係数への影響の検討は本研究で用いた 衛星画像の解像度では判別が困難であったことから、これ らは現地調査を含めた今後の課題となる。

これらの SAR シグナルへの影響要因に加えて,ソー ラーパネルの種類によって可視光・赤外光領域に対する反 射率が異なる可能性が存在する。しかしながらこの点の更 なる検討には現地調査が必要となる為,本研究では詳細な 分析を行う事が困難であった。

以上をふまえたソーラーパネル検出の使用者精度を高め ていく上での今後の課題として、テクスチャ分類の適用、 反射率・コヒーレンス情報の時系列解析、地表植生の影響 を受けにくい ALOS-2 のLバンド SAR の利用、今回用い た ascending 軌道とは入射角・方位角の異なる descending 軌道におけるコヒーレンス情報を併せて用いる事が挙げら れる。

検出されたソーラーパネルとハザードマップを比較・検 討することによって,発生する可能性のある災害の種類と ハイリスクな施設の特定が可能となった。対象地域では土 砂災害警戒区域と比較して,洪水想定浸水区域中に多くの ソーラーパネルの存在が示唆された。特に最大のものは面 積がおよそ 152000 m² とメガソーラー級であり,洪水被害 が生じた場合には復旧費用や流出被害などが甚大となる可 能性が存在する。これらの施設に対しては行政が積極的に 指導・監視を行うなど,防災・減災へ繋がる行動をとる必 要性が高いと言える。

本手法で利用した Sentinel-1 衛星及び Sentinel-2 衛星は データが無償で公開されていることから,費用面での負担 なく対象領域・対象期間を拡大することが可能である。し たがって,将来的には本手法を国土全体へ適用することに より,被災確率の高いソーラーパネルの検出と想定される 災害の種類について全国規模でのデータベース化が可能と なることが期待される。

6. 結 論

オープンアクセスな衛星画像による光学データと, SAR データから得られたコヒーレンス情報による分類、更に時 系列データの統合によって高い全体精度と使用者精度によ るソーラーパネルの検出が可能となった。今後使用者精度 を高めていく上では異なる手法や異なる軌道で観測された SAR データの導入が必要となると考えられる使用者精度 については既存の土地被覆分類図による検出結果と比較し て低い値となったものの、提案手法では全データが無償で 容易に入手可能であることから検出結果の更新が容易かつ、 既存の土地被覆分類図による検出結果に含まれないソー ラーパネル区画を検出することが可能であった。このこと から,既存の土地被覆分類図によるソーラーパネル区画の 検出結果を提案手法によって補完することで、日本で急速 に整備が進むソーラーパネルの分布の現況の迅速な把握が 期待できる。加えて、検出されたソーラーパネルとハザー ドマップの比較により、想定される災害の種類とハイリス クな発電施設の検討が行える可能性が示された。

参 考 文 献

- 経済産業省:平成 30 年度エネルギーに関する年次報告, https://www.meti.go.jp/shingikai/sankoshin/hoan_shohi/denryo ku_anzen/newenergy_hatsuden_wg/pdf/014_01_00.pdf (Accessed 2021. 11. 10)
- 経済産業省:今夏のソーラーパネルの事故の特徴について、 https://www.meti.go.jp/shingikai/sankoshin/hoan_shohi/denryo ku_anzen/newenergy_hatsuden_wg/pdf/014_01_00.pdf (Accessed 2021. 11. 10)
- 経済産業省:令和元年台風 19 号におけるソーラーパネルの被害状況一覧, https://www.meti.go.jp/shingikai/sankoshin /hoan_shohi/denryoku_anzen/newenergy_hatsuden_wg/pdf/01 9_s03_01.pdf (Accessed 2021. 11. 10)
- 経済産業省:浸水した太陽光発電設備による感電事故防止について(注意喚起), https://www.meti.go.jp/policy/safety _security/industrial_safety/oshirase/2019/10/20191031.html (Accessed 2021.11.10)
- 環境省:太陽光発電施設等に係る環境影響評価の基本的 考え方に関する検討会報告書, http://www.env.go.jp/press/ files/jp/110948.pdf (Accessed 2021. 11. 10)
- 6) Yu, Jiafan, Zhecheng Wang, Arun Majumdar, and Ram Rajagopal: DeepSolar: A machine learning framework to efficiently construct a solar deployment database in the United States, Joule, 2 (12), pp. 2605–2617, 2018, https://doi.org/10.1016/j. joule.2018.11.021.
- 7) V. Golovko, A. Kroshchanka, S. Bezobrazov, A. Sachenko, M. Komar and O. Novosad: Development of solar panels detector, 2018 International Scientific-Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T), Kharkiv, Ukraine, pp. 761–764, Oct. 2018, https://doi.org/10.1109/INFOCOMMST.2018.8632132.
- 8) V. Golovko, S. Bezobrazov, A. Kroshchanka, A. Sachenko, M.

Komar and A. Karachka: Convolutional neural network based solar photovoltaic panel detection in satellite photos, 2017 9th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS), Bucharest, Romania, pp. 14–19, Sep. 2017, https://doi.org/10.1109/IDAACS.2017.8094501.

- 9) J. Yuan, H. L. Yang, O. A. Omitaomu and B. L. Bhaduri: Large-scale solar panel mapping from aerial images using deep convolutional networks, IEEE International Conference on Big Data (Big Data), Wachington D.C., USA, pp. 2703–2708, Dec. 2016, https://doi.org/10.1109/BigData.2016.7840915.
- 10) J. M. Malof, L. M. Collins and K. Bradbury: A deep convolutional neural network, with pre-training, for solar photovoltaic array detection in aerial imagery, 2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Texas, USA, pp. 874–877, July. 2017, https://doi.org/10.1109/ IGARSS.2017.8127092.
- 11) Malof, Jordan M., Kyle Bradbury, Leslie M. Collins, and Richard G. Newell: Automatic detection of solar photovoltaic arrays in high resolution aerial imagery, Applied energy, 183, pp. 229–240, 2016, https://doi.org/10.1016/j.apenergy.2016.08.191.
- 12) J. M. Malof, Rui Hou, L. M. Collins, K. Bradbury and R. Newell: Automatic solar photovoltaic panel detection in satellite imagery, 2015 International Conference on Renewable Energy Research and Applications (ICRERA), Palermo, Italy, pp. 1428–1431, Nov. 2015, https://doi.org/10.1109/ICRERA. 2015.7418643.
- 13) Q. Li, Y. Feng, Y. Leng and D. Chen: SolarFinder: Automatic Detection of Solar Photovoltaic Arrays, 2020 19th ACM/IEEE International Conference on Information Processing in Sensor Networks (IPSN), Sydney, Australia, pp. 193–204, Apr. 2020, https://doi.org/10.1109/IPSN48710.2020.00024.
- 14) M. S. Karoui, F. z. Benhalouche, Y. Deville, K. Djerriri, X. Briottet and A. L. Bris: Detection and area estimation for photovoltaic panels in urban hyperspectral remote sensing data by an original NMF-based unmixing method, IGARSS 2018–2018 IEEE International Geoscience and Remote Sensing Symposium, Valencia, Spain, pp. 1640–1643, July. 2018, https://doi.org/10.1109/IGARSS.2018.8518204.
- 15)中村良介,石井智大,野里博和,坂無英徳,望月義彦, 飯塚里志,石川 博:地球観測衛星画像上の地物自動認 識,人工知能学会全国大会論文集 第 30 回全国大会 (2016),JSAI2016 巻, pp. 1B24, June. 2016.
- 16) リモートセンシング学会(編):基礎からわかるリモート センシング,理工図書,東京,2011.
- 17) P. Iervolino, R. Guida and P. Whittaker: A novel ship-detection technique for Sentinel-1 SAR data 2015 IEEE 5th Asia-Pacific Conference on Synthetic Aperture Radar (APSAR), pp. 797– 801, Sep. 2015, https://doi.org/10.1109/APSAR.2015.7306324.
- 18) Aayush Grover1, Shashi Kumar, and Anil Kumar: SHIP DETECTION USING SENTINEL-1 SAR DATA, ISPRS TC V Mid-term Symposium "Geospatial Technology – Pixel to People", Dehradun, India, pp. 317–324, Nov. 2018, https://doi. org/10.5194/isprs-annals-IV-5–317–2018.
- 19) Kang M, Ji K, Leng X, Lin Z: Contextual Region-Based Convolutional Neural Network with Multilayer Fusion for SAR

Ship Detection, Remote Sensing, 9 (8), pp. 860, 2017, https:// doi.org/10.3390/rs9080860.

- 20) He C, Tu M, Xiong D, Tu F, Liao M: Adaptive component selection-based discriminative model for object detection in high-resolution SAR imagery, ISPRS International Journal of Geo-Information, 7 (2), pp. 72, 2018, https://doi.org/10.3390/ ijgi7020072.
- 21) Zhixin Qi and Anthony Gar-On Yeh and Xia Li and Zheng Lin: A novel algorithm for land use and land cover classification using RADARSAT-2 polarimetric SAR data, Remote Sensing of Environment, 118, pp. 21–39, 2011, https://doi.org/10.1016 /j.rse.2011.11.001.
- 22) Duong PC, Trung TH, Nasahara KN, Tadono T: JAXA Highresolution land use/land cover map for central Vietnam in 2007 and 2017, Remote Sensing, 10 (9), pp. 1406, 2018, https://doi. org/10.3390/rs10091406.
- 23) Adrian Werner, Christopher D Storie and Joni Storie: Evaluat-

〔著者紹介〕

●嶌田 将貴(シマダ ショウキ)



2020 年筑波大学生命環境学群生物資源学 類卒業。現在,東京大学大学院工学系研 究科社会基盤学専攻修士課程 2 年。衛星 画像と機械学習を利用したソーラーパネ ルの検出に関する研究に取り組んでいる。 専門は環境リモートセンシング。日本リ モートセンシング学会会員。 ing SAR-optical image fusions for urban LULC classification in Vancouver Canada, Canadian Journal of Remote Sensing, 40 (4), pp. 278–290, 2014, https://doi.org/10.1080/07038992.2014. 976700.

- 24) H. Zhang, Y. Zhang and H. Lin: Urban land cover mapping using random forest combined with optical and SAR data, 2012 IEEE International Geoscience and Remote Sensing Symposium, Munich, Germany, pp. 6809–6812, Nov. 2012, https:// doi.org/10.1109/IGARSS.2012.6352600.
- 25) D. J. Weydahl: Analysis of ERS SAR coherence images acquired over vegetated areas and urban features, International Journal of Remote Sensing, 22 (14), pp. 2811–2830, 2010, https://doi.org/ 10.1080/01431160010006412.
- 26) Rao Zahid Khalil and Saad-ul-Haque: InSAR coherence-based land cover classification of Okara, Pakistan, The Egyptian Journal of Remote Sensing and Space Science, 21, pp. S23– S28, 2018, https://doi.org/10.1016/j.ejrs.2017.08.005.

●竹内 渉 (タケウチ ワタル)



1999 年東京大学工学部土木工学科卒業。 2004 年東京大学大学院工学系研究科博士 課程修了(社会基盤工学専攻,博士(工 学))。同年,東京大学生産技術研究所入 所,特任研究員,特任助手,講師,准教 授を経て 2018 年より人間・社会系部門教 授。2007-2009 年アジア工科大学院(AIT,

タイ王国) 客員講師, JICA 専門家として派遣。2010-2012 年 (独)日本学術振興会 JSPS バンコク研究連絡センター長。 2017-2019 年 内閣府 政策統括官(科学技術・イノベーショ ン担当)付 上席調査員(総合科学技術会議・イノベーション 会議事務局 エネルギー・環境担当)。専門は環境・災害リ モートセンシング。日本リモートセンシング学会,日本写真 測量学会,米国写真測量学会(ASPRS),米国物理学連合 (AGU)の各会員。