

地図情報整備効率化のための技術開発 －衛星画像及び AI 画像分析技術を用いた変化抽出技術の開発－

実施期間 令和 5 年度～令和 6 年度
基本図情報部地図情報技術開発室 長野 玄
桑村 亜実 野口 真弓

1. はじめに

国土地理院では、面的更新と迅速更新の二つの手法を組み合わせ、電子国土基本図を更新している。面的更新を実施する範囲は、前回更新からの経過年数や当該範囲の実際の地物の変化量等に基づいて決定している。このうち地物の変化量については、更新に用いる地図情報や空中写真と既存の地図情報を目視で比較することで把握しているため、多大な労力と時間を要している。地物の変化量の大きい箇所を効率的な把握方法が、全国的な変化に基づいた計画的な更新を実施する上での課題となっている。このため全国的な地物変化をヒートマップ状に把握することを目的として、国土地理院では、令和 5 年度より、二時期の中分解能衛星画像を用いた AI の画像分析による変化抽出技術の開発を実施している（桑村ほか、2024a, 2024b）。

本報告では、令和 5 年度に開発した中分解能衛星画像を用いて変化を含む領域を抽出する技術に対して、抽出精度を向上するために行った改良の成果と、中分解能衛星画像を用いて把握した変化を含む領域に対して、より詳細な変化箇所を把握することを目的として令和 6 年度に新たに実施した高分解能衛星画像を用いた地物単位の変化抽出技術の開発成果を報告する。

2. 中分解能衛星画像を用いた変化抽出技術の改良

2.1 中分解能衛星画像による変化抽出技術を用いたシステムの概要

令和 5 年度に開発した中分解能衛星画像による変化抽出技術を用いたシステムの概略を図-1 に示す。詳細は令和 5 年度調査研究年報で報告した。

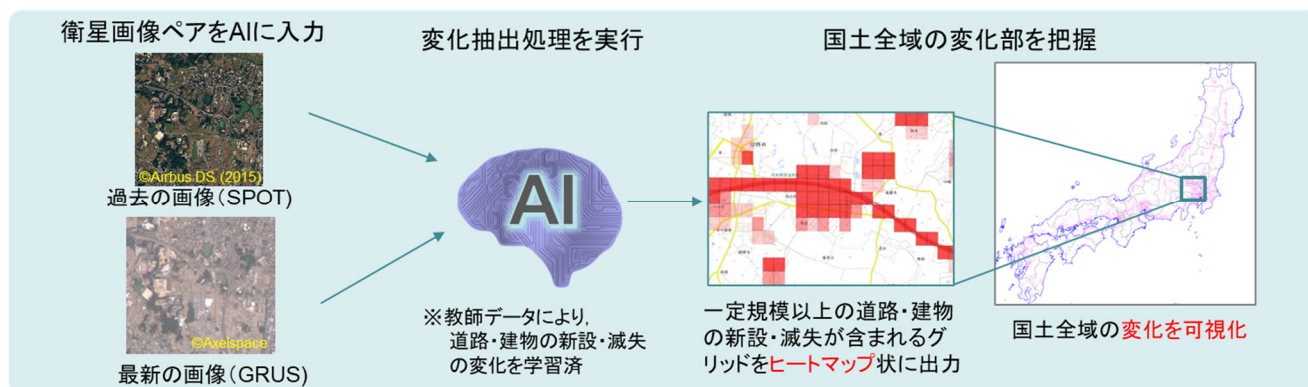


図-1 令和 5 年度に開発した中分解能衛星画像による変化抽出技術を用いたシステム

システムでは、「建物新設」、「建物減失」、「道路新設」及び「道路減失」の 4 カテゴリーの変化を学習させた AI モデルに対し、同一地域を観測した過去と最新の衛星画像ペアを入力し、これを基に AI が変化抽出処理を実行することで、一定の規模以上の建物及び道路の変化が含まれる箇所を 128 pix ×

128 pix のグリッド単位でヒートマップ状に出力する。

AI モデルは、深層学習の一手法である **Siamese Network model** を使用した。本手法は、同じ構造を持つニューラルネットワークに二つの異なる入力を与え、出力される特徴ベクトルを比較することで二つの入力間の類似度を判定する手法であり、1990 年代初頭に発表されて以降、主に画像分類において広く使用されている (Koch et al., 2015)。一般的な画像分類 (画像のクラス分類) では与えられた画像がどのクラスに属するかを学習する必要があるが、学習に当たってクラスごとに多数のデータが必要となる一方で、**Siamese Network model** では画像が何のクラスに属するかではなく画像の類似度を学習するため、画像ペアに対して「同じ」か「異なる」のラベルがあれば学習が可能である。学習に用いるデータが少量である場合においても、他の画像分類手法よりも有効に学習及び推論が可能な手法であるとされていることから、本研究における AI モデルとして採用した。AI モデルに対して学習データを基に学習を繰り返すことでパラメータの自動調整を行い、その後、作業者によるコード修正を繰り返すことで、AI モデルの構造や学習方法の細かな調整を実施した。

AI による変化抽出処理では、AI による推論結果をグリッド単位で **GeoJSON** 形式のファイルで出力することが可能である。ファイルの属性には、AI がどのくらいの確からしきで変化を抽出したかを示す確信度が 0 から 1 の範囲内で含まれており、この値が 1 に近いほど、AI がより確からしい変化として推論したことを示す。

変化抽出には、観測時期が異なる二時期の光学衛星画像を使用した。地物の変化前を示す過去の画像には、フランスの **Airbus Defence and Space** 社が運用する光学衛星 **SPOT-6** 及び **SPOT-7** (以下「**SPOT**」という。) の分解能 1.5 m の衛星画像を使用し、地物の変化後を示す最新の画像には、日本の **Axelspace** 社が運用する光学衛星 **GRUS-1** (以下「**GRUS**」という。) の分解能 2.5 m の衛星画像を使用した。

2.2 令和 5 年度に開発した中分解能衛星画像を用いた変化抽出技術の課題

令和 5 年度に開発した AI モデルによって、全国の二次メッシュのうち市街地を中心に抽出した 1,335 メッシュの範囲に対する推論を実行し、ヒートマップ状に建物新設箇所を出力した。AI による推論を定性評価した結果、地物変化がない箇所を誤って過抽出する例や地物が増えている箇所の抽出漏れの例が見られた。過抽出は、同一グリッド内に建物と裸地を複合的に含む箇所及び大規模な駐車場等に、抽出漏れは、森林、畑、造成中の輝度が高い裸地から宅地又は大規模な建物に変化した箇所に確認された。こうした課題は、学習時に用いたデータに該当の特徴を持つ地物が不足していることに起因するものと推測されたことから、令和 6 年度に、これらの地物を含む学習データを追加する等の改良を行った。

2.3 中分解能衛星画像を用いた変化抽出技術の改良の概要

2.2 で述べた令和 5 年度の課題に対して、学習データの追加、入力画像の前処理及び学習モデルの調整により改良を図り、その効果を精度評価指標を用いて定量的に評価した。

2.3.1 学習データの追加

令和 5 年度の技術開発では山間部や都市部などを含めた 16 メッシュの学習データを与えていたが、以下の 2 種類の手法によって学習データを拡充し、合計 197 メッシュの学習データを得た。

- ・作業者が GIS ソフトを用いて二時期の衛星画像から変化地物を目視判読し、変化した地物を囲むポリゴンを作成する。
- ・令和 5 年度に開発したシステム上で、出力された推論結果を編集し、正しい地物変化の情報を属

性に与えたファイルを作成する。

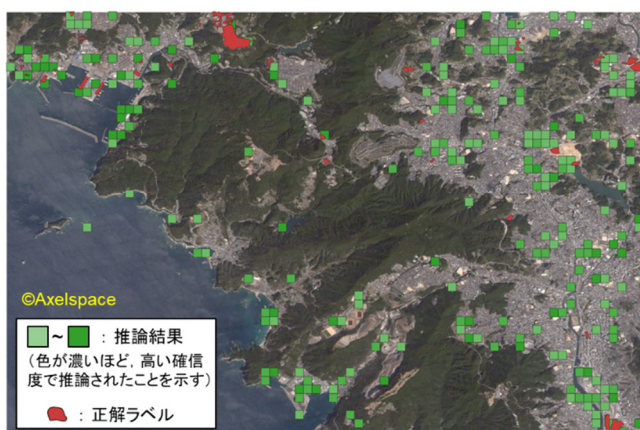
追加した学習データは、令和5年度の推論において抽出漏れが見られた、森林や畑、造成中の輝度が高い裸地から宅地又は大規模な建物に変化した箇所を重点的に含めるように選定した。

2.3.1.1 テスト地区（492916）における検証結果

学習データの追加による効果を検証するため、学習データ追加前と追加後の AI モデルによって、同一の地区（二次メッシュ番号：492916）を対象とした推論を実施し、推論結果を比較した。学習データ追加前後の推論結果を図-2 に示す。

図-2 の左図は令和5年度の AI モデルによって、右図は令和6年度の AI モデルによって、それぞれ建物新設として推論されたグリッドを表示している。いずれの図も、確信度 0.5 以上のグリッドのみを表示し、より高い確信度の推論結果ほどグリッドの色を濃く表示している。また、作業者によって建物新設があると判読されたポリゴンを赤色の正解ラベルとして表示している。

令和5年度のAIモデルにおける推論結果
(学習データ追加前, 建物新設の確信度0.5以上を表示)



令和6年度のAIモデルにおける推論結果
(学習データ追加後, 建物新設の確信度0.5以上を表示)

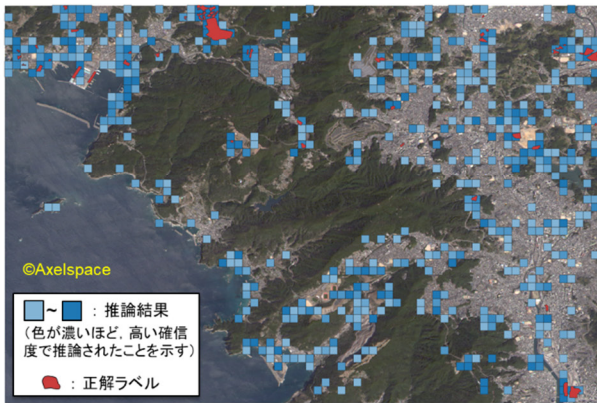


図-2 テスト地区（492916）における学習データ追加の検証結果（同じしきい値で表示）

図-2 に対する定性的な評価として、学習データを追加することで、同じ確信度（=0.5）をしきい値として表示した場合に建物新設と推論されるグリッド数が多くなったこと、ただし、その多くは正解ラベル以外を建物新設として推論している誤検出とみられることが確認された。

画像内の各グリッドには、0 から 1 までの間の数値で確信度が属性値として付与された状態で出力され、表示上の確信度のしきい値を上げることで、画像内で表示されるグリッド数は減少する。令和6年度の AI モデルによる推論結果に対して、推論結果が正解ラベルとより近くなるよう、表示上のしきい値を 0.5 から 0.8 に変化させた結果を図-3 に示す。図-3 の右図では、実際には後述の精度評価指標を用いて定量的な評価を確信度のしきい値ごとに行い、最も良い結果が得られた（=推論結果が正解と最も近くなる）しきい値として 0.8 を設定した。

令和6年度のAIモデルにおける推論結果
(学習データ追加後, 建物新設の確信度0.5以上を表示)



令和6年度のAIモデルにおける推論結果
(学習データ追加後, 建物新設の確信度0.8以上を表示)


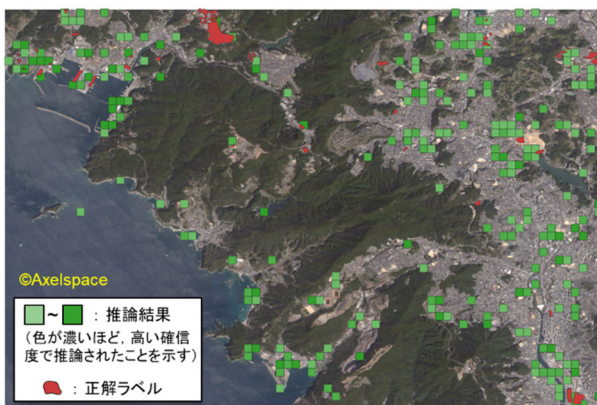


図-3 テスト地区 (492916) における令和6年度の推論結果 (表示上のしきい値を変化)

図-2の左図及び図-3の右図を並べた図を図-4に示す。図-4において、学習データの追加によって、正解ラベルに近いグリッドが、より高い確信度で推論されるようになったことが定性的に確認された。

令和5年度のAIモデルにおける推論結果
(学習データ追加前, 建物新設の確信度0.5以上を表示)



令和6年度のAIモデルにおける推論結果
(学習データ追加後, 建物新設の確信度0.8以上を表示)



図-4 テスト地区 (492916) における学習データ追加の検証結果 (モデルごとにしきい値を設定)

さらに、定量的な精度評価のため、AIの精度を評価する際に広く用いられている混同行列を使用し、精度評価指標を求めた。また、混同行列から、AIが”変化あり”と推論したグリッドのうち”変化あり”正解グリッドと重複する割合を表す適合率(a), ”変化あり”正解グリッドのうちAIが”変化あり”と推論したグリッドと重複する割合を表す再現率(b), 適合率と再現率の調和平均で表されるF値(c)を算出した。混同行列の概念図と適合率, 再現率及びF値の算出式を以下の図-5に示す。

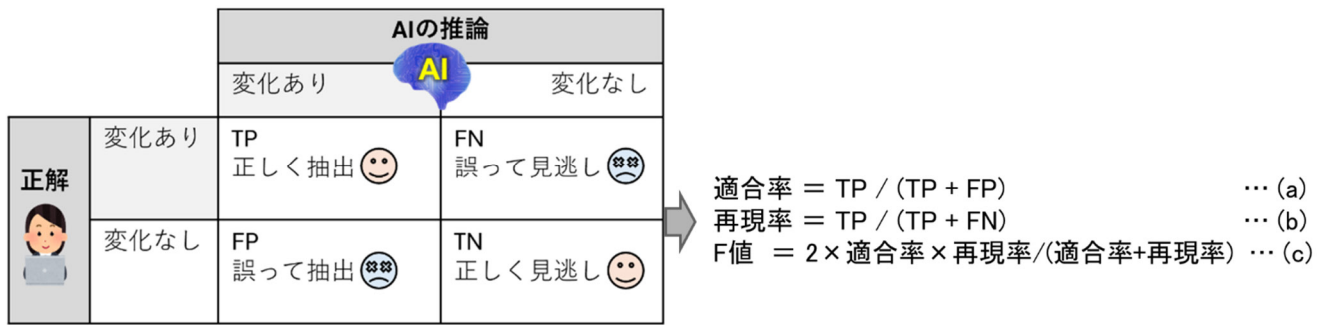



図-5 混同行列の概念図と適合率、再現率及びF値の算出式

学習データ追加前と追加後の AI モデルによる推論結果（確信度はモデルごとに設定）の精度評価指標を図-6 に示す。この結果より、学習データを追加することで精度評価指標（適合率、再現率、F値）が増加する傾向が確認された。なお、本技術の開発に当たっては、推論結果を地図更新フローの初期段階で利用するという観点から、誤抽出は許容したとしても見逃しを少なくなることを重視し、適合率よりも再現率が高くなるように学習パラメータを調整した。



※「建物変化」は建物新設又は滅失のいずれか、「道路変化」は道路新設又は滅失のいずれか、「地物変化」は「建物変化」又は「道路変化」のいずれかが生じている場合を指す。

図-6 学習データ追加前後の AI モデルによる推論結果の精度評価指標

2.3.1.2 全国 4,871 メッシュにおける推論

学習データ追加後の AI モデルを用いて、全国の 4,871 メッシュに対して建物新設の有無を推論した結果を図-7 に示す。図-7 は、AI モデルが建物新設の確信度が 0.8 以上であると推論した結果を基に、QGIS のツールを用いて該当グリッドの密度を求めたヒートマップを表している。赤色が濃い箇所ほど確信度が 0.8 以上の建物新設グリッドの密度が高いことを示しており、二時期の間で新設された建物がある可能性が高いと推測される。この結果は、面的更新の事業計画を検討する際の参考資料として活用した。

また、二次メッシュごとに確信度 0.8 以上の建物新設のグリッド数を算出し、二次メッシュ当たりの該当グリッド数が多い上位 5 メッシュの範囲並びにそのうち最もグリッド数が多い香川県高松市の二次メッシュ（二次メッシュ番号：513430）における 2015 年撮影の SPOT 衛星画像、2023 年撮影の GRUS 衛星画像及び GRUS 衛星画像に AI モデルを用いた推論結果を重ね合わせた結果を図-8 に示す。

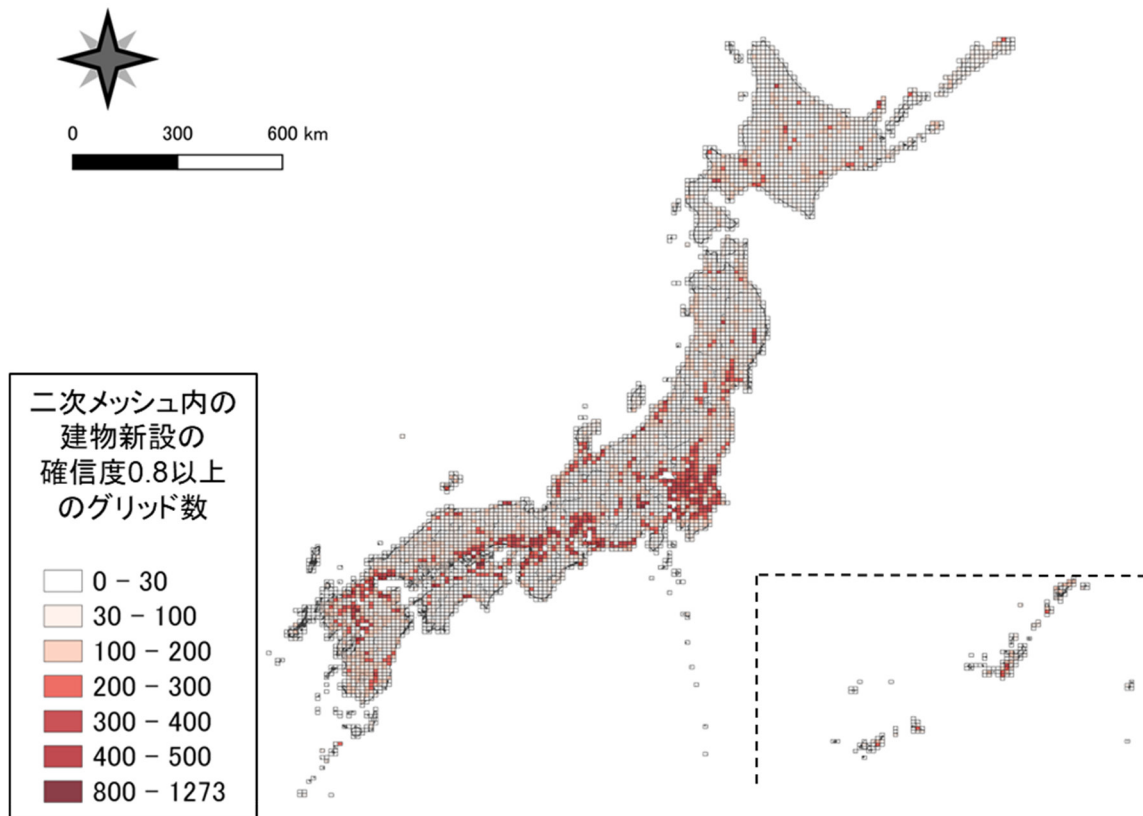


図-7 学習データ追加後のAIモデルを用いた全国の建物新設の推論結果のヒートマップ

二次メッシュ当たりの「建物新設」の確信度0.8以上のグリッド数が多い上位5メッシュ

二次メッシュ番号	確信度0.8以上のグリッド数	範囲
513430	1,273	香川県高松市
533834	1,201	山梨県甲府市
513337	871	香川県高松市
493064	843	福岡県八女市
513431	743	香川県さぬき市


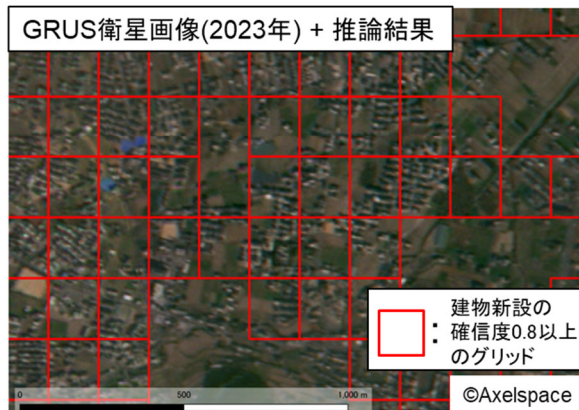


図-8 二次メッシュ当たりの建物新設のグリッド数が多い上位5メッシュ（左上）並びに香川県高松市におけるSPOT衛星画像（右上）、GRUS衛星画像（右下）及び建物新設のAI推論結果（左下）

図-8 の範囲で衛星画像を判読した結果として、大規模な宅地造成は確認されなかったものの、建物が散在的に新設されていることが確認された。二次メッシュ当たりの建物新設グリッド数が多いと出力されたメッシュにおいて、局所的な変化だけでなく、メッシュ全体の平均的な変化も捉えられていると推測される。これは本モデルの開発目的である、地物の変化量の大きい箇所の効率的な把握に寄与するものである。

2.3.2 入力画像の前処理及び学習モデルの調整

2.3.1 で言及した学習データの追加に加え、入力画像の前処理や AI モデルの学習パラメータ調整によるシステム改良を実施した。具体的な改良内容を以下に記載した。

①ペア画像間の画質の統一度の向上

学習データのデータセット全体に対してではなく、入力する二時期のペア画像に対して画質の正規化を行うことで、ペア画像間の画質の統一度が向上するよう処理した。

②汎化性能を向上させるためのデータ処理上の工夫

学習データの衛星画像に対して、人工的に明るさの変化、回転・反転を加えた画像ペアも作成して学習させる処理を行った。「回転・反転を加える」とは、元の画像ペアに対して、それぞれ同じ角度（90度、270度など）だけ回転させる又は左右・上下反転させることで、元の画像と異なる向きのデータを作成することを指す。画像に対して与えられる明るさの変化、回転・反転の度合いは学習回数に応じて異なる値が自動的に割り振られ、ペア画像間では同じように明るさの変化、回転・反転が加えられるよう処理した。

③変化あり / なしのデータ数の不均衡に対する対応

本技術開発で対象とする地物変化は、「変化あり」が「変化なし」に比べてサンプル数が非常に少ないため、こうしたデータの不均衡を考慮した損失関数である **Focal loss** を採用するよう改良した。

損失関数とは、AI モデルの出力する結果と AI モデルが目指す正解の差を表すために用いられる指標であり、損失関数がより小さくなるようなパラメータを探索することで、AI における学習が進められる。**Focal loss** とは、損失関数の中でも、より難易度の高いサンプルに対して重みを増加させる損失関数である。サンプル数が少ないクラスのサンプルは、学習時に正解率が上がりやすく分類が難しい傾向にあるため、**Focal loss** により小規模サンプルの学習を相対的に強調することで、データ不均衡の影響を緩和しながら効果的な学習を行うことが可能となる。

これらの改良の効果を検証するため、テスト地区（メッシュ番号：492916）を対象として、2.3.1.1 と同様に、改良前後のシステムによる変化抽出の推論（図-6 と同様に、確信度はモデルごとに設定）を実施した。その結果を図-9 に示す。図-9 の左側（学習モデル改良前）は、図-6 の右側と同じ図である。学習モデル改良の効果として、適合率及び F 値が上昇することが確認された。

学習モデル改良前のAIモデルによるテスト地区（492916）の推論結果の精度評価指標（確信度の閾値：0.8）

label	適合率(%)	再現率(%)	F値
建物変化	34.7	48.4	40.4
道路変化	10	4.6	6.3
地物変化	35.0	46.0	39.8

学習モデル改良後のAIモデルによるテスト地区（492916）の推論結果の精度評価指標（確信度の閾値：0.35）

label	適合率(%)	再現率(%)	F値
建物変化	72.7	45.2	55.7
道路変化	62.5	22.7	33.3
地物変化	74.1	45.3	56.3

※「建物変化」は建物新設又は滅失のいずれか、「道路変化」は道路新設又は滅失のいずれか、「地物変化」は「建物変化」又は「道路変化」のいずれかが生じている場合を指す。

図-9 学習モデル改良前後の AI モデルによる推論結果の精度評価指標

2.3.3 令和6年度に実施した中分解能衛星画像を用いた変化抽出技術の改良のまとめ

令和5年度の成果及び課題に対して、学習データの追加、入力画像の前処理及び学習モデルの調整により改良を図った。また、精度評価指標を用いた評価により抽出精度が向上したことを確認した。

3. 高分解能衛星画像を用いた変化抽出技術の開発

3.1 高分解能衛星画像を用いた変化抽出技術の概要

電子国土基本図の整備における図化作業への活用を目的に、分解能が1mより小さい高分解能の衛星画像を使用し、AIが変化抽出処理を実行することで、一定の規模以上の建物及び道路の変化箇所を地物単位で出力するシステムを開発した。

地物単位での変化箇所の抽出に当たっては、高解像度の変化検出を得意とする HRNet (Sun et al., 2019) を応用した変化検出モデルを使用した。抽出する変化部は、中分解能の衛星画像と同じく、「建物新設」、「建物滅失」、「道路新設」及び「道路滅失」の4カテゴリに分類した。抽出する目安は、分解能0.8m程度の衛星画像から判別可能な地物を基に決定し、おおむね200m²以上の建物の新設及び滅失並びに幅員6m以上かつ延長がおおむね50m以上の道路の新設及び滅失等とした。

また、モデル上の制約により、複数のラベルが同じ場所で重複する（建物新設と道路滅失が同時に発生している等）場合においても付与できるラベルが1種類となるため、同一場所で複数の事象が発生している場合は、道路新設 > 建物新設 > 道路滅失 > 建物滅失の優先順位でラベルを付した。

3.2 使用した衛星画像の概要

変化抽出には、観測時期が異なる二時期の光学衛星画像を使用した。二時期の画像はいずれもアメリカの Planet Lab 社が運用する SkySat 衛星の分解能0.8mの衛星画像を使用した。SkySat 衛星は質量110kg程度の小型の光学衛星で、2013年の第一号機の打ち上げ以後、現在までに合計21機が打ち上げられており、複数の機体を一体的に運用する「衛星コンステレーション」と呼ばれる仕組みによって、高頻度の観測を実現している。ALOS-3の後継衛星として、複数の小型衛星による衛星コンステレーションが想定されていたため、同様の条件で既に運用されていた SkySat 衛星を技術開発の対象とした。

3.3 AIモデル開発における対象地域

変化抽出の対象となる地物（建物及び道路）が一定以上存在し、SkySat画像のアーカイブ画像が二時期存在する地域を選定し、山間部や都市部などを含めた19地域の衛星画像を用いてモデルの学習を実施した。

3.4 テスト地区（神奈川県厚木市周辺）での推論結果

AIモデルの学習に用いていない神奈川県厚木市周辺の SkySat 画像ペアに対して、開発した AI モデルを用いて地物変化の推論を行った結果を図-10 に示す。図-10 では、左上に 2019 年撮影の画像、右上に 2023 年撮影の画像、左下に AI モデルを用いた推論結果、右下に作業者によって判読して作成した正解ラベルを示す。この図の範囲では大規模商業施設や物流倉庫が新設され、周囲に道路も新設されている。

定性的な評価として、目視でも隣り合うピクセル間の色調差が明瞭で変化が目立つ箇所は、地物が混み合っている精度良く検出ができていないこと、建物のみではなく道路の新設及び滅失も一定程度検出できていることが確認された。また、図-10 の範囲以外では、高層建築物の側面が写り込み、他の建物として誤認識される事例（図-11）が確認された。このような事例を収集し、どのような特徴の箇所で検出が困難か分析することにより、今後の精度向上の方策を検討する。

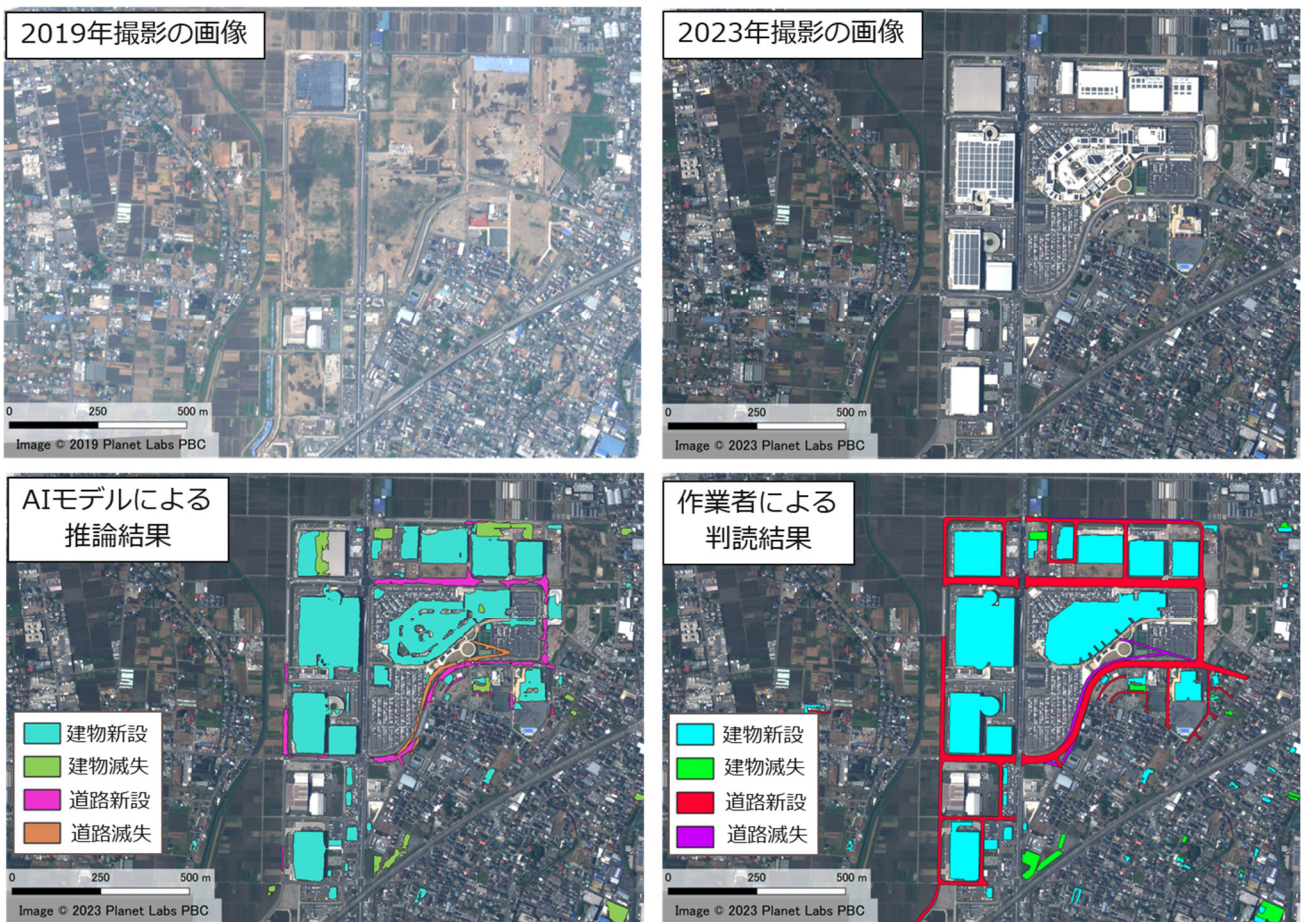


図-10 神奈川県厚木市周辺の SkySat 画像ペアに対する地物変化の推論結果




図-11 高層建築物の側面が写り込み、他の建物として誤認識された事例

4. 結論

令和5年度に開発した中分解能衛星画像を用いて変化を含む領域を抽出する技術に対して、抽出精度を向上するために改良を行い、一定の精度向上が確認できたことから、面的更新の事業計画の策定に活用した。また、高分解能衛星画像を用いた地物単位の変化抽出技術の開発も行った。これらの結果を基に、更なる精度向上に取り組み、地図の自動図化等、地図作成を効率化するための取組を進める。

参考文献

- G. Koch, R. Zemel and R. Salakhutdinov (2015) : Siamese neural networks for one-shot image recognition, ICML Deep Learning Workshop, Vol. 2.
- 桑村亜実, 佐々木励起, 南秀和 (2024) : 中分解能衛星画像及び AI 画像分析技術を用いた変化部抽出技術の開発, 令和5年度調査研究年報, 50-56.
- 桑村亜実, 長野玄, 野口真弓 (2024) : 衛星画像及び AI を用いた変化抽出手法の検討, 日本写真測量学会 令和6年度秋季学術講演会論文集, 193-196.
- K. Sun, B. Xiao, D. Liu and J. Wang (2019) : Deep High-Resolution Representation Learning for Human Pose Estimation, <https://arxiv.org/abs/1902.09212> (accessed 4 April 2025).