口頭発表

2025年11月1日(土) 11:00 ~ 12:20 | C会場(共通教育棟 D21番教室)

[C2] 土地利用分析

司会：堤田 成政

11:00 ~ 11:20

[C2-01] 建物外観画像と深層学習を用いた建物単位の空き家判定手法の開発

*奥村 太郎[1]、寺田 遣都[1]、秋山 祐樹[1]、宮田 涼[1] (1. 東京都市大学)

11:20 ~ 11:40

[C2-02] 衛星画像と機械学習を用いた土地利用分類に基づく開発適地の自動選定手法の構築

*久保田 涼太[1]、寺田 遣都[1]、秋山 祐樹[1] (1. 東京都市大学)

11:40 ~ 12:00

[C2-03] 土地利用の変遷に着目した局所人口分布の空間変動の分析

*白石 彩乃[1]、熊谷 樹一郎[1]、卯田 航平[1] (1. 摂南大学)

12:00 ~ 12:20

[C2-04] マルチスペクトル衛星データと地域特性の統合による建物構造・築年次推定

*荻野 光司[1]、大佛 俊泰[1] (1. 東京科学大学)

©一般社団法人地理情報システム学会

建物外観画像と深層学習を用いた建物単位の空き家判定手法の開発

奥村太郎*・寺田遣都・秋山祐樹***・宮田涼******

Development of a Building-Level Vacant House Detection Method Using Exterior Images and Deep Learning

Taro Okumura*, Kento Terada**, Yuki Akiyama***, Ryo Miyata******

Abstract: This study proposes a building-level method for vacant house detection using deep learning and exterior images captured with low-cost 360-degree cameras. Tanabe City (Wakayama Prefecture) and Maebashi City (Gunma Prefecture) were selected as case studies. A deep learning model based on VGG-16 was applied to classify buildings as vacant or non-vacant. Using only the Tanabe dataset, the model achieved 77.4% accuracy, though recall for vacant houses was limited to 42.9%. Incorporating Maebashi data improved performance to 79.5% accuracy and 51.8% recall. Extrapolation tests revealed strong regional effects: the Tanabe-trained model failed to detect most vacant houses in Maebashi (recall 0.8%), while the Maebashi-trained model detected more vacant houses in Tanabe (recall 77.9%) but often misclassified non-vacant houses (recall 38.4%). These results highlight the impact of data imbalance and regional characteristics. Expanding datasets and improving preprocessing will be essential to enhance generalization and support cost-effective municipal surveys for vacant house management.

Keywords: 深層学習（deep learning），空き家（vacant house），建物外観（building exterior），360 度カメラ（360 degree camera），空間結合（spital integration）

１．はじめに

１.１　研究背景

近年，日本では人口減少を背景に，全国的に空き家が増加し続けており，最新の住宅・土地統計調査（2024）によると 2023 年時点での全国における空き家の数は約 900 万戸，空き家率は 13.8%と過去最多となっている．特に管理水準の低下した空き家は，倒壊の危険性や景観の悪化といった様々な悪影響を周囲に及ぼす恐れがある．

こうした背景から空き家対策の推進を目的として 2015 年 5 月より「空き家対策の促進に関する特別措置法」が施行され，全国の自治体には空き家の所在や所有者の把握を目的とした調査が努力義務として課せられた．しかし，現状の空き家調査の手法の多くは，建物の外観を 1 棟ずつ確認する戸別目視が中心となっており，広域の調査には多くの時間と費用を要する．また戸別目視には判定基準が定められているが，調査結果は調査員の主観に左右されるため，調査結果の信頼性の担保も課題である．そのため，自治体全域の空き家の空間分布を迅速かつ安価に把握する技術が求められている．

１.２　既往研究

これまでに空き家の空間分布を把握する研究は数多く見られる．山下ほか（2015）は上下水道の使用量データを用いて，年代別に各地区の空き家数と空き家率を算出し，市域全体における空き家の発生状況及び分布を把握する手法を検討した．その結果，水道使用量データから空き家の分布や増加率を把握できることを明らかにした．また秋山ほか（2021）は，住民基本台帳や水道使用量データといった自治体が保有するデータと空き家の現地調査結果を用いて空き家の特徴を抽出し，市域全体の空き家分布推定を行っている．しかし，これらの研究で使用するデータは個人情報に該当するものも多く，その取得や活用が困難である．また，不動産登記情報を使用することで各建物の特性を詳しく把握できるが，同情報は高価かつ，使用する際に多くの制約があるため活用が難しい．

１.３　本研究の目的

そこで本研究では，既往研究で使用された制約を有するデータを用いることなく，市販の安価な 360°カメラで撮影した建物外観画像と空き家の現地調査結果を用いて

*　学生会員　東京都市大学建築都市デザイン学部（Tokyo City University）
〒158-0087　東京都世田谷区玉堤 1-28-1　E-mail：g2232019@tcu.ac.jp
**　学生会員　東京都市大学大学院総合理工学研究科（Tokyo City University）
〒158-0087　東京都世田谷区玉堤 1-28-1　E-mail：g2581638@tcu.ac.jp
***　正会員　東京都市大学建築都市デザイン学部（Tokyo City University）
〒158-0087　東京都世田谷区玉堤 1-28-1　E-mail：akiyamay@tcu.ac.jp
****非会員　元 東京都市大学建築都市デザイン学部（Tokyo City University）
〒158-0087　東京都世田谷区玉堤 1-28-1　E-mail：ryomiyataryo@gmail.com

深層学習モデルを構築し，空き家の特徴を自動抽出することで建物外観画像から空き家か非空き家かを判定する手法を開発することを目的とする．

2．本研究の対象地域と使用データ

2.1　研究対象地域の選定

研究対象地域は空き家対策に積極的かつ本研究の実施への協力が得られた和歌山県田辺市（以下「田辺市」）とした．また，平成 30 年度に実施された田辺市の空き家実態調査より，新旧様々な築年代の建物が存在し，空き家が数多く分布する，同市の江川地区と東陽地区を研究対象地域に設定した．さらに，田辺市のデータを他地域と統合した検証や外挿検証を行うため，自治体から空き家に関するデータの提供を受けた群馬県前橋市全域（以下「前橋市」）を追加の研究対象地域に設定した．

2.2　本研究で使用したデータ

本研究では表 1 に示すデータを使用した．空き家分布データは，2024 年に田辺市の江川地区および東陽地区の戸建て住宅を対象に，田辺市建設部建築課の協力の下，戸別目視で実施した現地調査により作成した．また，前橋市の空き家分布データについては，2016 年度に前橋市が空き家データベース作成を目的として実施した空き家調査結果を使用した．空き家の状態は，両市ともに A（流通中），B（流通可能），C（要補修），D（補修困難な特定空き家）の 4 段階で格納されている．一方，建物外観画像は，田辺市では現地で自動車に車載したカメラで撮影を行った（車両の両側面窓に 1 台ずつ設置）．ただし，車両走行が困難な狭小路はヘルメット上に装着した 1 台の 360°カメラを用いて徒歩で撮影を行った．図 1 に各カメラの撮影範囲の概略図を示す．一方，前橋市の建物外観画像は，株式会社ゼンリンが道路計測調査やカーナビ用道路データ収集を目的に自動車に搭載した 360°カメラから撮影した 360°画像（2018 年度）を使用した．

3．教師データの作成

3.1　空き家分布データの結合

まず，田辺市と前橋市の空き家分布データの情報を基盤地図に空間結合することで建物データを作成した．次に，建物外観画像の撮影地点の座標と，建物データの頂点座標を結合し，画像内の建物に位置情報を付与した．歪みが少ない建物外観画像を得るために，自動車から撮影する場合，カメラの方位の逆側を 0°とした時の 120°から 240°の間に位置し，撮影地点から 20m 以内の建物を対象とした．一方，ヘルメットから撮影する場合，進行方向逆側を 0°とした時の 90°または 270°の正面に位置し，撮影地点から 20m 以内の建物を対象とした（図 2）．また，前橋市では 360°カメラが計測車両の上部に装着されていることから田辺市のヘルメット撮影と同様の条件で，撮影地点から 15m 以内の建物を対象とした．また，両市とも複数の画像が対応する建物は，最も距離が近い画像のみを対象とした．その結果，田辺市では空き家の建物外観画像を 103 枚，非空き家の建物外観画像 315 枚取得できた．

表 1　本研究で使用するデータ

データ名	詳細情報
空き家分布データ	・対象地域：和歌山県田辺市・群馬県前橋市 ・データ内容：各建物の空き家判定情報
建物ポリゴンデータ	・使用データ：国土地理院基盤地図情報 ・データ内容：調査地域の全建物の位置と形状情報
住宅情報	・使用データ：株式会社ゼンリン住宅地図データベース「Zmap TOWN Ⅱ」 ・データ内容：対象地域内の全建物の位置情報および建物の重心座標
建物外観画像	田辺市： ・撮影機材：RICOH社 THETA X　・解像度：2752×5504ピクセル ・撮影間隔：6秒　・取得情報：各撮影画像の撮影地点の座標および撮影者の進行方向 前橋市： ・撮影機材：FLIR社　LadyBug3　・解像度：2700×5400ピクセル ・撮影間隔：2.5m　・取得情報：各撮影画像の撮影地点の座標および撮影者の進行方向

3.2　空き家分布データの結合

3.1 で作成した画像に対して，調査対象の建物データを用いて切り出し，分析対象となる個々の建物外観画像を作成した．まず，カメラ位値を基準に進行方向逆側にある座標と建物頂点座標が成す角度を算出し，その角度をピクセル値に変換することで建物範囲を求めた．

続いて，画像から建物領域のみを抽出し，モデル構築に利用可能な建物外観画像を作成した．まず，全画像に写るカメラ土台や計測車両内部を固定領域で除去した後，雲や日光で白く映る空の部分を除去し，画像内から建物部分のみを抽出した．さらに，前橋市の建物外観画像では，撮影地点から建物までの距離が遠く，建物が小さく写ることがあるため，最後に輝度を基準に画像内の高明度である空の部分を切り取り，建物部分のみを抽出した．以上の工程により，建物外観画像を作成した．

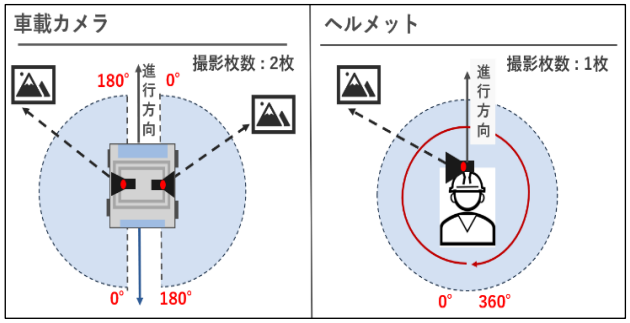


図 1　360°カメラの撮影範囲の概略図

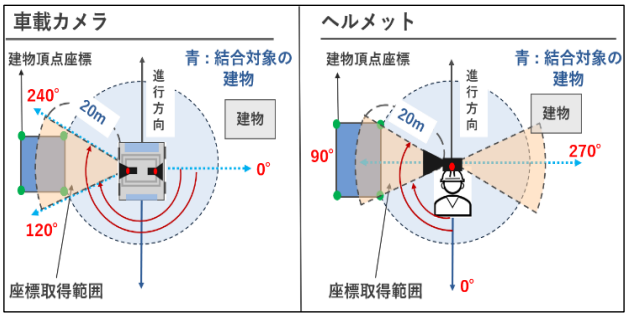


図 2　建物座標を取得する角度範囲の概略図

３.３　深層学習モデルの構築

最後に３.２で作成した建物外観画像を用いて空き家分類モデルを作成した．本研究では画像分類に優れた性能を持つ深層学習モデルである VGG-16（Simonyan et al.,2014）を用いて転移学習を行うことでモデルを構築した．建物外観画像に対し，空き家判定を受けた建物（状態 A～D 判定全ての空き家を含む）を空き家，それ以外の建物を非空き家として判定を付与した．さらに，得られた建物外観画像の 80%を訓練データ，20%をテストデータとしてランダムに分割し，モデルの学習を行った．

４．精度検証と考察

現地調査で取得した田辺市のデータのみで行った検証結果に基づく混同行列とラベル全体の評価指標による精度を表 2 に，各ラベルの評価指標による精度を表 3 に示す．表 2 の結果から 77.4%の正解率で空き家を分類することができた．また，F 値も 70.3%と特定のラベルに偏らず，安定した分類結果を得ることができた．一方，ラベルごとの評価では，非空き家の再現率 94.6%と高精度となった一方で，空き家は 42.9%と課題が残る結果となった．この結果の要因として，モデル構築時に使用した教師データにおいて，空き家のサンプル数が非空き家と比較して著しく少なかったことが挙げられる．このデータの不均衡によりモデルが非空き家を優先して予測する傾向を示したと考えられる．さらに，学習データには建物以外の要素が写り込んだ画像が多く含まれ，分類精度の低下に寄与した可能性がある．以上の結果から，教師データの増加や，360°画像から建物を切り出す精度の向上により，これらの課題に対応できるものと考えられる．

５．前橋市の建物外観画像を組み合わせた検証

本章では，前章の精度検証で見られた教師データの不足や建物切り出し精度の課題を解決するために前橋市の建物外観画像を組み合わせた検証を行う．

５.１　検証概要と方法

まず，田辺市の車載カメラから撮影した建物外観画像について，画像 1 枚につき建物 1 件のみを結合する手法からカメラの方位の逆側を 0°とした時，120°から 240°の間に位置する全ての建物を画像と結合する条件に変更した．しかしこの条件では，道路沿いの遠方に存在する建物と誤って結合される可能性があるため，撮影地点から 15m 以内に存在する建物のみに対象を限定した．この結果，空き家の画像を 122 枚，非空き家の画像を 372 枚取得することができた．次に，画像を切り出す段階では，結合により得られた画像の横幅のピクセル値を拡張する処理を行い，1 枚の画像に写る建物の面積を拡大し，特徴の抽出に有用な情報量を増加させた．さらに，モデルの学習データの充実を目的として，前橋市の建物外観画像（空き家 1,474 枚，非空き家 4,494 枚）を用いた教師データの増強を行った．このとき教師データの増強が判定精度に与える影響を検証するため，前橋市の空き家データを全て混合して検証を行った．なお，前橋市の空き家と非空き家の比率は田辺市の比率に合わせている．モデルの評価には交差検証を用いて，各データ分割における評価結果の一貫性を確認するとともに，モデル全体の健全性及び汎化性能を検証した．

５.２　精度検証と考察

前橋市のデータを組み合わせて検証した結果，79.5%の正解率が得られた．この結果から，データ量の増強によって分類精度が上昇することが確認できた．田辺市と前橋市の空き家データを混合した場合の検証結果に基づく混同行列およびラベル全体の評価指標による精度を表 4 に，各ラベルの評価指標による精度を表 5 に示す．表 4 の結果から調査地域全体の分類において，正解率 79.5%，F 値 71.1%と特定のラベルに偏らず，安定した分類結果を得ることができた．さらにラベルごとの評価を見ると，非空き家の再現率は 88.6%に対し，空き家の再現率は 51.8%であり，田辺市単体で構築した空き家分類モデルと比較して，空き家の予測精度が一定程度向上していることが確認できた．

表 2　混合行列による精度検証（田辺市のみの場合）

		非空き家	空き家
真値	非空き家	53	3
	空き家	16	12
正解率 (%)		77.4	
適合率 (%)		78.4	
再現率 (%)		68.8	
F値 (%)		70.3	

表 3　ラベル別の評価指標結果（田辺市のみの場合）

	非空き家	空き家
適合率 (%)	76.8	80.0
再現率 (%)	94.6	42.9
F値 (%)	84.8	55.8

表 4　混合行列による精度検証（前橋市を組み合わせた場合）

		非空き家	空き家
真値	非空き家	4313	553
	空き家	769	827
正解率 (%)		79.5	
適合率 (%)		72.4	
再現率 (%)		70.2	
F値 (%)		71.1	

表 5　ラベル別の評価指標（前橋市を組み合わせた場合）

	非空き家	空き家
適合率 (%)	84.9	59.9
再現率 (%)	88.6	51.8
F値 (%)	86.7	55.6

６．外挿検証

本章では，モデルの汎化性能を検証するため，田辺市と前橋市の 2 つの対象地域間での外挿検証を行った．

６.１　検証方法

外挿検証では，田辺市のデータのみを教師データとして学習したモデル（以下「田辺市モデル」）に対し，前橋市の全データを評価用データとして検証をする場合と，前橋市のデータのみを教師データとして学習したモデル（以下「前橋市モデル」）に対し，田辺市の全データを評価用データとして検証する場合の 2 通りを実施した．評価指標は第 5 章と同様に正解率，適合率，再現率，F 値を算出し，さらに混同行列により予測の傾向を分析した．

６.２　精度検証と考察

田辺市モデルの外挿検証の結果に基づく混同行列およびラベル全体の評価指標による精度を表 6 に，各ラベルの評価指標による精度を表 7 に示す．表 6 の結果から正解率が 75.1%，F 値が 43.7%を得ることができた．ラベルごとの評価を見ると，非空き家の再現率は 99.4%に対し，空き家の再現率は 0.8%と著しく低く，田辺市モデルは前橋市のほとんどの空き家を非空き家と誤分類される傾向が確認された．

前橋市モデルの外挿検証の結果に基づく混同行列およびラベル全体の評価指標による精度を表 8 に，各ラベルの評価指標による精度を表 9 に示す．表 8 の結果から正解率が 48.2%，F 値が 47.7%を得ることができた．ラベルごとの評価を見ると非空き家の再現率は 38.4%と低かったが，空き家の再現率は 77.9%と比較的高く，前橋市モデルは田辺市の空き家を捉える傾向が強い一方で，非空き家の誤分類が多く発生した．以上のことから外挿検証の結果，両ケースとも交差検証時と比較し，精度は大きく低下した．これは，前橋市は太平洋戦争末期の空襲で市街地の大部分が焼失し，その後に再建された建物が多く，またその後も建物の更新が数多く見られる都市であることに対し，田辺市は空襲を受けておらず，戦前からの古い建物が数多く現存しているという地域差による影響が顕著に現れた結果であると考えられる．

表 6　混合行列による精度検証（田辺市モデル）

		非空き家	空き家
真値	非空き家	4468	26
	空き家	1462	12
正解率 (%)		75.1	
適合率 (%)		53.5	
再現率 (%)		50.1	
F値 (%)		43.7	

表 7　ラベル別の評価指標（田辺市モデル）

	非空き家	空き家
適合率 (%)	75.3	31.6
再現率 (%)	99.4	0.8
F値 (%)	85.8	1.6

表 8　混合行列による精度検証（前橋市モデル）

		非空き家	空き家
真値	非空き家	143	229
	空き家	27	95
正解率 (%)		48.2	
適合率 (%)		56.7	
再現率 (%)		58.2	
F値 (%)		47.7	

表 9　ラベル別の評価指標（前橋市モデル）

	非空き家	空き家
適合率 (%)	84.1	29.3
再現率 (%)	38.4	77.9
F値 (%)	52.8	42.6

７．おわりに

本研究では田辺市を対象に，市販の安価な 360°カメラで撮影した建物外観画像を用いて，建物単位で空き家判定を行う手法として，深層学習による空き家分類モデルの構築および精度検証を行った．その結果，田辺市単体では 77.4%の正解率で空き家の判定が可能であることが確認されたが，空き家の再現率は低く，改善の余地があることが分かった．さらに，前橋市の建物外観画像を組み合わせて交差検証を行った結果，調査地域全体では 79.5%の正解率を達成し，F 値も 71.1%を示したことから，汎用的かつ高精度に空き家分布を推定できる可能性が示された．一方，田辺市と前橋市で外挿検証を行った結果、田辺市モデルでは 75.1%，前橋市モデルでは 48.1%の正解率に留まり，いずれのモデルもラベルごとの精度に偏りが生じ，モデルの性能低下が確認された．

今後は，外挿検証において 4 段階に分けられた空き家のうち，まずは C（要補修）と D（補修困難な特定空き家）といった対応が必要な空き家を判定するモデルを構築し，段階的に分類項目を拡張していくことで精度の向上を目指す．また，別都市のデータを加えてモデルの適用範囲を拡張し，高い汎用性を持つモデルの構築を進めることで，自治体における効率的かつ実用的な空き家対策調査手法としての可能性の提示を目指す．

参考文献

総務局統計局（2023）令和 5 年住宅・土地統計調査 住宅数概要集計（速報集計）結果．<https://www.stat.go.jp/data/jyutaku/2023/pdf/g_kekka.pdf>．（2025.8.15.閲覧）

山下伸・森本章倫（2015）地方中核都市による空き家の発生パターンに関する研究.「都市計画論文集」, Vol.50, No.3, 932-937.

秋山祐樹・冨田健人・水谷昂太郎・馬場弘樹（2024）自治体保有データと機械学習を活用しいた非空き家住宅の特定による空き家現地調査の負担軽減方法の提案―群馬県前橋市における事例―,「GIS－理論と応用」, 32 (1), 13-24.

Simonyan, K. and Zisserman, A. (2014) Very Deep Convolutional Networks for Large-Scale Image Recognition, “arXiv”, 1409.1556.

衛星画像と機械学習を用いた土地利用分類に基づく開発適地の自動選定手法の構築

久保田涼太*・寺田遣都・秋山祐樹*****

Development of an Automated Method for Selecting Suitable Development Sites through Land Use Classification with Satellite Imagery and Machine Learning

Ryota Kubota*, Kento Terada**, Yuki Akiyama***

Abstract: In recent years, the tendency toward long working hours has been cited as a problem in Japan's construction industry, necessitating the promotion of Digital Transformation（DX）to streamline operations. However, the selection of suitable development sites is still carried out through human visual inspection, requiring significant costs and time. Meanwhile, the development of detailed land use mesh data—which divides all of Japan into 100m mesh units and classifies them by land use purpose—faces similar challenges. This study predicted and evaluated land use classifications in the Tohoku region using satellite imagery and machine learning. It then combined this with an evaluation metric called development potential, created based on factory site selection criteria, to extract suitable development sites. As a result, high prediction accuracy was achieved in two prefectures of Tohoku, successfully identifying suitable development sites. We aim to further advance this technology to achieve full-scale implementation in practical operations and significantly reduce the time required for this task.

Keywords: 土地利用分類（land use classification），衛星画像（satellite imagery），機械学習（machine learning），開発適地（suitable development site），画像分類（image classification）

１．はじめに

１.１　研究背景

近年，日本の建設業界における問題の 1 つに，「長時間労働」が挙げられる．業界全体ではデジタル・トランスフォーメーション（DX）を推進して業務を効率化させ，労働時間を削減していく努力が続けられている．

しかし，依然として DX 化が進んでいない業務領域も数多く存在する．その一つとして，開発可能な土地（以下，「開発適地」）の選定業務が挙げられる．開発適地とは，まとまった広さの田畑・森林など，将来的に大規模施設の建設に適した土地を指す．同業務は，現状ではオペレーターによる航空写真の目視判読に依存しており，膨大な時間と労力を要することが課題となっている．開発適地の選定は，都市計画や防災計画の基盤ともなっている土地利用細分メッシュデータ（以下，「土地利用データ」）が重要な判断材料となっている．土地利用データは，全国を 100m メッシュに区分し，各メッシュを土地利用目的別に分類した大規模な地理空間データである．

現在，土地利用データの整備は，開発適地の選定と同様に，オペレーターが衛星画像や航空写真を目視で判読し，手作業で分類するという労働集約的な手法に依存している．その結果，日本全国の約 3,400 万メッシュの整備には多大な時間とコストを要する上，オペレーターの判断に依存するため品質の不均一性も生じる．また，データの更新頻度が限られており，都市開発や災害等による土地利用の最新の変化に迅速に対応できず，データの鮮度が損なわれるという課題も生じている．

こうした背景から，AI 等の先進技術を活用した効率的な土地利用データの整備手法を確立し，開発適地を自動的に選定する技術が強く求められている．

１．２　既往研究と本研究の位置づけ

AI を用いて画像から土地被覆や地物を自動分類する手法は，近年数多く報告されている．越智（2009）は，画像オブジェクトに基づく高分解能衛星画像での土地被覆分類手法の提案を行っている．また，有水・毛綱（2020）は，深層畳み込みニューラルネットワークを用いたセグメン

*　学生会員　東京都市大学建築都市デザイン学部（Tokyo City University）
〒158-0087　東京都世田谷区玉堤 1-28-1　E-mail：g22320333@tcu.ac.jp
**　学生会員　東京都市大学大学院総合理工学研究科（Tokyo City University）
〒158-0087　東京都世田谷区玉堤 1-28-1　E-mail：g2581638@tcu.ac.jp
***　正会員　東京都市大学建築都市デザイン学部（Tokyo City University）
〒158-0087　東京都世田谷区玉堤 1-28-1　E-mail：akiyamay@tcu.ac.jp

テーション手法によって，森林作業道の自動走行における走行可能領域を判別する手法を開発し，車道クラスの高精度な分類方法の提案を行っている．

しかし，本研究が目的とする日本全国という規模を対象に，100m メッシュ単位で土地利用を自動的に分類するとともに，その結果を開発適地の選定作業の自動化に活用しようとする手法は未だに開発されていない．

１．３　本研究の目的

本研究の目的は以下の 2 点である．まず 1 点目として，衛星画像と機械学習を用いて，日本全国の土地利用を 100m メッシュ単位で自動分類し，土地利用データを高頻度かつ効率的に整備する技術を開発することである．具体的には，建物用地，その他可住地，水域，森林・荒地の 4 クラスに分類する．また，2 点目として，同技術を活用して得られた土地利用データを用いて，開発適地の候補となる領域を自動選定する手法を提案することである．

２．研究手法

２.１　対象地域

本研究では，日本全国への展開を見据えたパイロットスタディとして，都市部と農村部が存在し，土地利用分類の精度評価に適している東北地方全域を対象とした．

２.２　使用データ

モデル構築の学習データおよび精度検証の評価データには，国土数値情報が提供する 2020 年度の土地利用データを過去の土地利用判読結果として使用した．また，本研究では，衛星画像として欧州宇宙機関（ESA）が運用しており，無償での利用が可能な Sentinel-2 を採用した．Sentinel-2 は最大 10m の高い空間分解能，5 日間隔の高頻度な観測，13 種類のスペクトルバンドを特徴とする．

本研究で使用する画像については，土地利用データの判読時期である 2020 年 10 月から 12 月を対象としたモザイク画像を取得した．

２.３　特徴量の抽出

取得した衛星画像に対して，土地利用分類のための特徴量の抽出を実施した．分類モデルの入力特徴量として，土地被覆の識別に有効とされる複数のスペクトルバンドおよび指標を選定した．

具体的には，可視光で光の三原色である Blue（Band2），Green（Band3），Red（Band4）の 3 種類と，近赤外線に対応する NIR（Band8），短波長赤外線に対応する SWIR（Band11）の 2 種類，合計 5 種類のバンドを使用した．加えて，これらのバンドから式(1)～(3)で定義される 3 種類の指標（Hall, D. K. et al.，1995），（Tucker, C. J.，1979），（Xu, H.，2006）を作成し，特徴量として追加した．表 1 に各特徴量の解像度と概要を示す．

２.４　教師データの作成

機械学習モデルに入力可能な形式とするため，100m メッシュごとの特徴量データと，正解ラベルである土地利用判読結果を結合し，教師データセットを作成した．

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)} \quad (1)$$

$$MNDWI = \frac{(Green - SWIR)}{(Green + SWIR)} \quad (2)$$

$$NDSI = \frac{(SWIR - NIR)}{(SWIR + NIR)} \quad (3)$$

分類ラベルは，国土数値情報の土地利用データをもとに表 2 に示す 4 クラスとした．まず第 1 分類として，土地を可住地と非可住地に大別する．次に第 2 分類として，可住地を建物用地とその他可住地の 2 クラスに，非可住地を水域と森林・荒地のクラスに分類する．その結果，最終的に合計 4 クラスに分類される．

２.５　機械学習モデルの構築

2.4 で作成した教師データを用い，東北地方全域の土地利用分類を自動化することを目的に，Random Forest に基づく機械学習モデルを構築した．なお，過学習を抑制して汎化性能を確保するため，5 分割交差検証を実施した．分類処理には，2.4 で述べた段階的な二値分類手法を採用した．なお，機械学習モデルは県単位で構築した．

２.６　予測と評価

2.5 で構築した機械学習モデルを用いて東北地方各県を対象として 100m メッシュ単位で土地利用分類の予測を実施した．得られた予測結果は，正解データである土地利用判読結果と比較することで，モデルの分類精度を定量的に評価する．なお，モデルの精度を評価するために採用する指標は表 3 の通りである．

表 1　本研究で用いた特徴量

特徴量	解像度(m)	概要
Blue (Band2)	10	青色可視光スペクトルバンド(490nm)
Green (Band3)	10	緑色可視光スペクトルバンド(560nm)
Red (Band4)	10	赤色可視光スペクトルバンド(665nm)
NIR (Band8)	10	近赤外スペクトルバンド(842nm)
SWIR (Band11)	20	短波赤外スペクトルバンド(1610nm)
NDVI	10	緑植生の茂り具合を示す指標.
MNDWI	20	地表面における雪を含めた水域や，植生に含まる水分量の存在を示す指標.
NDSI	20	地表面における砂やコンクリートなどの分布を示す指標.

表 2　土地利用分類項目の対応表

第一分類	第二分類	土地利用データの分類項目
可住地	建物用地	-
	その他可住地	田・その他の農用地・道路・鉄道・その他の用地・ゴルフ場
非可住地	水域	河川地および湖沼・海浜・海水域
	森林・荒地	-

また，本研究でモデルの精度を多角的に評価するために採用する指標について表 3 に示す．

2.7　開発ポテンシャルの評価

2.6 で予測した 4 分類の土地利用データを用いて，開発適地の選定を実施した．具体的には，主に田畑を中心とした農用地を占める，その他可住地と森林・荒地に分類されたメッシュを対象に，開発適地の絞り込みを定量的に実施するため，新たな評価指標として，開発ポテンシャルを定義し評価を行った．

開発ポテンシャルとは，経済産業省の「工場適地の選定基準について」で定められている基準に基づいて，開発適地としての適性を定量的に評価する指標である．具体的な算出項目と配点を表 4 に，算出に使用したデータを表 5 に示す．評価項目の多くは産業施設やインフラ施設までの距離となっており，距離が近いほど高い得点が与えられる．

表 3　モデルの精度評価のための指標

指標	概要	評価の観点
正解率 (Accuracy)	全てのデータのうち，正しく分類されたものの割合.	モデル全体の正しさ
適合率 (Precision)	あるクラスだと予測されたデータの中で，実際に正解だったデータの割合.	予測の的確さ
再現率 (Recall)	実際に特定のクラスに属するデータ内で，正しく予測されたデータの割合.	見逃しの少なさ
F値 (F-measure)	適合率と再現率の調和平均であり，両者のバランスを考慮した指標.	適合率と再現率の調和

表 4　開発ポテンシャルの算出項目と配点

実装された調査項目	得点
国道までの距離	0～5
高速道路のI.Cまでの距離	0～7
新幹線到着駅までの距離	0～5
空港までの距離	0～5
市町村の人口規模	0～5
人口5万人都市までの距離	0～3
人口15万人都市までの距離	0～5
工科系大学までの距離	0～3
公設試験場までの距離	0～3

表 5　開発ポテンシャルの算出に使用したデータ

データ元	詳細情報
国土数値情報	全国道路データ(1995年)
	全国高速自動車道データ(2020年)
	全国駅データ(2020年)
	全国空港データ(2020年)
	全国行政区域データ(2020年)
	全国学校データ(2023年)
国勢調査(e-Stat)	人口等基本集計(2020年)
経済省公設試験場	工業試験場(2023年)

本研究では，合計得点（41 点）のうち，6 割（25 点）を満たすメッシュを抽出することで，開発適地の候補となる領域の絞り込みと評価を行った．

3．結果

3.1　土地利用分類の予測結果

本稿では，宮城県および秋田県の結果を例として示す．2 県の土地利用分類の予測結果を図 1 と図 2 に，各クラスに対する評価指標と推定精度を表 6 と表 7 に示す．宮城県と秋田県のいずれにおいても，高い精度で土地利用分類予測が行われたことが確認された．なお，いずれの県においても，モデル構築から予測終了までに要した時間は約 2 時間であり，人間による目視判読に比べて大幅に短時間で処理が可能であり，作業負担の大幅な軽減を実現することができた．

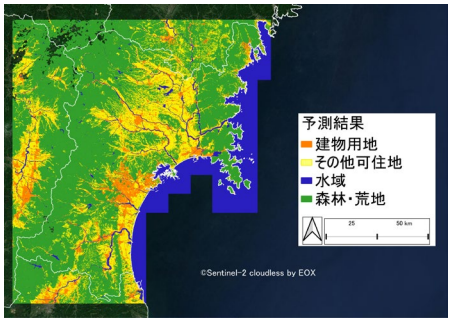


図 1　宮城県における予測結果

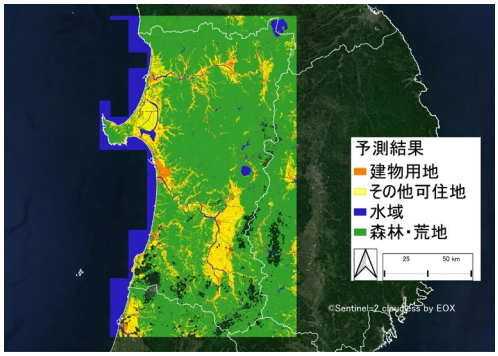


図 2　秋田県における予測結果

表 6　宮城県における各クラスに対する評価指標と推定精度

宮城県	正解率(%)	適合率(%)	再現率(%)	F値(%)
建物用地	—	92.71	99.99	96.22
その他可住地	—	98.51	98.09	98.3
水域	—	99.43	99.3	99.37
森林・荒地	—	99.99	99.31	99.65
全体	99.08	97.66	99.17	98.38

表 7　秋田県における各クラスに対する評価指標と推定精度

秋田県	正解率(%)	適合率(%)	再現率(%)	F値(%)
建物用地	—	77.17	99.99	87.11
その他可住地	—	92.84	97.03	94.89
水域	—	98.58	98.22	98.4
森林・荒地	—	99.99	98.12	99.05
全体	98.02	92.15	98.34	94.86

３.２　開発適地の抽出

2.7 で定義した開発適地を抽出した結果を図 3，図 4 に示す．開発ポテンシャルの得点が 25 点未満の領域を半透明で，25 点以上の開発適地は得点が大きくなるにつれて濃い色で示している．2 県ともに，主に大都市の周辺部で開発適地が連続的に広がっていることが確認された．なお，開発ポテンシャルの付与に要した時間は 1 県につき約 2 時間であった．

４．考察

表 7 によると，秋田県の建物用地における適合率が 80%に満たず，他の結果と比較して低いことがわかる．一方，表 6 より宮城県における建物用地では，90%を超える適合率となっていた．総務省統計局の「住宅及び世帯に関する基本集計」（2023）によると，秋田県は 2023 年時点での総住宅数が約 44 万戸と全国的にも少ないことがわかる．2018 年と比較すると 1.1%減少しており，この減少率は全国で最も高い値である．また，居住世帯のある住宅に関するデータでは，一戸建の割合が 79.4%を占めており，これも全国で最も高い値である．さらに，政府統計が公開している「都道府県・市区町村のすがた（社会・人口統計体系）」の 2020 年のデータによると，秋田県には秋田市を除いて，人口 10 万人規模の市町村がないこともわかる．以上より，秋田県では衛星画像内の建物データが少ないことや，建物用地と判断できる領域が小さいことが，適合率の低さに影響していると考えられる．

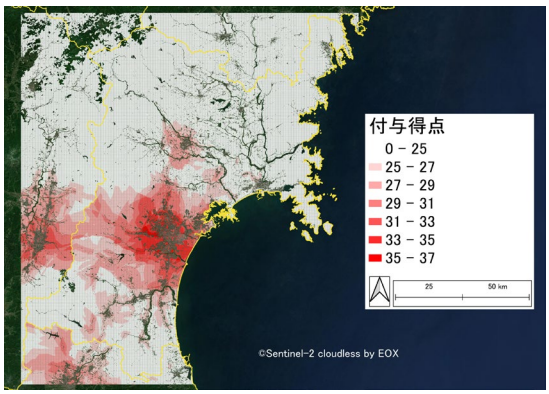


図 3　宮城県における開発適地

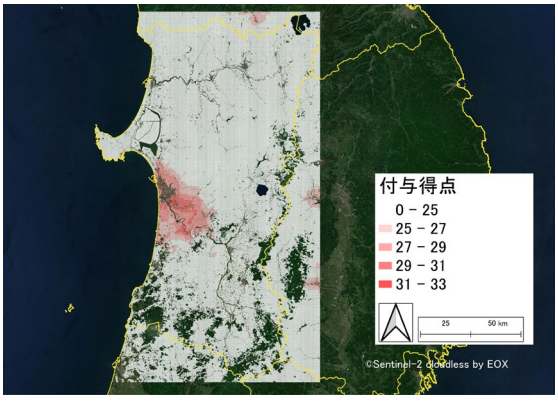


図 4　秋田県における開発適地

５．おわりに

本研究では，衛星画像に機械学習を適用して土地利用分類を予測し，その結果を開発ポテンシャルの評価値と重ね合わせることで，開発適地を自動的に選定する技術を構築した．その成果として，東北地方全域を対象とした土地利用分類の自動化を実現し，宮城県および秋田県における精度検証により高い分類性能を確認した．さらに，開発ポテンシャルと土地利用分類を組み合わせることで，開発適地の自動選定が可能であることを示した．また，従来の目視による選定と比較して，業務時間やコストを大幅に削減できることも明らかとなった．

今後は，日本全国を対象とした開発適地の自動選定を進めることを目標とする．また，本研究では土地利用データの判読時期に合わせて 2020 年の衛星画像を使用したが，今後はより新しい時点の画像を活用し，既存モデルによる外挿的な適用を検討する予定である．

さらに，開発ポテンシャルの評価項目は現状，産業施設やインフラ施設までの距離に依存している．実務的な適用を見据えると，土地の形状や工事および運営に要するコストなど，新たな実務的観点を取り入れた指標の拡充が不可欠である．これらの展望を踏まえ，本技術を実務における本格的な運用へと発展させることを目指す．

謝辞

本研究は，JSPS 科研費（24K00243）の助成を受けて実施した．ここに記して謝意を表す．

参考文献

越智士郎（2009）画像オブジェクトに基づく高分解能衛星画像での土地被覆分類手法の検討.「東南アジア研究」, **46**（4）, 578-592.

有水賢吾・毛綱昌弘（2020）深層畳み込みニューラルネットワークを用いたセマンティックセグメンテーションによる森林作業道抽出.「森林利用学会誌」, **35**（1）, 7-13.

Hall, D. K., Riggs, G. A., Salomonson, V. V.（1995）Development of methods for mapping global snow cover using Moderate Resolution Imaging Spectroradiometer data. *Remote Sensing of Environment*, **54**（2）, 127–140.

Tucker, C. J.（1979）Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, **8**（2）, 127-150.

Xu, H.（2006）Modification of normalized difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, **27**（14）, 3025–3033.

経済産業省（2017）工場適地の選定基準について. <https://www.meti.go.jp/shingikai/sankoshin/chiiki_keizai/kojo_ritchi/pdf/035_s03_02.pdf>.

総務省統計局（2024）住宅及び世帯に関する基本集計. <https://www.stat.go.jp/data/jyutaku/2023/pdf/kihon_gaiyou.pdf>.

土地利用の変遷に着目した局所人口分布の空間変動の分析

白石彩乃*・熊谷樹一郎・卯田航平*****

Analysis of spatial variation in local population distribution focusing on land use change

Ayano Shiraishi*, Kiichiro Kumagai**, Kohei Uda***

Abstract: Japanese population is currently declining. This population decline may lead to a decrease in social development and difficulties in maintaining urban functions. The government is promoting measures to concentrate urban functions within walking distance and increase population density. On the other hand, the "Urban spongification" phenomenon, in which vacant houses and lots randomly occur in urbanized areas, is one of the issues because it may also hinder population concentration. We have focused on the spatial distribution of local population in urban areas and developed methods to statistically define and understand the size of low population density areas. However, the relationship between the spatial characteristics of local population and land use has not been sufficiently examined. This study aims to clarify the relationship between the characteristics of local population distribution and the land use status over a 25-year period.

Keywords: 都市のスポンジ化（Urban spongification），人口動態（Population dynamics），空間的自己相関（Spatial autocorrelation），土地利用（Land use），用途地域（Land use zones）

１．はじめに

日本の総人口は戦後の急激な経済成長に伴って増加し，1967 年に一億人を超えた．しかし 2008 年をピークに人口は減少傾向に転じ，2053 年には再び一億人を下回ると推計されている．このような人口減少は社会の開発意欲の低下や都市機能の維持困難を招き，さらなる都市の衰退を進行させる恐れがあると指摘されている．

国土交通省は対策案として，徒歩圏内に都市機能を集約し，人口を集積させることを目指した「コンパクト・プラス・ネットワーク」を推進している．これは小スケールの市街地を形成し，公共サービスや産業活動の維持・活性化を期待するものである．一方，都市の小さな敷地単位で空き家・空き地などの低・未利用地が不規則に発生する「都市のスポンジ化」が課題として挙げられている．この現象はコミュニティの衰退や治安・景観の悪化を促し，人口の集積を妨げる要因ともなり得るため，都市構造の変化が進む現在，都市のスポンジ化に対応した中長期的な都市構造のモニタリングが求められる．

著者らは人口の空間分布そのものに着目し，市街地における人口の低密な範囲を統計的に定義・把握する手法を開発してきた．これにより局所人口の空間分布の広がりを詳細に把握することが可能となった(Kumagai et al., 2021, 2022). 具体的には人口の増加期，減少期における都市構造の変化の分析や人口集中地区の適用性の検証などを行ってきた．一方で，開発した手法は局所人口データの空間特性を定量化するものであり，土地利用の推移や規制などとの関連性については十分に検討されてこなかった．

そこで本研究ではこれまで開発してきた空間分析法をもとに，土地利用の変化に着目し，局所人口分布の特性について 25 年間の空間的変遷の特性を明らかにする．

２．対象領域および対象データの選定

対象領域として大阪府全域を採用した．大阪府ではほぼ全域が都市計画区域に指定されており，対象領域内には多様な空間パターンで人口が分布している．

対象データとしては，国勢調査基本単位区別集計の 1995 年度，2020 年度の人口分布データ，国土地理院数値地図の 1974 年度，1996 年度の細密数値情報 10m メッシュ土地利用データ，国土数値情報の 2021 年度の 50m メッシュ土地利用詳細データ，行政区域データ，2019 年度の用途地域データを採用した．

３．使用手法

３．１　局所人口データを用いた空間分析方法

著者らが開発・整備した局所人口の空間分布特性を抽出する手法は，局所的な空間的自己相関測度$G_i(d)$に基づいている．点iからの距離パラメータdの範囲内における重み係数$w_{ij}(d)$と属性値u_jを用いて，$G_i(d)$は式(1)で定義され，u_jの高い値，もしくは，低い値の集積度を表す（Ord

*　学生会員　摂南大学大学院理工学研究科社会開発工学専攻（Setsunan University）
〒572-8508　大阪府寝屋川市池田中町 17-8　E-mail：201036sa@gmail.com
**　正会員　摂南大学大学院理工学部都市環境工学科（Setsunan University）
***　非会員　摂南大学大学院理工学研究科社会開発工学専攻（Setsunan University）

et al.,1992).

$$G_i(d) = \frac{\sum_j w_{ij}(d)u_j}{\sum_j u_j} \qquad i \neq j \qquad \text{式(1)}$$

標準化正規化変量$z_i(d)$は，局所的な空間的自己相関測度$G_i(d)$の期待値$E[G_i(d)]$と分散$\sqrt{V_{ar}[G_i(d)]}$を用いて，式(2)のように得られる．

$$z_i(d) = \frac{G_i(d) - E[G_i(d)]}{\sqrt{V_{ar}[G_i(d)]}} \qquad \text{式(2)}$$

標準化正規化変量は，有意水準(本研究では10%に設定)によって「正・負の空間的自己相関あり」と「空間的自己相関なし」に判定される．本研究ではu_jに局所人口を割り当てるとともに，次のように判定結果を応用した．

距離パラメータdの増加に応じた「正・負の空間的自己相関あり」・「空間的自己相関なし」の判定領域の変化率が収束した時点の距離パラメータを最大値d_{max}とする．計測地点iにおいてd_{max}から距離パラメータを段階的に小さくし，「正の空間的自己相関あり」の有無を検査していく．図-1 のように局所人口u_jの分布が「正の空間的自己相関あり」と判定されなくなった距離パラメータd_kをASP (Ambiguity of Spatial scale in densely Populated area: 高人口集積内空間不確定量)と定義した(Kumagai et al., 2021, 2022). d_{k+1}からd_{max}の範囲内では局所人口の合計が有意に高くなっているが，その内側のd_k(=ASP)の範囲に限り局所人口の合計が相対的に低くなっていることになる．つまりこのd_kは都市部での局所人口の空洞化が生じている可能性がある．なお，これらの計算により「正の相関あり」がどのdでも生じない場合は「相関なし」と判定し，少ない局所人口が非常に広い範囲で拡がっていることから，ここではASP$_\infty$と表す．また，すべての距離パラメータで「正の相関あり」となった場合，局所人口の合計が低い範囲がない(高い局所人口が集積している)とし，ASP$_0$と表している．

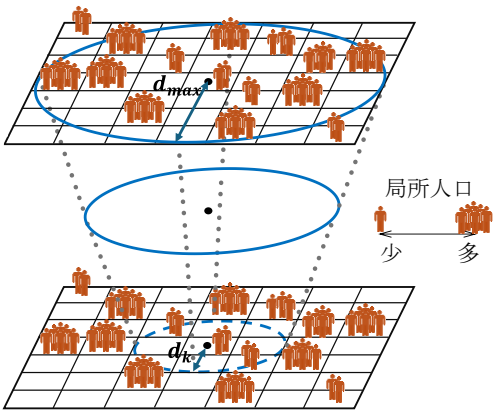


図-1 ASP の概念図（Kumagai et al., 2021）

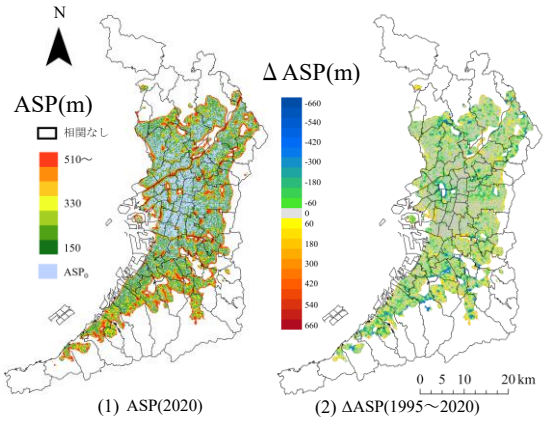


図-2 ASP と Δ ASP の算出結果

この処理を対象領域内の各地点で実施し，その結果を地点ごとに格納することで図-2(1)のようなASP のマップを得ている．

３．２ 複数時期における ASP の分析方法

都市のモニタリングの観点から人口分布における変化に着目し，局所人口の低密な範囲の経年変化について算出する．ASP の差は同一地点での複数の時期間のd_kの差となり，図-2(2)の 1995 年と 2020 年との例のように，大きく分けて「ASP 縮小(-Δ ASP)」「ASP 拡大(+Δ ASP)」の 2 パターンに分類される．「ASP 縮小」は ASP 内の人口が増加し，「ASP 拡大」は ASP 周辺地域人口が減少することで局所人口の低密な範囲が変動したことを意味する．

本研究では過去の土地利用状態と，人口の増加から減少への変換期における低密な範囲の変化との関連性を比較・分析するため，1995 年から 2020 年までの 25 年間の変化を対象とする．

４．分析結果

４．１ 土地利用状態との関連性の分析

まず局所人口の低密な範囲を示す ASP と土地利用状態の関係性を確認するため統計的な検証を行う．2021 年の土地利用状態と 2020 年の ASP についてχ 二乗検定定を実施したところ，p 値<0.001 で独立性が棄却される結果となった．そこでこれらの残渣分析を実施し，その違いの傾向を分析した．

残渣分析の結果を表-1 に示す．表中の(-)記号は，期待値よりも実測値が有意に小さいことを示している．中高層建物，低層建物(非密集地，密集地)や道路，鉄道といった開発の進んでいる土地利用状態を表す地点では ASP$_\infty$(人口の集積の捉えられない地点)が期待値よりも有意に小さいことが示されている．一方で，田，その他の農用地，森林，工場，ゴルフ場などの宅地などの開発が行われていない地点では ASP$_\infty$が有意に大きく，期待値より多く分布していることが確認できる．また，宅地以外では人口の低密な範囲がない ASP$_0$ が期待値より有意に小さく， ASP = 150(m)~390(m)も有意に小さいことを示して

表-1 土地利用状態と ASP との残渣分析結果

		ASP(m)											
		ASP_0	150	210	270	330	390	450	510	570	630	690	750	ASP_∞
土地利用状態	田	(-)***	(-)***	(-)***		***	***	***	***	***	***	***	***	***
	その他の農用地	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***						**	***
	森林	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	***
	荒地	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	***
	建物用地	(-)**												***
	中高層建物	***	***	***	***				(-)***	(-)***	(-)***	(-)***	(-)***	(-)***
	工場	(-)***	(-)***		***	***	***	***	***	***	***	***	***	***
	低層建物(非密集地)	***	***	***	***	***	***	***	***					(-)***
	低層建物(密集地)	***	***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***
	道路	***	***	***	***	***	***	***	***	***	***	***	***	(-)***
	鉄道	***	***	***	***	***	***	***	***		***			(-)***
	その他の用地	(-)***	(-)***	(-)***	(-)**	(-)*								***
	施設等用地	(-)***	***	***	***	***	***	***	***	***		**	***	(-)***
	空き地	(-)***	(-)***	(-)***	***	***	***	***	***	***	***	***	***	***
	公園・緑地	(-)***	**	***	***	***	***	***	***	***	***	***	***	(-)***
	河川地および湖沼	(-)***	(-)***	***	***	***	***	***	***	***	***	***	***	(-)***
	海浜	(-)***	(-)***	(-)***	(-)*	(-)*								***
	海水域	(-)***	(-)***	(-)***	(-)**	(-)***	(-)**	(-)**	(-)*	(-)*				***
	ゴルフ場	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***			***

***0.001, **0.001-0.01, *0.01-0.05

いる．このようにそれぞれの土地利用の状態によって局所人口の空間的な分布が異なっていることが示唆された．

４．２　都市構造の変化とΔASP の関係性の分析

4.1 節では，土地利用の状態によって局所人口の空間分布には差異が見られた．特に宅地として利用されている地域とそのほかの地域については人口の低密な範囲を示す ASP との関係性に相違が確認された．これらは現時点の土地利用状態との比較だが，都市構造は時代とともに変化し，それに伴って人口の分布も変動していると考えられる．したがって土地利用状態の変遷の履歴とその影響を分析することが重要である．そこで本研究では，人口の変動パターンと密接に関連があると考えられる中高層建物，低層建物(非密集地，密集地)といった住宅地に変化した場合を「市街化」と定義する．複数期のデータ間で土地利用項目をまとめることで，1974 年以前，197 年から 1996 年まで，1996 年から 2021 年の 3 期間に市街化された時期を区分し，各時期の市街化とΔASP との関係性を分析する．

表-2(1)に大阪府内のΔASP と市街化された時期についての残渣分析の結果を示す．1974 年までに開発された地点ではΔASP が＋，－ともに多くの項で期待値よりも有意に小さく，人口の低密な範囲の変化がなかった地域(ΔASP = 0)については期待値よりも有意に大きいことがわかる．1974 年から 1996 年にかけて市街化された地域は-ΔASP の変化は全体的に有意に小さいが，+ΔASP はほとんどの項で有意な差が得られていない．1996 年から 2021 年にかけて市街化された地域は-ΔASP の変化の分布は期待値よりも大きい側で有意であり，人口の低密な範囲の縮小に関係性のある箇所が多いことがわかる．

４．３　用途地域による影響について

表-2(2)には，大阪府内の第一種低層住居専用地域，第二種低層住居専用地域に絞ったなかでの市街化の時期とΔASP についての残渣分析の結果を示す．こちらでも 1996 年から 2021 年に開発された地域については同様の結果が得られているが，1974 年から 1996 年に開発された地域では+ΔASP の変化が有意に大きいことが多くの項で示されている．用途地域は一度設定されると長期的に維持されることが多く，特に低層住居専用地域については他と比較して用途の制限が強い面もあり，開発から 30 年～50 年経過後に局所人口の低密な範囲が拡がった箇所が多くなる結果につながったと考えることもできる．

同様に第一種中高層住居専用地域，第二種中高層住居専用地域に限定した地域についてΔASP との残渣分析を行った．その結果を表-2(3)に示す．1974 年以前に開発された地域ではΔASP＝+60m の範囲で期待値よりも有意に大きいことを示しており，人口の低密な範囲が拡がっている地域が多く分布しているということがわかる．

５　特徴地点の考察

市街化の時期と低層住居専用地域の関係性について代表的な地域を取り上げ，図-3 に示した．

図-3(1)(2)は 1974 年以前に市街化された堺市西区上野芝内ヶ丘町，藤井寺市加津が丘 2 丁目付近である．ΔASP=-60, 0, 60(m)といった黄色や緑色の分布が多く，局所人口の低密な範囲の変動は小さい箇所が多く分布している．1974 年以前に市街化された地区では，低層住居専用地域として指定され面積が比較的小さく，この時期の開発の特徴と見受けられた．50 年以上前から宅地であった箇所も含まれており，人口更新が進んだ結果として局所人口の空間分布にそれほど大きな変化が生じていないと推測される．

図-3(3)(4)には 1974 年から 1996 年に市街化された貝塚市希望が丘三丁目付近，池田市伏尾台地域を示す．この期間では，1974 年以前に開発された地域と比較して低層住居専用地域と指定された面積が大きく，特にニュータ

表-2 宅地開発時期と ASP との残渣分析結果

(1)大阪府全域

開発時期	ΔASP(m) -660	-600	-540	-480	-420	-360	-300	-240	-180	-120	-60	0	60	120	180	240	300	360	420	480	540	600	660
市街化なし	(-)**	(-)***	(-)***	(-)*	***	***	***	***	***	***	***	(-)***	***	***	***	***	***	***	***	**			(-)**
~1974	(-)**	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)*	
1974~1996				(-)*	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	***									***		**
1996~2021	***	***	***	***	***	***	***	***	***	***	***	***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***					

***-0.001,**0.001-0.01,*0.01-0.05

(2)低層住居専用地域

開発時期	ΔASP(m) -660	-600	-540	-480	-420	-360	-300	-240	-180	-120	-60	0	60	120	180	240	300	360	420	480	540	600	660
市街化なし	(-)*	(-)**	(-)***	(-)***				*	**	***	(-)***	(-)***	(-)***	(-)***									
~1974	(-)*	(-)**	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***		***	***	***		(-)***	(-)***	(-)**	(-)***	(-)***	(-)**	(-)*		
1974~1996					(-)**	(-)*	(-)*			(-)***	(-)**	***	***	***	***	***	*	*					*
1996~2021	***	***	***	***	***	***	***	***	***			(-)***	(-)***									**	

***-0.001,**0.001-0.01,*0.01-0.05

(3)中高層住居専用地域

開発時期	ΔASP(m) -660	-600	-540	-480	-420	-360	-300	-240	-180	-120	-60	0	60	120	180	240	300	360	420	480	540	600	660
市街化なし					***	***	***	***	***	***	(-)*	(-)***	***	***	***	***	***	***					
~1974	(-)**	(-)**	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	(-)***	***	***					(-)**					
1974~1996						(-)**		(-)***	(-)***	(-)***	(-)***	***		(-)**									
1996~2021		***	***	**	***	***	***	***	***	***	***	(-)**	(-)***	(-)***	(-)***	(-)***	(-)**						

***-0.001,**0.001-0.01,*0.01-0.05

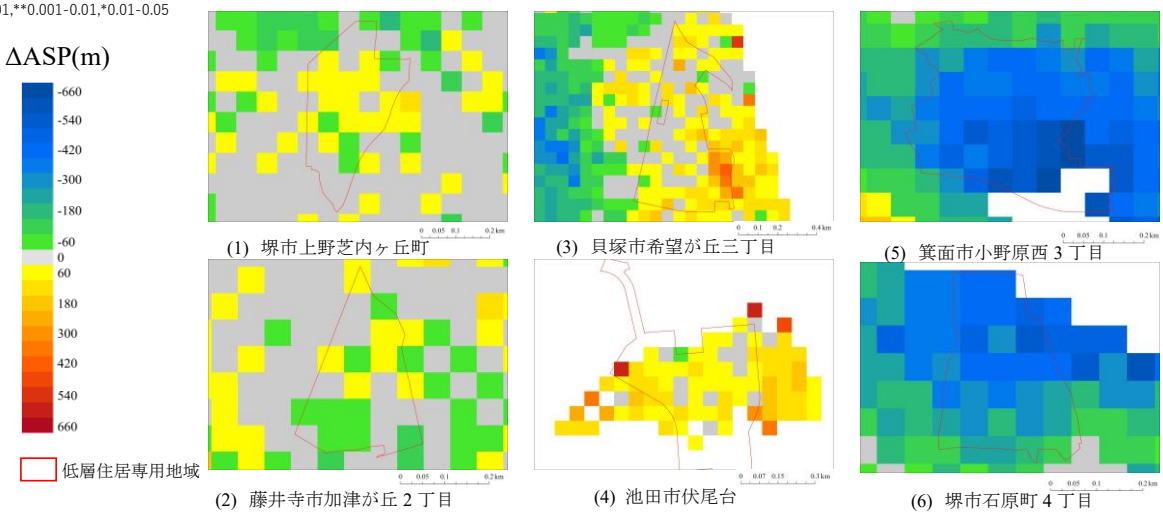


図-3 ASP の変動の特徴的な地域

ウンなど大規模な住宅地の開発が多く行われている傾向が確認された．ΔASP と比較すると約 50 年で局所人口の低密な範囲が拡大している地域も多く，人口更新が進んでいない可能性が示唆された．

次に 1996 年から 2021 年に開発されている箕面市小野原西 3 丁目，堺市東区石原町 4 丁目を図-3(5)(6)に示す．この地域では-ΔASP の分布が多くみられ，人口の低密な範囲が縮小した地点が多い．大規模な住宅地開発が行われた 2000 年前後は人口増加期にあたる．これら地域については今後，中長期的に人口動態について把握していく必要性があるであろう．

用途地域の中でも特に低層住居専用地域については用途の制限が強く，地域によっては居住者の入れ替えが進みにくいケースも想定される．特に，人口増から人口減へと変化したなかでは，1974 年から 1996 年で市街化された地域において局所人口の低密な範囲が拡大する傾向が強く表れる結果となった．なお，1992 年に 12 種類の用途地域指定制度が制定されていることも市街化の規模に関係がある可能性もあり，今後の検証が必要である．

6．おわりに

本研究では土地利用状態の時代による変化と，それに伴う局所人口分布の空間的変遷の比較を行った．市街化を 3 期間に区分したうえで，各時期の市街化とΔASP との関係性を検討した．残渣分析などの結果から，低層住居専用地域といった区分において，市街地としてその地域が開発された時期によって局所人口の低密な範囲の拡大・縮小といった特徴的な変化が見られることが確認された．過去の開発から 50 年程度経過した地域では，特に局所人口分布の低密な範囲が拡大している傾向が明らかになった．

参考文献

K. Kumagai and Y. Kameda (2021) Detection of the spatial variations of local populations from the viewpoint of urban structure analysis, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Sciences, Vol.V-4-2021, pp.177-185.

K. Kumagai, S. Tsukamoto, H. Tokoi, and M. Wada (2022) household-size data for urban management in a declining population, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol.V-4-2022, pp.283-291.

Ord, J. K. and Getis, A. (1992) Local Spatial Autocorrelation Statistics: Distributional Issues and an Application, Geographical Analysis, Vol.27, No.4, pp.286-306,1995.

マルチスペクトル衛星データと地域特性の統合による建物構造・築年次推定

荻野 光司*・大佛 俊泰**

Estimation of Building Structure and Construction Year Through the Integration of Multispectral Satellite Data and Local Characteristics

Koji Ogino*, Toshihiro Osaragi**

Abstract: Building location and attribute data are essential for urban planning and disaster mitigation. However, their availability remains limited, and current estimation methods suffer from limited accuracy and applicability. We previously developed a building footprint detection model using open-access satellite imagery. In this study, to assign attributes to individual footprints, we estimated building structure type and construction year for each cell. We constructed multiple cell-based models using visible, near-infrared, and shortwave infrared bands of Sentinel-2, based on a convolutional neural network. The results indicate that incorporating near-infrared and shortwave infrared data significantly improved the estimation accuracy of non-wooden buildings compared with visible-only models. However, the model still underestimated pre-1970 wooden buildings in densely populated neighborhoods dominated by old wooden houses. To address this limitation, we introduced a proximity indicator to such densely wooden housing areas and confirmed its effectiveness.

Keywords: 建物属性推定（building attribute estimation），建物構造（building structure），建築年次（construction year），Sentinel-2（Sentinel-2），木造住宅密集地域（densely populated wooden housing areas）

1. はじめに

建物の位置や属性情報から成る建物データは，都市計画や防災計画などの基礎となる情報である．近年，深層学習がリモートセンシング分野に導入され，建物の外周線を検出する研究が盛んに行われている．一方で，その外周線に属性情報を付与する研究は，発展段階にある．

東京都による地震に関する地域危険度測定調査では，建物倒壊危険度を推定する際，構造と築年次により 14 種の建物被害関数を設定している．しかし，個人情報保護や安全保障の観点から，これらの属性情報は公開が制限されており，研究や実務で活用可能なオープンデータは極めて限定的である．

リモートセンシング・地上画像データを用いた属性情報推定に関する既往研究は，大きく(1) 建物外周線の検出と幾何特徴を用いた推定，(2) 画像からの直接推定，(3) 可視域外のマルチスペクトル衛星データや合成開口レーダー（SAR）などを活用した推定に分類できる．

Du et al.（2015）は，衛星画像と建物外周線から屋根形状やテクスチャ，空間分布などの幾何的特徴を把握し建物用途分類を行ったが，手動の特徴設計に依存するという限界がある．沖・小川（2021）は，建物外観画像を直接深層学習モデルに入力することで構造や築年次を推定したが，可視光画像のみでは外観が類似する異なる属性を区別しにくいという課題がある．さらに，Frantz et al.（2021）は，Sentinel-1 SAR と Sentinel-2 を用いて建物高さを推定し，大規模な属性推定の可能性を示した．しかし，建物構造や築年次については十分に研究されていない．荻野・大佛（2025）は，人口や夜間光量，正規化植生指数（NDVI）を用いて属性情報を推定したが，地域ごとの構造の違いを十分に捉えきれず，精度に課題を残していた．

本研究では，既往研究の手法および改良したモデルを複数構築し，メッシュ単位で建物構造と築年次別の棟数を推定し，各モデルの精度を評価する．これにより，構造・築年次ごとにどの情報が精度向上に寄与するのかを明らかにすることを目的とする．

2. 建物構造・築年次推定モデルの構築

表 1 のとおり，入力データ以外の条件を統一した（乱数要素を含む）複数のモデルを構築することにより，どの入力データが精度向上に寄与するかを明らかにする．

2.1 建物構造・築年次推定モデルの概要

建物構造・築年次推定モデルには，畳み込みニューラルネットワークとして ResNet18 を採用した．ハイパーパラメータの設定にあたっては，学習率とバッチサイズを変化させたグリッドサーチを実施した（表 1, 2）．各組み合わせに対し，検証データにおける損失関数L（平均二乗

* 学生会員 東京科学大学 環境・社会理工学院（School of Environment and Society, Institute of Science Tokyo）
〒152-8550 東京都目黒区大岡山 2-12-1-M4-1 E-mail：ogino.k.275c@m.isct.ac.jp
** 正会員 東京科学大学 環境・社会理工学院（School of Environment and Society, Institute of Science Tokyo）

誤差，式(1)）の推移および評価指標を比較した結果，いずれのモデルにおいても安定した学習が確認された設定を最終的に採用した．

$$L = \frac{1}{NC}\sum_{i=1}^{N}\sum_{j=1}^{C}\left(\hat{y}_{ij} - y_{ij}\right)^2 \qquad \text{式(1)}$$

(N：データ数，C：建物属性数，$\hat{y}$：推定値，y：実測値)

2.1 建物構造・築年次推定モデルの入力データ

オープンアクセス衛星である Sentinel-2 の 2017 年 5 月 8 日のデータを使用した．可視光バンド 2，3，4 を超解像モデルにより 4 倍の解像度に向上させ，構築済みの建物外周線の検出モデル（荻野・大佛，2025）による推論を行い，最終出力結果とデコーダ最終段階の値を抽出した（図 1 (1)）．Sentinel-2 のマルチスペクトルデータ（図 1 (2)）は，外周線検出モデルのデータサイズに合わせるための前処理を行った（図 1 (2), 4)）．

2.2 建物構造・築年次の教師データ

本研究で推定する構造・築年代別の棟数は，表 2 の 11 分類とした．2010 年の町丁目単位で集計された構造・築年次別の棟数データを用い，東京都の建物現況調査データ（区部 2011 年度，多摩 2012 年度）に確率的に属性を付与した．乱数シードに基づき 100 ケースを生成し，500m メッシュごとに構造・築年次別の棟数を平均化して教師データとした．

メッシュ集計量とした理由は，建物単位の教師データが入手できなかったこと，衛星データの解像度および画像認識モデルのデータサイズの制約があったためである．

2.3 学習用・精度検証用の対象地域

対象地域は東京都全域とし，モデルの汎化性能を検証するため，学習と精度検証は異なる市区とした（図 2）．グリッドサーチのための検証データは，学習用データセットから無作為に 2 割を抽出した．

3. 建物構造・築年次推定モデルの精度評価

本章では，グリッドサーチにより決定した学習率 0.0001，バッチサイズ 64 の条件で学習したモデルの精度評価を行う．ただし，モデル 3 は，この値による精度が著しく悪かったため，学習率 0.0001，バッチサイズ 4 のモデルで精度評価を行う．

3.1 全体および構造・築年次別の精度評価

図 3 (1)は，精度検証データ全体に対する推定精度を示している．モデル 1 は，今回のモデル群の中で最も精度が低かった（$R^2 = 0.376$）．これに対してモデル 2 は，入力情報量の増加により精度が向上した（$R^2 = 0.513$）．建物外周線の情報を用いるより，外周線検出モデルのデコーダ最終段階の出力を活用することで，より高い精度を得られることを確認した．さらに，可視光や可視域外の情報を活用したモデル 3 およびモデル 4 では，精度が一層改善された（モデル 3：$R^2 = 0.563$, モデル 4：$R^2 = 0.644$）．

表1 構築した建物構造・築年次推定モデルの一覧

モデル名	入力データ	モデル構造[2)]	特徴
モデル1	U-Net[1)] 最終出力	ResNet 18	外周線から幾何的特徴の設計不要
モデル2	U-Net デコーダの最終段階	ResNet 18	最終出力の畳み込み処理前の値であり，モデル1より情報量が多い
モデル3	Sentinel-2 Band 2, 3, 4	ResNet 18	可視光画像のみを用いた設計
モデル4	Sentinel-2 Band 2, 3, 4, 8, 11, 12	ResNet 18	可視光に加えて，近赤外域・中間赤外域の情報を考慮した設計

1) 荻野・大佛（2025）は，セマンティックセグメンテーションモデルであるU-Netを用いて，建物外周線の検出モデルを構築した．
2) 学習率0.0001，0.001，バッチサイズ4，8，16，32，64の条件でグリッドサーチを行い，検証データの損失関数（平均二乗誤差）の推移および評価指標から全モデルで安定した学習が行われたハイパーパラメータを採用した．

(1) 建物外周線の検出モデルの出力値

データ種類	データサイズ (C, H, W)[1)]	解像度	表2との対応
最終出力[2)]	(1, 256, 256)	2.5 m	モデル1
デコーダの最終段階	(16, 256, 256)	2.5 m	モデル2

1) C：チャンネル数，H：高さ方向のピクセル数，W：横幅方向のピクセル数．
2) 各ピクセルが建物であるか否かの確率を表す．

(2) Sentinel-2のマルチスペクトルデータ[3)]

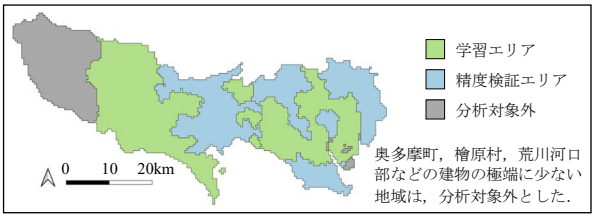
バンド名	中心波長	解像度[4)]	特徴	反射率の高い物質	表2との対応
Band 2	493 nm	10 m	青色	水体	モデル3, 4
Band 3	560 nm	10 m	緑色	健全な植生	モデル3, 4
Band 4	665 nm	10 m	赤色	土壌・裸地・構造物	モデル3, 4
Band 8	833 nm	10 m	近赤外域	植生	モデル4
Band 11	1,610 nm	20 m	中間赤外域	土壌・構造物	モデル4
Band 12	2,190 nm	20 m	中間赤外域	土壌・構造物	モデル4

3) Spatio Temporal Asset Catalog (STAC) を通じて取得したLevel-2Aプロダクト（幾何補正および大気補正済み）を使用した．
4) (1)のデータサイズに合わせるため，バイリニア補間により，解像度を2.5mに向上させ，上下左右の端から各28ピクセルをゼロ埋めし，(256, 256)にした．

図1 使用した建物外周線検出モデルの出力値と衛星データ

表2 構築した建物構造・築年次推定モデルの一覧

略称	構造	築年次	略称	構造	築年次
W-1	木造	1970年以前	RC-1	鉄筋コンクリート造	1970年以前
W-2	木造	1980年以前	RC-2	鉄筋コンクリート造	1980年以前
W-3	木造	1990年以前	RC-3	鉄筋コンクリート造	1981年以降
W-4	木造	2000年以前	S-1	鉄骨造	1970年以前
W-5	木造	2001年以降	S-2	鉄骨造	1980年以前
			S-3	鉄骨造	1981年以降



(1) 学習用・精度検証用・分析対象外エリアの空間分布

(2) 学習用・精度検証用データセットの内訳

地域	学習用データ数	精度検証用データ数
全域	3,341	2,356
区部	1,180	1,355
多摩	2,161	1,001

図2 学習・精度検証地域とデータセットの内訳

図 3 (2)は，構造・年次別の決定係数をモデルごとに示している．特筆すべきは，モデル 4 の RC 造棟数推定の大幅な精度向上であり，近赤外域・中間赤外域が RC 造の特徴抽出に寄与していることを示唆する．さらに，図 3 (3)で RC 造の築年代別推定精度を確認したところ，モデル 3 では過大・過少が散見されるが，モデル 4 では全体的に改善された．一方，モデル 4 の RC-1 では，過少推定が残っており，その要因については 3.3 節で検討する．

3.2 近赤外域・中間赤外域データの効果検証

3.1 節で確認した可視域外データの寄与をさらに検証するため，6 つの全バンドを用いたモデル 4 をベースラインモデルとし，Band 8，11，12 をそれぞれ 1 つずつ除外した 3 つのモデルを構築した．表 3 に結果を示す．

まず，Band 8（近赤外域）を除外した場合，R^2は 0.287 に大幅に低下した．これは，近赤外域データが推定精度に強く寄与していることを示している．一方で，Band 12（中間赤外域）を除外した場合もR^2は 0.449 と精度が低下しており，このバンドも一定の寄与を持つことが確認できる．これに対し，Band 11（中間赤外域）を除外した場合，R^2は 0.609 に留まり，MSE や MAE も大きく悪化していない．このことから，Band 11 の寄与は相対的に小さく，推定精度に対して必須でない可能性がある．

3.3 空間分布による精度評価

推定値と実測値との差を空間的に可視化し，残差の空間分布を検討した（図 4）．RC-1 の推定結果についてみると，モデル 3 では精度が低く，特に東部の一部地域において過大推定が広がっていた（図 4 (1)）．一方，モデル 4 ではこれら地域の過大推定が解消された（図 4 (2)）．ただし，神田，日本橋，銀座といった都心部では過少傾向が確認された．これは教師データと衛星データとの年度差により再開発の影響を十分に捉えられなかったこと，都心部での頻繁なビル改修に伴う外装材の更新によって建物年代の推定が困難になったことが一因と考えられる．

モデル 4 の W-1 をみると，残差分布の平均値は-4.17，標準偏差は 63.1 であり，残差の 79.3%が±1σ，93.3%が±2σに収まるなど，統計的には中心に強く集中する分布を示した．しかし空間分布に着目すると（図 4 (3)），足立区や板橋区，中野区の木造住宅密集地域（木密地域）で過少傾向，北部や東部の一部地域で過大傾向が確認された．これらの要因として，使用した衛星データの解像度（10～20m）の制約により，木密地域特有の細街路や小規模木造住宅を十分に捉えられなかったことが考えられる．

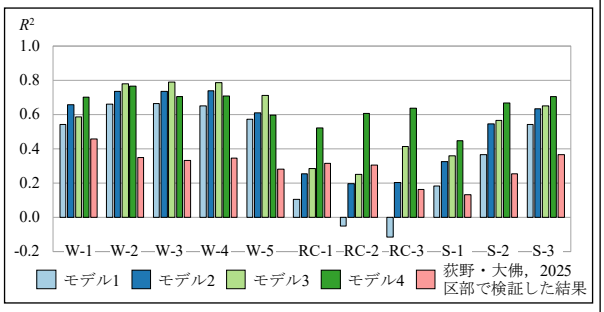
4. 木密地域までの近接度を考慮したモデルの構築

3.3 節で過少推定を確認した木密地域は，大地震時の建物倒壊リスクの高い地域であり，高精度な推定が求められる．本章では，木密地域までの近接度（地域特性）を考慮したモデルを構築し，木造棟数の推定精度向上を図る．

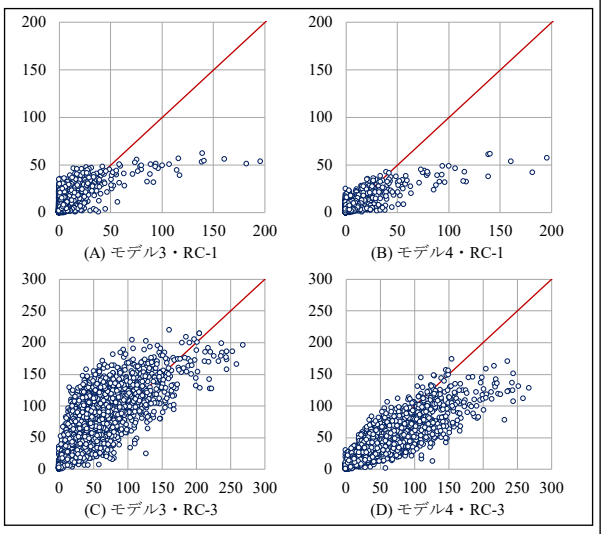
(1) 精度検証データセット全体の推定精度

モデル名 (表1対応)	学習率	バッチサイズ	損失関数L MSE[1]	RMSE[2]	MAE[3]	R^2[4]
モデル1	0.0001	64	1373	37.1	22.1	0.376
モデル2	0.0001	64	1052	32.4	18.8	0.513
モデル3	0.0001	4	1020	31.9	18.4	0.563
モデル4	0.0001	64	890.7	29.8	16.5	0.644
荻野・大佛，2025			1613	40.2	24.9	—[5]

1) 平均二乗誤差，2) 二乗平均平方根誤差，3) 平均絶対誤差，4) 決定係数
5) 構造・築年次別に説明変数が異なるため，(2)に各自由度調整済みR^2を示す．



(2) 構造・築年次別の推定精度 (縦軸：決定係数，横軸：表2の略称)



(3) モデル3，4のRC造の推定精度 (縦軸：推定棟数，横軸：実測棟数)

図3 建物構造・築年次推定モデルの推定精度

表3 近赤外域・中間赤外域データの影響度合い

除外バンド	学習率	バッチサイズ	損失関数L MSE	RMSE	MAE	R^2 (モデル4との差)
Band 8	0.0001	64	2582	50.8	25.9	0.287 (-0.357)
Band 11	0.0001	64	879.0	29.6	16.2	0.609 (-0.035)
Band 12	0.0001	64	1490	38.6	20.2	0.449 (-0.195)

4.1 木密地域までの近接度の算出方法・モデル概要

まず，東京都が公開している 2020 年度の町丁目単位の木密地域を衛星画像の分析解像度（2.5m）に合わせてラスタライズし，計算の高速化を図った．次に，図 5 (1)のフローチャートに従い，グリッド内の各ピクセルから木密地域までの最短距離 d [m] を算出し，その距離に基づいて近接度を表す指標 $r=\exp(-d/s),\ 0\leq r\leq 1$ を計算した．この指標は，ピクセルが木密地域内にある場合に 1 をとり，距離が大きくなるにつれて減衰する値である．なお，パラメータ s は，距離 d をどの程度のスケールで捉

えるかを調整する役割を持つ．

本研究では $B = 1500$ [m]（図 5 (1)），とし，$s = 50, 100, 200, 300, 400, 500$ [m] の各設定に対して r を算出した．その上で，モデル 4 にそれぞれの r を 1 チャンネルずつ追加し，7 チャンネルの画像を 6 パターン作成した．モデル 1 から 4 と同一のデータセットとモデル構造を用い，学習率 0.0001，バッチサイズ 64 の条件下で各パターンについて学習を行い，検証データの損失関数の値が最も低いパターンを採用した．

4.2 木密地域までの近接度を考慮した結果

図 5 (2)にモデル 4 と木密地域までの近接度を考慮したモデル（モデル 5）の推定結果を比較して示す．ここで，$s = 400$ [m] で計算した r を採用した．これにより，木密地域の影響範囲を比較的広く評価する．木造棟数の決定係数は，全築年代でモデル 4 を上回った（図 5 (2) (A)）．また，図 5 (2) (B)の W-1 の推定精度において，モデル 4 で過少推定が見られた箇所が，モデル 5 では改善が確認された．該当する地域は，図 5 (2) (C)に示す板橋区や中野区である．一方で，足立区は，一定の改善傾向は見られるものの，依然として過少推定が残っていた．木密地域までの近接度だけでは説明できない，土地利用や建物配置といった地域特性の影響があると考えられる．

5. おわりに

建物構造と築年次別の棟数推定において，可視光に加えて近赤外域と中間赤外域を利用することの有効性を確認した．さらに，木密地域までの近接度を衛星データに結合する手法を検討し，その有効性を検証した．その結果，木密地域のデータが整備されている地域ではモデル 5 を，未整備地域ではモデル 4 を適用することで，データ整備状況に応じた柔軟な利用が可能であることを示した．

謝辞

本研究は JSPS 科研費 JP25KJ1248 と日本科学協会の笹川科学研究助成（2024-2022）の助成を受けたものです．

参考文献

沖拓弥・小川芳樹 (2021) 不動産データベースの外観画像と属性情報を用いた建物構造・築年代推定モデル.「日本建築学会計画系論文集」, **86** (779), 357-367.

荻野光司・大佛俊泰 (2025) オープンアクセス衛星データを用いた建物検出・属性推定の統合モデルの構築.「日本建築学会計画系論文集」, **90** (837), 掲載予定.

Du, S., Zhang, F. and Zhang, X. (2015) Semantic classification of urban buildings combining VHR image and GIS data: An improved random forest approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, **105**, 107-119.

Frantz, D., Schug, F., Okujeni, A., Navacchi, C., Wagner, W., van der Linden, S. and Hostert, P. (2021) National-scale mapping of building height using Sentinel-1 and Sentinel-2 time series. *Remote Sensing of Environment*, **252**, 112128.

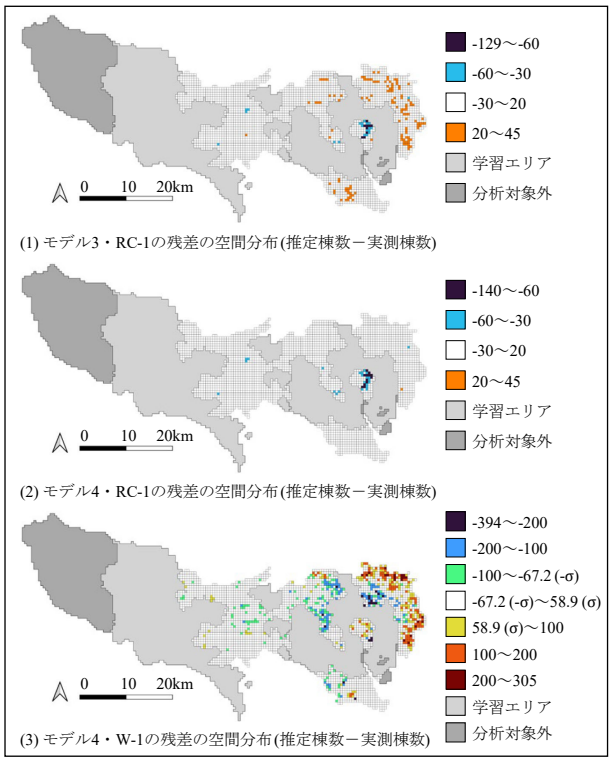


図4 モデル3，4の推定誤差の空間分布

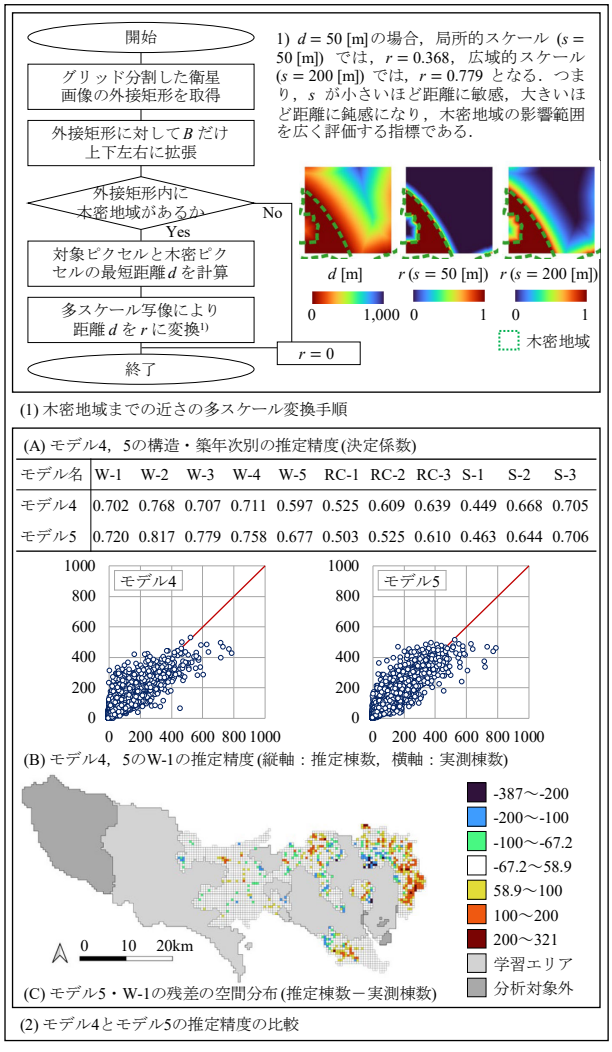


図5 木密地域までの近さを考慮したモデル概要および結果