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)]

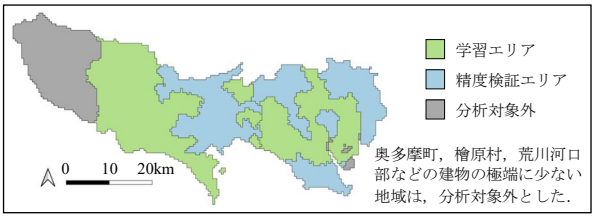
バンド名	中心波長	解像度[4)]	特徴	反射率の高い物質	表2との対応
Band 2	493 nm	10 m	青色	水体	モデル3, 4
Band 3	560 nm	10 m	緑色	健全な植生	モデル3, 4
Band 4	665 nm	10 m	赤色	土壌・裸地・構造物	モデル3, 4
Band 8	833 nm	10 m	近赤外域	植生	モデル4
Band 11	1,610 nm	20 m	中間赤外域	土壌・構造物	モデル4
Band 12	2,190 nm	20 m	中間赤外域	土壌・構造物	モデル4

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．

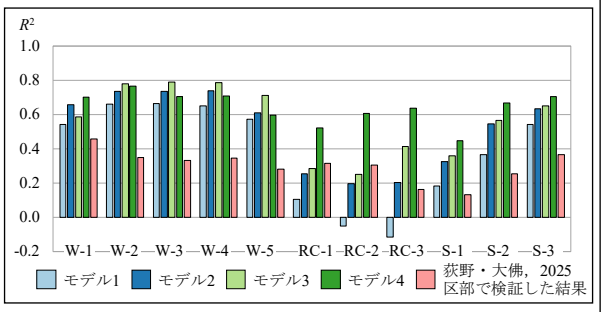
4. 木密地域までの近接度を考慮したモデルの構築

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．

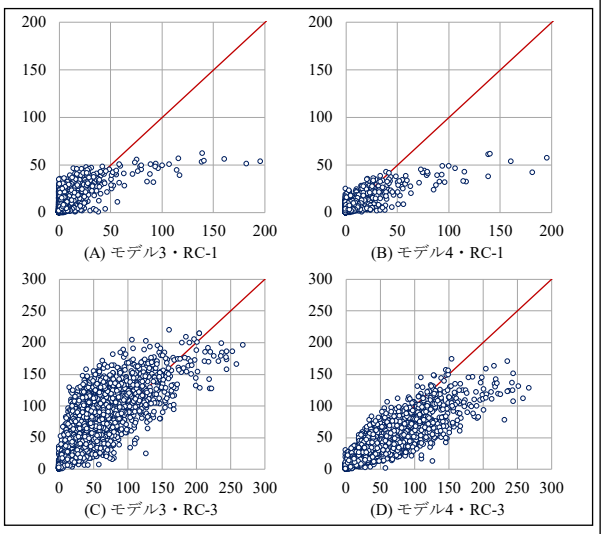
(1) 精度検証データセット全体の推定精度

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.

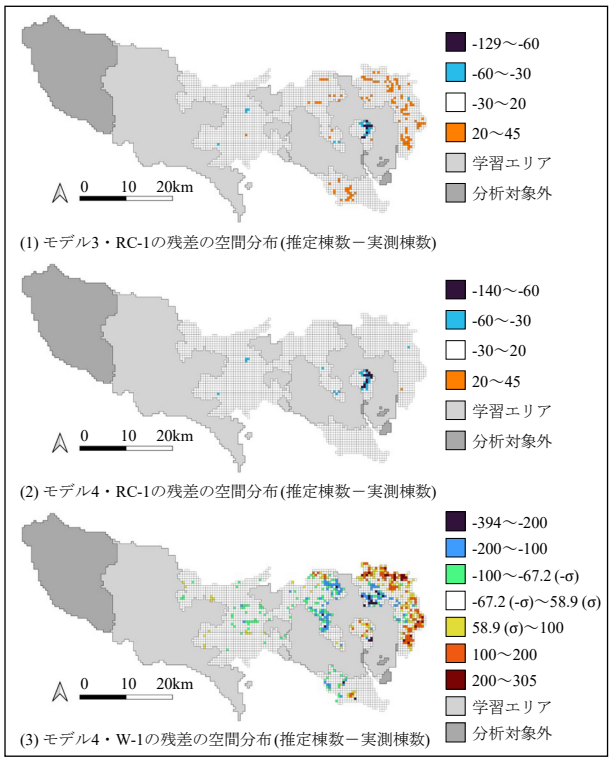


図4 モデル3，4の推定誤差の空間分布

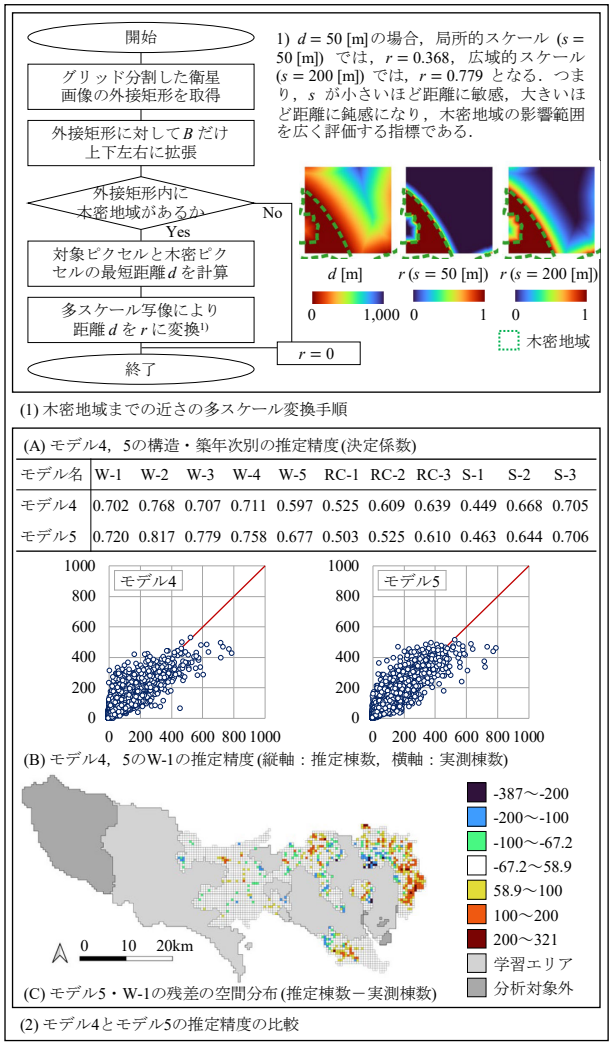


図5 木密地域までの近さを考慮したモデル概要および結果