

深層学習を用いた衛星画像からの建物抽出モデルの外挿による開発途上国の建物データ整備

東京都市大学 正会員 ○山野寺 瞭太

東京都市大学 正会員 秋山 祐樹

東京大学 空間情報科学研究センター 非会員 宮崎 浩之

1. はじめに

近年、開発途上国の多くの都市で人口が爆発的に増加している。都市の持続的な開発・発展には適切な都市計画・交通計画の立案が重要であり、その立案の際に不可欠な情報の1つが人口統計である。しかし、開発途上国の人口統計の整備はカバーする範囲や更新頻度が不完全な場合も多く、現状の人口分布の把握が困難である。そのため、これらの国では高い解像度で人口分布を把握する技術が求められている。Kaiser. et al. (2017)は深層学習を用いて衛星画像から人口が分布する建物を自動抽出する手法を開発しているが、開発途上国では、深層学習の教師データとなる建物データが利用できない、あるいは整備が不完全である場合が多いという課題がある¹⁾。そのため、十分な学習データや検証用データの確保ができないという問題がある。

そこで本研究では、まず高性能な建物データを利用できる日本で建物抽出モデルを作成する。そして、このモデルを開発途上国に外挿することで、正解データが十分に整備された先進国で整備した建物自動抽出モデルを、開発途上国などの正解データが少ない地域に外挿する手法の妥当性を検討する。

2. 検討手法

まず、学習データとして様々な統計・空間情報が利用可能である東京都新宿区、世田谷区、八王子市を学習データとして建物自動抽出モデルを構築した（以下、「東京モデル」）。次に、タイのバンコク都全域（以下「バンコク」）を対象に、現地で開発したモデルとの精度を比較するために、後述する検証エリア以外のバンコクのデータを学習データとする建物自動抽出モデルを構築した（以下、「バンコクモデル」）。そして、バンコクのトンロー地区を検証エリアとして、建物自動抽出の精度検証を行った。

3. 使用したデータ

本研究では衛星画像と建物形状のポリゴンデータ

（以下、「建物ポリゴン」）の2種類のデータを用いて、モデル構築に必要な学習データを作成した。衛星画像は対象地域の GoogleMap の背景画像を使用した。また、建物ポリゴンは、東京モデルは株式会社ゼンリンの住宅地図（2020 年）、バンコクモデルは Microsoft 社の Global MLBuilding Footprints を使用した²⁾。本研究ではこれらを 6:2:2 の割合で、学習データ、検証データ、テストデータに分類した。

4. 衛星画像からの建物自動抽出

まず、衛星画像と建物ポリゴンから、衛星画像に対応する範囲の建物ポリゴンを用いて学習データを作成した。次に、作成した学習データを用いて、深層学習モデルを構築した。本研究では、Meta 社の detectron2 というライブラリを用いて転移学習を行い、モデルを構築した³⁾⁴⁾。これにより、東京とバンコクの建物抽出モデルを作成することができた。最後に、本研究で作成した建物自動抽出モデルを用いて、バンコクの中心市街地に位置するトンロー地区で建物自動抽出、精度検証を行った。図-1 に検証用の GlobalMLBuildingFootprints と各モデルによる建物抽出結果を示す。

5. 精度の検証

本研究の評価指標としては、建物の抽出結果と建物ポリゴンの重なりを評価する IoU（Intersection over Union）と、抽出された建物数と建物ポリゴン上の建物数の一致率を示す建物抽出率を用いた。以上の評価指標を用いて東京モデルとバンコクモデルの両方に対して精度検証を行い、東京モデルの精度がバンコクモデルが同等の精度を保有しているか否かを検証した。

表-1 にトンロー地区における各モデルの精度を示す。その結果、両モデルとも IoU と建物抽出率は 60%以上となった。また、東京モデルとバンコクモデルの精度を比較すると、IoU と建物抽出率ともに 10%程度の差があることが分かる。しかし、図-1 によると、東京モデルを使用してもバンコクモデルとほぼ同様の抽出結果が

キーワード 都市計画、開発途上国、衛星画像、建物、深層学習、外挿

連絡先 〒158-8557 東京都世田谷区玉堤 1-28-1

東京都市大学世田谷キャンパス TEL03-5707-0104

得られていることが分かる．これらの結果から，東京モデルの開発途上国への外挿は，改善の余地はあるものの，十分可能であることが明らかとなった．

6. 考察

本研究では，東京モデルとバンコクモデルを用いて，衛星画像から建物を自動抽出した際の精度検証を行った．その結果，両モデルをトンロー地区に外挿した際の精度に有意な差は認められず，モデルの外挿は十分に可能であることが示された．本研究で見られた精度の違いの理由は，学習させる建物の特性の違いに起因するものと考えられる．著者らによるトンロー地区を対象とした現地調査（2022 年 12 月 15 日実施）によると，トンロー地区には赤茶色などの濃い色の瓦屋根の建物が密集している地区が多く分布しており，そのような

建物が周囲の樹木と同化してしまい，目視でも建物の位置や範囲を特定することが難しい地区が形成されていることが分かった．そして，そのような地区では，抽出精度が低下していることが分かった．さらに，樹木も日本と異なり常緑樹であるため，色調が日本より濃いものが多い．その樹木が建物と建物の間を埋めるように繁茂するため，建物の抽出がより困難な状況になっているものと考えられる．今回使用した東京の衛星画像には，そのような地区はあまり含まれていなかったため，東京モデルの外挿精度が上がらない原因になっているものと考えられる．一方，東京でもよく見られる赤や白など明るい色調の屋根を持つ建物は，十分に抽出できていることが分かった．これらの課題を改善するためには，同じような特徴を持つ建物や立地環境を有する地域を学習範囲に加えることで，モデルの精度を向上させることができるものと考えられる．

7. まとめ

本研究では東京において建物抽出モデルを作成し，バンコクで作成した建物抽出モデルと抽出精度の比較を行うことで，先進国で整備した建物抽出モデルの開発途上国への外挿可能性を検討した．その結果，一定の精度で外挿可能であることが分かった．今後は，本研究の精度検証や現地調査で明らかになった様々な要素を考慮し，学習データをさらに充実させることで，モデルのさらなる精度向上や，世界の様々な地域でチューニングできるよう研究を進めていきたいと考えている．

謝辞

本研究は JSPS 科研費（JP20H01483）の助成を受けたものです．ここに記して謝意を表します．

参考文献

1) Kaiser, P., Wegner, J., Lucchi, A., Jaggi, M., Hofmann, T. and Schindler, K., “Learning Aerial Image Segmentation from Online Maps”, *IEEE Transactions on Geoscience and Remote Sensing*, Vol.55, No.11, 2017.

2) Microsoft: GlobalMLBuildingFootprints, <<https://github.com/microsoft/GlobalMLBuildingFootprints>>, (accessed March 28, 2023)

3) Gkioxari, H, K., Dollár, G. and Girshick, R. :Mask r-cnn, *Proceedings of the IEEE international conference on computer vision*, pp. 2961-2969, 2017.

4) Facebookresearch :Detectron2, <<https://github.com/facebookresearch/detectron2>>, (accessed March 28, 2023)




図-3. 検証用の建物ポリゴン（上）と自動抽出結果（東京モデル（中），バンコクモデル（下））

表-1. トンロー地区における各モデルの精度

	東京モデル	バンコクモデル
IoU (%)	64.34	76.02
建物抽出率 (%)	62.08	75.09