

AI等を活用した地図作成の効率化に向けた技術開発 －空中写真及び衛星画像を用いた地図の自動作成－

実施期間

令和7年度

基本図情報部地図情報技術開発室

藤原 博行

長野 玄

野口 真弓

大久保 弘樹

神山 優恵

1. はじめに

電子国土基本図は、我が国の地理空間情報のデータ基盤として、国・地方公共団体の行政サービス等を支える信頼性の高い位置情報を提供するベース・レジストリとしての役割を担っている。

これまで国土地理院においては、空中写真や大縮尺地図を活用し、電子国土基本図（地図情報）の整備・更新を行ってきたが、近年は人工衛星から得られる高分解能衛星画像の利活用が進むとともに、機械学習技術の急速な発展により、地図作成工程の自動化が現実的な選択肢となりつつある。本稿では、こうした技術的背景を踏まえ、地図作成工程の効率化及び継続的な更新体制の構築を目指して、建物及び道路を対象とする自動取得技術の開発成果を報告する。

2. 空中写真及び衛星画像から地図を自動作成する技術開発

本技術開発は空中写真及び衛星画像を活用して、建物及び道路を対象とした地物の形状を自動取得し、既存地図との整合を行うことで、地図作成工程の自動化（自動作成）を目指すものである。令和7年度は地物形状の自動取得に関する技術開発を実施した。

技術開発は①地物領域を自動抽出するAI図化モデルの選定、②AI図化モデルの学習データ構築、③AI図化モデルの性能評価、④AI推論結果に対する後処理の検討、⑤図化データの性能評価、⑥AI図化モデルによる地図作成工程の効率化の検証の流れで開発・検討を実施した。

2.1 地物領域を自動抽出するAI図化モデルの選定

建物及び道路を自動抽出するに当たり、近年に提案された衛星画像や空中写真の地物抽出に特化したセマンティックセグメンテーション手法を対象に調査を実施し、Polygonization-by-Frame-Field-Learning（以下「PFFL」という。）及びSAMPolyBuildをAI図化モデルの検討候補として選定した。

PFFLはCNN（Convolutional Neural Network）モデルを用いて画素単位で地物領域を抽出してから、その「向き」や「角」など図化に関する情報を数学的に学習させることで、直線的な境界線で整った形状を導き出す手法である（Girard et al., 2021）。

SAMPolyBuildは、領域抽出結果の改善に注目し、セマンティックセグメンテーションにおいて高い汎化性能を発揮するSAM（Segment Anything Model）を活用することを提案した手法である。初めに物体検出モデルにより、対象物の領域抽出を行い、SAMを用いてポリゴン頂点の位置を最適化することで、複雑な形状をしている建物にも対応できることが特徴となる（Wang et al., 2024）。

本技術開発で採用するAI図化モデルの選定に当たり、PFFLとSAMPolyBuildの性能比較を実施した。オルソ画像並びに当該オルソ画像を用いて作成した建物及び道路データを用いて学習することで、PFFLがSAMPolyBuildより高い性能を達成して汎化性能も高くなることが確認できた。

上記の比較検証結果に基づき、建物及び道路ともに、PFFLを本開発のAI図化モデルとして選定した。

2.2 AI 図化モデルの学習データ構築

様々な地域や撮影状況の空中写真や衛星画像に適用可能な AI 図化モデルの構築に当たり、モデルの汎化性能と再現性が重要となる。AI 図化モデルに学習させるデータにおいて、地域特徴（都市部、耕地部、森林部等）に偏りがある場合、汎用的なモデル構築が困難となるため、各種偏りの少ない学習データを構築する必要がある。今回、学習データは国土地理院が保有する 4 地域のオルソ画像（地上画素寸法 20 cm）並びに当該オルソ画像を用いて過年度に作成した電子国土基本図（地図情報）の建物及び道路データを用いた。構築した学習データの概要を表-1 に整理する。地域特徴・撮影時期による学習データの偏りを抑制するため、各地域から同程度の数量のデータをサンプリングする等の対策を実施した。

また、地域ごとに、学習に用いるデータと評価に用いるデータを図-1～図-3 のとおり 8:2 程度の割合で分け、「2.3 AI 図化モデルの性能評価」及び「2.5 図化データの性能評価」では、学習に用いていないデータによって評価した。

表-1 学習データの概要

地域	地域特徴	画像の見た目	撮影時期
水戸	主に都市部，耕地部で構成。 農地，山，河川，大規模工場あり。	全体的に黄色。	4 月
埼玉	主に都市部，耕地部で構成。 河川，団地，大型商業施設，工業施設あり。	全体的に緑色。植生あり。	6 月
甲府	主に都市部で構成。 農地，山，河川，工業施設あり。	全体的に黄色。	10 月
奈良	主に都市部，森林部で構成。 山，中小河川あり。	全体的に緑色。植生あり。 雲の影響か，明暗の変化あり。	5 月



図-1 水戸地区における学習に用いるデータ（黄色破線）と評価に用いるデータ（赤色破線）




図-2 埼玉地区における学習に用いるデータ（赤色図郭）と評価に用いるデータ（青色図郭）




図-3 甲府地区（左図）と奈良地区（右図）における
学習に用いるデータ（赤色図郭）と評価に用いるデータ（青色図郭）

2.3 AI 図化モデルの性能評価

前節の学習データで学習した AI 図化モデルの性能について、表-1 に記載した 4 地域全ての学習データで学習した AI 図化モデルと 1 地域（水戸）のみの学習データで学習した AI 図化モデルの建物及び道路の形状推定精度と形状検出精度を比較し、評価した。形状推定精度とは、抽出した建物及び道路が実際の形状（既存の電子国土基本図（地図情報）の建物及び道路データ）とどれだけ一致しているかを指し、形状推定精度の評価指標として IoU（Intersection over Union）を用いた。また、形状検出精度は、オルソ画像から検出した建物及び道路が正しく分類できているかを指し、適合率（precision）、再現率（recall）及び F1 スコア（F1-score）を用いて評価した。それぞれの指標に関する概要を表-2 に示す。

表-2 性能評価に用いた指標に関する概要

指標	指標の特徴
IoU (Intersection over Union)	AI が推定した領域と正解領域の重なり度合い 1 に近いほど、AI 図化モデルの形状推定精度が高いことを示す
適合率 (precision)	AI が推定した結果のうち、正しいものの割合 1 に近いほど、誤検出が少ないことを示す
再現率 (recall)	正解のうち、AI が検出できたものの割合 1 に近いほど、検出漏れが少ないことを示す
F1 スコア (F1-score)	適合率と再現率の調和平均 1 に近いほど、AI 図化モデルの形状検出精度が高いことを示す

建物の形状推定精度と形状検出精度の定量評価結果を表-3 に示す。4 地域の学習データで学習した AI 図化モデルは 1 地域のみで学習した AI 図化モデルよりも建物の IoU がおおむね向上しており、AI 図化モデルの形状推定精度が全体的に向上したことを確認した。また、建物の形状検出精度についても、1 地域で学習したモデルよりも F1 スコアは同程度、あるいは改善する傾向を示し、AI 図化モデルの形状検出精度が向上したと考えられる。再現率も改善され、検出漏れが減少する傾向が確認できた。一方、適合率は悪化する傾向になり、面積の小さい領域を過剰に抽出することによって誤抽出が多くなることが課題となった。

面積の小さい領域の誤抽出が多い課題に対しては、改善のための追加学習の時間・作業量コストを鑑み、抽出後に面積の小さい建物を除外するフィルタリング処理を行うことで対応する。これらの結果から、4 地域の学習データで学習することで、建物の抽出性能の改善を確認できたと考えられる。

本結果から、建物を対象とした場合、特定地域のみの学習データで学習した AI 図化モデルでは、当該地域外のデータに対する形状推定精度及び形状検出精度が十分に得られない例が確認できた。この課題に対しては、地域特性に偏りが生じないように選定した複数地域の学習データを用いることが有効であることが明らかとなった。一方で、建物形状には地域特有の差異が存在するため、特定地域の学習データと複数地域の学習データを適切に使い分けることも重要であると考えられる。

表-3 建物の形状推定精度と形状検出精度の定量評価結果

評価データ	学習データ	IoU	再現率	適合率	F1 スコア
水戸	水戸のみ	0.651	0.637	0.370	0.469
	4 地域	0.649	0.674	0.320	0.433
埼玉	水戸のみ	0.449	0.272	0.343	0.303
	4 地域	0.674	0.706	0.324	0.444
甲府	水戸のみ	0.692	0.605	0.337	0.433
	4 地域	0.708	0.629	0.309	0.414
奈良	水戸のみ	0.428	0.218	0.407	0.284
	4 地域	0.616	0.596	0.277	0.378

道路の形状推定精度と形状検出精度の定量評価結果を表-4 に示す。4 地域の学習データを用いて学習した AI 図化モデルは道路において、学習データを 1 地域から 4 地域に拡張することで、IoU は水戸と奈良で改善、埼玉と甲府で悪化する傾向を示し、再現率は全地域で上昇したことを確認した。道路抽出において、学習データを 4 地域に拡張することは建物抽出ほど顕著な汎化性能の改善は見られなかった。これは建物と比較して、形状やテクスチャのパターンが定型的な道路が多く、地域特徴による変化が相対的に少ないことが原因と考えられる。

表-4 道路の形状推定精度と形状検出精度の定量評価結果

評価データ	学習データ	IoU	再現率	適合率	F1 スコア
水戸	水戸のみ	0.617	0.315	0.020	0.038
	4 地域	0.628	0.427	0.011	0.022
埼玉	水戸のみ	0.734	0.482	0.017	0.033
	4 地域	0.698	0.490	0.008	0.016
甲府	水戸のみ	0.734	0.472	0.012	0.023
	4 地域	0.680	0.528	0.006	0.012
奈良	水戸のみ	0.516	0.155	0.011	0.021
	4 地域	0.679	0.370	0.008	0.016

2.4 AI 推論結果に対する後処理の検討

AI 図化モデルが抽出した画素単位のラスター形式の建物及び道路領域を、図化作業に扱うベクトル形式のポリゴンデータにするためには、変換処理が必要となる。ラスターの形状を考慮せず、直接ポリゴンに変換する場合、ポリゴンの頂点が大量に生成され、地図情報レベル 2500 で表現されるような直線的で整った表現にならず、既存の地図に統合する際の障害となることが懸念される。このため、AI による推論結果を図化データに変換する際にライン長・曲率・直角頂点の優先度といった変換パラメータの重み付けを変更することで、最適な図化形状になるよう調整を実施した。建物領域のポリゴン変換処理前後のイメージ図を図-4 に示す。




図-4 建物領域ポリゴンの変換処理結果（イメージ図）

また、道路領域に関しては、変換処理により作成した道路領域ポリゴンの輪郭が細かい階段状に変化しており、ノード数も非常に多く、そのままでは図化データとしての利用が難しいことが判明した。

当該事象が起こる要因としては、図化データへの変換アルゴリズムが直線及び直角形状を重視した特性を持つため、道路のような細長く連続的で滑らかな形状との親和性が低いことが考えられる。そのため、変換パラメータでの調整ではなく、図-5 に示す不要なノードを削除して形状を滑らかに整える平滑化処理で対応した。



図-5 道路領域ポリゴン平滑化処理の結果

2.5 図化データの性能評価

前節までに示した AI 図化技術の開発成果を踏まえて、当該技術で図化した建物及び道路（以下「AI 図化データ」という。）の図化精度について検証した。具体的には、建物及び道路の AI 図化データについて、地図情報レベル 2500 の精度基準への適合性を検証した。検証エリアは、学習データとして用いた水戸・埼玉・甲府・奈良の 4 地域から、建物が密集するエリアと郊外の 2 地区をそれぞれ選定した。

2.5.1 建物データの評価

建物の図化結果については、正解図化データとの比較による位置精度の評価を実施した。正解図化データ及び AI 図化データの建物ポリゴンからそれぞれ重心点を生成し、両者の対応関係を確認し、1 対 1 の対応関係が成立する建物のペアを作成した。

AI 図化データには、建物形状の分割単位の違いにより 1 棟の建物が複数のポリゴンとして抽出されるケースや、AI 図化モデルの誤検出、電子国土基本図（地図情報）において取得対象外とする小規模構造物等が含まれており、1 対 1 の対応関係が成立しない場合がある。これらについては評価対象から除外し、1 対 1 の対応関係が成立した建物を評価対象として、重心位置の較差から標準偏差を算出することにより、位置精度を評価した。

建物の位置精度の評価方法の概念図を図-6 に示す。




図-6 建物の位置精度の評価方法（概念図）

評価に当たり、正解建物のデータ数に対して1対1対応が成立したAI図化建物データの割合（成立率）を確認した。続いて、評価対象の建物（1対1対応が成立した建物）について重心位置の較差から標準偏差を算出し、地図情報レベル2500の位置精度よりも厳しく設定した基準値（標準偏差1.75m）と比較した。

上記の評価方法に基づく、水戸・埼玉・甲府・奈良の4地域の位置精度評価結果を表-5に示す。

表-5 AI図化建物データの位置精度評価結果

地域	正解建物数	AI建物数	1対1成立数	成立率	最大較差 (m)	標準偏差 (m)
水戸	1,634	2,398	1,530	94%	13.24	1.31
埼玉	3,523	4,166	3,284	93%	9.98	0.80
甲府	1,921	3,019	1,717	89%	11.65	1.47
奈良	1,402	2,214	1,250	89%	16.13	1.79

正解建物数に対して1対1の対応が成立した建物の割合は、全ての地域において90%程度となり、良好な結果となった。これは、AI図化建物データの多くが正解建物データと対応関係を持つ建物として抽出されていることを示している。

また、評価対象建物の重心位置の較差から算出した標準偏差は、水戸地域1.31m、埼玉地域0.80m、甲府地域1.47m、奈良地域1.79mとなり、基準値（標準偏差1.75m）と比較したところ、水戸、埼玉及び甲府地域では基準値より小さく、奈良地域では基準値を僅かに越える結果となった。なお、奈良地域については、オルソ画像と正解建物データの建物位置に全体的なずれが見られる傾向が確認されており、作成時期の差異や原典資料の違い等の影響が考えられる。

2.5.2 道路データの評価

道路については、AI図化モデルにより抽出された道路縁データについて、地図情報レベル2500の精度基準への適合性を確認するため、正解道路縁データとの位置関係の比較による位置精度の評価を実施した。道路は線形地物であるため、建物のように個別の対応関係を定義することが難しい。このため本検証では、正解道路縁データに対して左右それぞれ1.75mのバッファを生成し、このバッファ

内に含まれる AI 図化道路縁データの延長割合を算出することにより位置精度を評価した。

具体的には、AI 図化モデルにより抽出された道路縁の総延長を母数とし、そのうち正解道路縁データの 1.75 m のバッファ内に含まれる道路延長の割合を算出した。

道路の位置精度の評価方法の概念図を図-7 に示す。また、評価方法に基づく、水戸・埼玉・甲府・奈良の 4 地域の位置精度評価結果を表-6 に示す。




図-7 道路の位置精度の評価方法（概念図）

表-6 AI 図化道路縁データの位置精度評価結果

地域	AI 図化道路縁 総延長 (m)	精度範囲内 延長 (m)	割合
水戸	71,044.96	49,954.74	70%
埼玉	102,273.38	75,094.76	73%
甲府	79,570.08	46,780.59	59%
奈良	81,995.17	55,635.61	68%

正解道路縁データに対する 1.75 m バッファ内に含まれる AI 図化道路縁データの延長割合は、全ての地区においておおむね 60%以上を満たす結果となった。

2.6 AI 図化モデルによる地図作成工程の効率化の検証

本技術開発では、従来の手法における数値図化にかかる作業時間が、AI 図化モデルの利用によって 3 割程度削減されることを目標とした。技術開発の効果を検証するため、従来の作業による地図更新作業と AI 図化モデルを用いた更新作業との作業時間を比較した。

検証は水戸地域の 2 図郭（約 2 km×約 1 km）を対象とし、地物は建物のみに限定した。

従来工程では、約 360 分を要したのに対し、AI 図化モデル活用時は約 260 分となり、今回の検証においては、3 割程度の作業時間削減が確認された。

ただし、本検証は対象地域及び地物が限定的であるため、今後は検証地域の拡大に加え、道路を対象とした検証も実施する予定である。

3. 空中写真及び衛星画像から地図を自動作成する技術を利用したプログラムの開発

地図作成工程の効率化のため、前章で述べた技術を用いて、表-7に記載する機能を実装したプログラムを作成した。プログラムはシンプルな UI になっており、AI の専門知識がない者でも地物領域推論やモデルの追加学習を行えるようなプログラムを目指した。開発したプログラムの地物領域推論実行時の UI を図-8 に示す。オルソ画像を入力し、各種パラメータを選択・設定することで図化結果がシェープファイル（SHP）で出力される。

表-7 開発したプログラムの機能一覧表

機能	概要	入力	出力
地物領域推論	入力した TIFF 形式のオルソ画像から地物（建物・道路領域の 2 モデル）のポリゴンを出力。	TIFF 画像	ポリゴン SHP
モデルの追加学習	既存の 2 モデルをベースに、学習用の正解データを追加入力することで、追加学習を実施。	TIFF 画像、正解データの SHP	モデル重み
建物の異動判読	2 時期の建物領域 SHP を入力し、IoU を基準に指定しきい値以下の場合を更新と判定。	2 時期の建物 SHP	更新箇所 SHP
道路の更新判読	2 時期の道路領域 SHP 及び旧時期の道路中心線 SHP（未入力の場合はポリゴンから自動抽出）を入力。 ポリゴンを交差点単位で分割し、道路単位で IoU を算出して更新判定を実施。 新時期 AI 推論ポリゴンの外周線を抽出し、平滑化処理（2.4 節）を行った上で出力。	2 時期の道路領域 SHP, 旧時期の道路中心線 SHP（任意）	更新箇所（道路縁）SHP, 旧時期道路縁・中心線, 新時期道路縁・中心線（平滑化済み）SHP
道路中心線抽出	道路領域から道路中心線を自動抽出。	道路領域 SHP	道路中心線 SHP

入力

タスク名

PRIL推論-9531485e-7b2d-409d-4ba2-9bc2ea873d2e

入力画像(複数) *

ファイルの選択

ファイルが選択されていません

アップロード

スナップショット

この画像は必須です。サーバ上のアップロード先にファイルがありません。

複数選択可。未指定なら /data/app_temp/job_id/input が使われます

サーバ上のファイル

(なし)

学習済みモデル *

2026-03-10-test1_69a3d | 2026-03-10 08:49:20

building: 建物モデル 適用解像度(0.2m)

road_backbone: 道路モデル 適用解像度(0.2m)

リサンプリング解像度 *

0

推論画像とモデルの適用解像度が通り場合、適用解像度を指定してください。

単位(m)

0を指定するとリサンプリングを行いません。

出力SHP名 (拡張子不要) *

result

フィルタリング閾値 *

1.25

指定した閾値条件を満たさないオブジェクトをフィルタリングします

単位(m)

画像正規化方式 *

☒ input
☐ train

画像のRGB正規化方式

- input: 入力画像ごとに正規化
- train: 学習データの統計値を用いて正規化

※ 一般的に地域では input を推奨。

※ 山間部や農地など、色バリエーションが多い場合は train を推奨。

図-8 地物領域推論実行時の UI

4. 地物領域推論の試行

前章で作成したプログラムに実装した機能のうち、地物領域推論機能について、試行作業を行った。試行地区として幅員区分の異なる様々な道路や住宅街が存在する熊本県宇城市を選定した。熊本県宇城市中心部周辺の地上画素寸法 20 cm のオルソ画像を入力し、地物領域推論を実行した結果を図-9 に示す。左図に入力したオルソ画像、右図に地物領域推論の結果を表示する。全体的に建物及び道路が大きく破綻することなく推論できていることが確認できる。




図-9 地物領域推論の入力画像（左図）と推論結果（右図）（熊本県宇城市）

道路の推論結果について、道路の幅員区分ごとに良否を分けて抽出した結果を図-10 に示す。図に示すのは、入力したオルソ画像に推論した道路縁を重畳表示させたものである。推論結果が良の箇所については幅員区分によらず、道路縁の端を正確に推論できた。推論結果が不良となった箇所では影により道路縁が見えにくい、歩道や車道と周囲の建物の敷地との境界部がはっきりしていない、立体交差の下側の道路が確認できない等、オルソ画像に明瞭に映っていないことが原因と思われる誤抽出が確認できた。


	幅員区分:3-5.5m未満	幅員区分:5.5-13m未満	幅員区分:13-19.5m未満
推論結果 良			
推論結果 不良	他の道路と接続しない 浮き道路が発生 	歩道や車道等の境界が曖昧 なことによる道路のゆがみ 	立体交差部を通常の交差点 として取得 

図-10 道路の推論結果

建物の推論結果について、建物の大きさを小規模、中規模及び大規模に分け、それぞれ良否を分けて抽出した結果を図-11 に示す。小規模には家屋などの建物、中規模にはスーパーマーケットなどの建物、大規模には学校や工場などの建物がそれぞれ含まれる。オルソ画像で明瞭に建物の縁が判断できる建物については正確に推論が行えているが、道路と同様にオルソ画像で影になっている箇所を誤って建物として推論するような例が見受けられた。また、中規模以上の建物については、形状が正しく推論できていない建物が多く見られるため、別の地区での試行を引き続き実施する予定である。


	普通建物	普通建物(中規模)	普通建物(大規模)
推論結果 良			
推論結果 不良			

図-11 建物の推論結果

5. まとめ

空中写真及び衛星画像を用い、建物及び道路を対象として地物の形状を自動的に取得する技術開発を実施し、当該機能を有するプログラムを作成した。今後は複数の地区で地物推論及び AI 図化モデルを用いた地図作成工程の効率化に関する試行作業を進め、問題点や改善点を整理することで、地物推論の精度向上を図るとともに、地図作成工程の効率化及び継続的な更新体制の構築を目指す。

参考文献

- Girard, N., Smirnov, D., Solomon, J., and Tarabalka, Y. (2021): Polygonal Building Extraction by Frame Field Learning, 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 5887–5896. doi:10.1109/CVPR46437.2021.00583
- Wang, C., Chen, J., Meng, Y., Deng, Y., Li, K., and Kong, Y. (2024): SAMPolyBuild: Adapting the Segment Anything Model for polygonal building extraction, ISPRS Journal of Photogrammetry and Remote Sensing, 218, 707–720. doi:10.1016/j.isprsjprs.2024.09.018