

# AI を活用した地物自動抽出に関する研究（第 5 年次）

実施期間 平成 30 年度～令和 4 年度  
地理地殻活動研究センター  
地理情報解析研究室 大野 裕幸 浦 郁子

## 1. はじめに

本研究は、労働集約的な業務構造となっている空中写真測量による地図作成に、近年画像認識の分野にブレイクスルーをもたらした畳み込みニューラルネットワーク（CNN）と深層学習の技術（以下総称して「AI」という。）を導入することで、長期的には地図作成の自動化を、短期的には地図作成における「判読」及び「図化」の工程の生産性向上を図ることを目的としている。また、本研究は平成 30 年度から 5 ヶ年計画の特別研究として実施しており、令和 4 年度はその最終年度として研究成果の取りまとめと研究成果の社会実装に向けた取組の一つとして教師データの公表を行った。

## 2. 研究内容及び得られた成果

### 2.1 研究開発の概要

令和 3 年度までは 256 ピクセル×256 ピクセルの画像を入力とする 16 層の CNN を使用していたが、学習データの整備が進んだ項目では True 画素のオーバーフローと見られる現象が生じ始めていた。また、多くの項目で抽出性能が頭打ちの傾向を呈していたことから、この CNN の入出力層に 4×4 フィルタを用いる畳み込み層を 1 層ずつ追加して、入力画像の範囲を従来の 4 倍に拡大した 512 ピクセル×512 ピクセルを入力とする 18 層の CNN を用いる方針に変更し、学習データを再構築した。これにより、True 画素のオーバーフローは生じなくなった一方、学習データの絶対数が 1/5 に減少することとなり、抽出性能が一時的に 16 層の CNN による抽出性能を下回ったものの、最終的に取り組んだ 27 項目のうち 58 砂礫地と 63 高塔以外のすべての項目で数値目標の達成又は 16 層の CNN で到達した性能を超える抽出性能を得た。なお、使用した CNN は、いずれも Conditional-GAN (Isola et al., 2017) の発生成器 (Generator) に用いられる 16 層の Encoder-Decoder 系の CNN をベースとしたものである。

また、対象地物が細く長い形状という特徴を有する 05 分離帯、06 普通鉄道（軌道）、41 風車の 3 項目については、4×4 フィルタでは抽出されるピクセルの形状が実際の地物の形状にうまく追従していない状況が確認されたことから、使用する CNN の入出力層に形状補正を目的とする 1×1 フィルタを用いる畳み込み層を追加して 20 層とした CNN（入力画像サイズは 18 層のものと同じ 512 ピクセル×512 ピクセルのため、学習データを再構築する必要が無い）を構築したことで、18 層の CNN による学習済モデルよりも高い抽出性能の学習済モデルを得ることができた。

最終的な取りまとめとして、研究評価委員会における終了時評価資料を作成したほか、研究成果の社会実装にむけた取組の一環として、数値目標とした抽出性能  $F \geq 0.800$  を達成した 9 項目を含め、 $F \geq 0.600$  の抽出性能が確認された 18 項目で構築したすべての学習データを「GSI データセット（愛称、正式名称は CNN による地物抽出用教師データセット）」として国土地理院ホームページから公表した。

### 2.2 学習データの作成

学習データは、深層学習において欠かせない基礎データであり、高い抽出性能を発揮する学習済モデルを構築するためには品質の良い学習データセットが必要である。572 ピクセル×572 ピクセルで

再構築した学習データセットは、誤抽出と抽出漏れを同時に1枚の学習データに含む範囲を選択しやすく、再現率 (Recall) の低下率を上回る適合率 (Precision) の向上率を保持し、その結果として抽出性能 (F 値) を向上させられるケースが多く見られた。

令和5年3月8日時点の項目毎の最終的な学習データ作成枚数及び抽出性能評価の最高値(F-Score: F 値)を表-1に示す。ここで記載した枚数は、令和3年度までと異なり572×572ピクセルサイズとしての数であり、入力用画像とラベリング画像のセットで1枚とカウントしている。また、最高値は、必ずしも枚数欄に記載の枚数で深層学習したモデルで算出された値とは限らない。F 値の算出には、令和3年度までに作成した検証用データ(大野・浦, 2022)を用いたが、一部の項目は当該項目専用のデータをさらに追加した検証用データを用いて算出した値となっている。63高塔は、表-1以外に286ピクセル×286ピクセルの学習データ5500枚に、572ピクセル×572ピクセルの学習データ1050枚から286ピクセル×286ピクセルに分割及び縮小して作成した学習データ5250枚を追加した合計10750枚の学習データを16層CNNで学習させたF=0.680のモデルを得ている。なお、すべてのモデルで、学習データを90度、180度、270度に回転させて学習データ数を増加させるData Augmentationを行っており、実際に学習させた枚数は表-1の4倍の数である。また、18層CNN及び20層CNNの学習時は、572ピクセル×572ピクセルの学習データから無作為に512ピクセル×512ピクセルの範囲がクリッピングされてCNNに入力される。同様に、16層CNNの学習時は、286ピクセル×286ピクセルの学習データから無作為に256ピクセル×256ピクセルの範囲がクリッピングされてCNNに入力される。

表-1 主要な項目別学習データの整備状況と抽出性能評価値 (F 値)

項目名	枚数	F 値	項目名	枚数	F 値	項目名	枚数	F 値
02 舗装道路	2000	0.801	14 横断歩道橋	1800	0.557	38 プラットホーム	2200	0.674
04 駐車場	1900	0.779	16 畑	1600	0.445	39 タンク	536	0.855
05 中央分離帯	2600	0.619	17・18 水田	2600	0.780	40 広葉樹林	640	0.400
06 軌道の中心線	2000	0.723	19 竹林	1600	0.608	41 風車	680	0.564
07 水部	1250	0.820	20 針葉樹林	800	0.679	44 防波堤	1340	0.815
08 堅牢建物	1000	0.415	21 茶畑	640	0.830	54 芝地	400	0.462
09 普通建物	1200	0.800	22 果樹園	640	0.312	58 砂礫地	960	0.324
10 無壁建物	960	0.688	26 しの地	520	0.339	63 高塔	2900	0.617
13 透過水制	920	0.801	27 太陽光発電設備	680	0.844	68 墓地	1700	0.806

### 2.3 自動図化の実現

本研究で構築したAIから得られる出力結果は、単に入力画像内の対象とする地物を指定色に色付けした推論画像にすぎない。一方、社会実装を考えた場合、出力は地理空間情報であることが望ましい。本研究では画素が地理座標を有するオルソ画像ではなく、空中写真の生画像をAIに入力するため、推論画像から得られる地物の座標は画像座標系の値であり、そのままでは地理空間情報とはならない。そのため、本研究を補完する研究として令和3年度に実施した一般研究の成果である自動図化機構(大野, 2022)のAI部に本研究で構築した学習済モデルを適用し、地物毎に後処理のパラメータをチューニングすることによって、空中写真の生画像とカメラパラメータを入力するだけで、図化したい地物の経緯度座標によるポリゴンデータを出力結果として得る自動図化を実施可能とした。この

場合の後処理のパラメータチューニングの内容は、対象とする地物項目によって異なる。なお、(大野, 2022) で原因不明としていた方位角の誤差は、測量に用いるカメラパラメータが平面直角座標系で計算されていることによる子午線収差が原因で生じていたことが判明し、平面直角座標系で計算されたカメラパラメータは入力前に方位角に補正を加えることとした。逆に言えば、カメラパラメータが経緯度座標系で算出されている場合は方位角の誤差が生じないことが確定したことになり、防災ヘリコプターやドローンなどに搭載した IMU から直接経緯度座標系で方位角を入力してリアルタイム図化するような実装を行う場合は、方位角補正を考慮する必要が無いことも結論づけられた。

自動図化機構は、地上画素寸法 20cm 級で撮影された空中写真の生画像と、当該写真を撮影した際のカメラパラメータを同時に入力することによって、目的とする地物が占める範囲の図化結果を経緯度座標系のポリゴンデータとして KML 形式で出力することができる。正射変換には、既存の基盤地図情報の DEM (5m, 10m いずれでも可) を使用する。自動図化機構は、起動する際に人間によるバッチファイルのダブルクリックという動作が必要となる以外、写真の標定、判読、図化及び後処理のすべての工程を自動的に処理し、KML 形式で図化結果が出力される。図-1 に自動図化機構と 02 道路の 18 層 CNN による 1960 枚モデルを用いて、2021 年撮影の空中写真 15 枚から作成した道路の自動図化結果を示す。地理院地図の標準地図を背景として、自動図化された道路の範囲を水色のポリゴンで表示したものである。自動図化機構の起動と、得られた自動図化結果から該当写真の範囲を切り出す行為のみ執筆者が実施したが、それ以外は人間が一切介在せず自動的に得られた図化結果である。また、

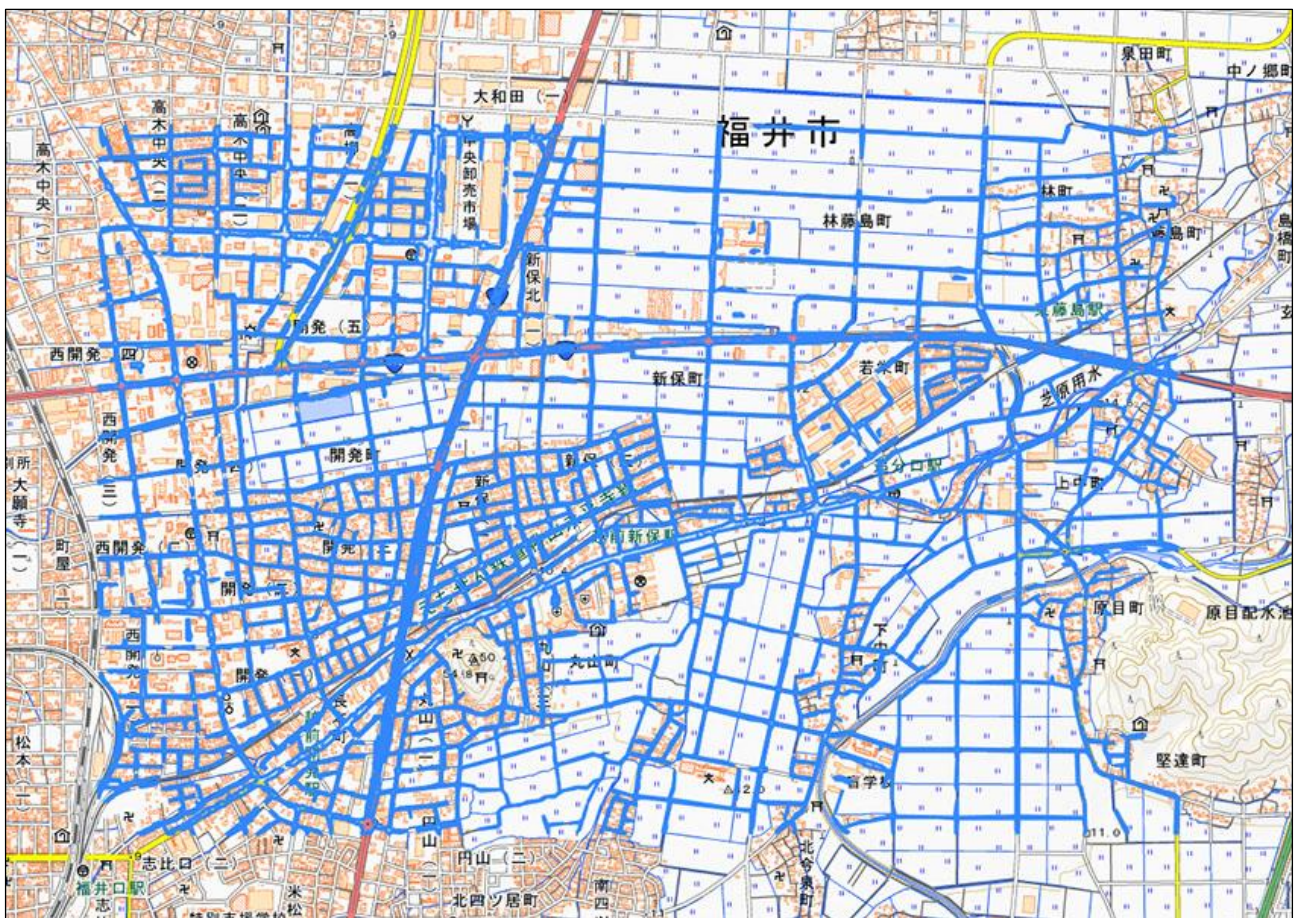


図-1 自動図化機構による道路の自動図化結果。使用した写真は CCB-2021-3-N-C05\_0008 と隣接する 14 枚。チャンピオンデータではない。自動図化機構の抽出性能は、使用した写真の撮影時期と合致する道路

データが無い場合定量的な評価ができていないが、このデータでは F 値で 0.900 以上、IoU でも 0.800 レベルに到達している可能性がある。このレベルまで図化できれば、平行線認識による芯線化（中南・大野，2002）の処理を加えることで幅員属性を自動的に付与した道路中心線を自動発生させることが可能と思われる。図-1 の実データは後述する「GSI データセット」の道路のページで公表している。

## 2.4 社会実装に向けた研究成果の公表

本研究の主要な成果として、作成したマイナーな地物を含む深層学習用学習データが挙げられる。深層学習は、学習データと CNN（損失関数等のハイパーパラメータを含む）が両輪となることで将来の性能向上が期待できる。しかし、地図作成の分野で、深層学習に自由に使用できる地上画素寸法 20cm クラスの学習データの公表例は多くないことから、国土地理院のウェブサイト上で 2022 年 11 月 11 日から「GSI データセット」として本研究の成果の公表を開始した。商用利用を含め、幅広い用途への使用を許諾する国土地理院コンテンツ利用規約の下で利用することができる。2023 年 2 月 28 日までには、 $F \geq 0.800$  を達成した 9 項目中 8 項目の学習データを公表済みであり、2023 年 2 月 28 日時点でのべ 1,011 回のダウンロードが行われている。最もダウンロード数が多かった項目は、2023 年 2 月 16 日に公表した茶畑の 319 回、次いで 2023 年 1 月 27 日に公表した普通建物の 271 回であった。令和 4 年度中に  $F \geq 0.600$  を達成した 18 項目まで公表項目を増加させる予定である。また、推論用ツールと学習済モデルの公表も計画している。特に竹林は、地図記号として地図に表示されていないケースが多く、AI による図化で相当な面積が抽出され、かつ写真を判読すると概ね正しく抽出されていることに驚く。地図記号が取捨選択で表示されていないのか、広葉樹林や針葉樹林として誤判読されて表示されていないのかは特定できないが、人間による判読結果（地図記号）よりも AI による判読能力の方が勝っていると思われる事例も生じている。

## 3. まとめ

自動図化は、国土地理院が長年取り組んできた課題であるが、これまで実用域に到達できる研究成果は得られていなかった。本研究では AI の、特に深層学習を用いる研究アプローチを採用したことにより、いくつかの項目で実用レベルに到達する自動図化結果を得ることができた。

GSI データセットとして公表した本研究の成果を使用すれば、今後新たに撮影されるものも含め、地上画素寸法 20cm 級の空中写真から誰でも容易に対象地物の図化結果が得られるようになることから、地図作成分野に限らず様々な分野の研究に本研究の成果が活かされることを願う。

## 参考文献

ISOLA, Phillip, ZHU, Jun-Yan, ZHOU, Tinghui, EFROS, Alexei A. (2017): Image-to-Image Translation with Conditional Adversarial Networks, CVPR2017.

国土地理院：GSI データセット，[https://gisstar.gsi.go.jp/gsi-dataset/index\\_ja.html](https://gisstar.gsi.go.jp/gsi-dataset/index_ja.html) (accessed 14 Mar. 2023).

中南清晃，大野裕幸（2002）：2 万 5 千分 1 地形図ベクトルデータ作成のためのラスタベクタ変換，国土地理院時報，98，25-32.

大野裕幸，浦 郁子（2022）：AI を活用した地物自動抽出に関する研究（第 4 年次），国土地理院令和 3 年度調査研究年報，210-213.

大野裕幸（2022）：新技術の活用による基盤情報整備力向上のための研究（第 3 年次），国土地理院令和 3 年度調査研究年報，222-225.