

Semantic Segmentation による航空写真の土地利用分類モデルの構築

中央大学大学院 学生員 ○羽物 裕人
 エイト日本技術開発 正会員 大川 博史
 中央大学 正会員 檜山 和男

1. はじめに

著者らはこれまで津波、高潮、洪水氾濫等の数値解析¹⁾を行ってきたが、土地利用区分毎に粗度係数²⁾を与える際には、半自動で行っており労力のかかるものであった。

そこで本研究では、深層学習に基づく画像分類手法により、航空写真の土地利用分類モデルを構築する。本モデルを一般に公開されている航空写真に転移学習させ、深層学習モデルの精度検証および評価を行った。

2. 画像分類手法

図-1 に本研究の分類モデル構築の流れであるフローチャートを示す。

(1) データの取得

本研究は、教師あり学習の手法に基づき、分類モデルの構築を行う。トレーニングデータは、国土地理院が公開している GSI データセット³⁾ (畳み込みニューラルネットワークによる地物抽出用データセット) を用いる。本データセットは、国土地理院の研究成果として公開されたものである。使用したデータは、普通建物、茶畑、水田、針葉樹林、水部、道路である。データの例を図-2 に示す。図-2 に示すように、オリジナル画像とアノテーション画像がセットの状態でデータセットが公開されている。このデータの画像サイズは、572px*572px と 286px*286px の 2 種類がある。画像サイズ 286px*286px のデータセットは、572px*572px を 4 枚に分割したデータとなっている。本研究では、できる限り多くの学習用データを確保したいため、画像サイズ 286px*286px のデータセットを採用した。テストデータは、国土地理院が公開している地理院タイルの電子国土基本図 (オルソ画像)⁴⁾ から航空写真を取得する。対象地域を高知県中土佐町久礼地区としテストデータの作成を行った。対象地域の写真を図-3 に示す。本研究は、赤線で囲われている小領域を対象領域をしている。分類項目は、国土地理院が公開している細密数値情報に基づき、建物、田・畑、山林、海・河川、道路の 5 クラスとした。

(2) 分類手法

a) データの前処理

取得した航空写真に対して予め施した処理について説明する。テストデータの作成のため、取得した航空写真を GIS ソフトを用い格子状に航空写真を分割する。また、テストデータには土地利用区分ごとにアノテーションする必要がある。テストデータのアノテーションについても GIS ソフトを使用して行った。アノテーション結果を図-4 に示す。




図-1 フローチャート




図-2 トレーニングデータの例



図-3 テストデータの対象領域



図-4 テスト領域のアノテーション結果

KeyWords : 深層学習, 航空写真, 土地利用, FCN, Semantic Segmentation

連絡先 : 〒112-8551 東京都文京区春日 1-13-27 TEL : 03-3817-1815 E-mail :a19.6t5r@g.chuo-u.ac.jp




図-5 分類に使用したネットワークモデル図

b) 深層学習モデルについて

深層学習とは、人間の脳神経細部を模倣したニューラルネットワークを用いて学習する機械学習手法の一つである。本研究では、深層学習に基づく画像分類手法による土地利用分類を行う。画像分類手法として完全畳み込みニューラルネットワーク (Fully Convolution Networks; FCN)⁵⁾の終盤層に空間ピラミッドプーリング (Spatial Pyramid Pooling) を用いるディープラーニングセグメンテーションタスクのPSPNET(Pyramid Scene Parsing Network)⁶⁾を採用し、分類モデルを構築する。今回構築したPSPNETのネットワークモデルの概要を図-5に示す。通常FCNでは、Encoderによって入力画像から抽出された特徴マップのサイズはダウンサンプリングされ、元の入力画像より小さいサイズとなる。しかし、PSPNETでは、Encoderで得られる画像サイズの小さい特徴マップに対して複数の解像度でMax Poolingを用いるPyramid Poolingにより、それぞれのスケールで捉えた複数の特徴マップが得られる。得られた異なるスケールの各特徴マップを元の特徴マップと同じスケールにアップサンプリングする。アップサンプリングされた各特徴マップを元の特徴マップにチャンネルを追加する方法で連結を行う。これにより、大域的に特徴を捉えられることに加え、局所的な細かい情報を得ることが可能になる。この連結した特徴マップに対してフィルタサイズ1*1の畳み込み処理を行い、Semantic Segmentationの結果を得る。

c) 学習環境・条件

開発環境について述べる。ハードウェア環境は、CPU: Xeon W-2225, GPU: Geforce RTX3090, OS: Ubuntu20.4, RAM: 32GBである。ソフトウェア環境は、Anaconda3上でPython3.9, Pytorch1.12.1を用いてプログラムを実行している。データの詳細を表-1に示す。深層学習に適用する上で、学習に用いるトレーニングデータにばらつきがあるため、データの縮小処理・拡張処理をプログラム上で行っている。これにより最適な分類モデルの構築を検討している。加えて、トレーニングデータは学習用データと検証用データに分けて学習を実行する。これにより、構築された分類モデルをテストデータに転移学習させ、深層学習モデルの

表-1 データの詳細

		トレーニングデータ	テストデータ
分類項目	項目	データ数	データ数
建物	普通建物	6,000ペア	69ペア
田・畑	茶畑	3,200ペア	201ペア
	水田	13,000ペア	
山林	針葉樹林	4,000ペア	127ペア
海・河川	水部	6,250ペア	79ペア
道路	道路	10,000ペア	64ペア

精度検証および評価を行う。

3. 学習結果

分類モデルの学習推移、学習における計算時間、転移学習を行った結果およびその評価は、講演時に示す。

4. おわりに

本研究では、取得したGSIデータセットを用いた深層学習により航空写真の土地利用分類モデルの構築を行い、構築した分類モデルに転移学習を行った。

今後は、学習に用いるトレーニングデータの項目の追加、テストデータの領域拡大、より有効な分類モデルの構築を行っていく予定である。

参考文献

1) 利根川大介, 樫山和男, 安定化有限要素法による津波遡上及び流体力の解析手法の構築, 応用力学論文集 (土木学会), Vol.12, pp.127-134, 2009.

2) 小谷美佐, 今村文彦, 首藤伸夫, GISを利用した津波遡上計算と被害推定法, 海岸工学論文集, Vol.45, 1998.

3) 大野裕幸ら: AIを活用した地物自動抽出に関する研究 (第1年次), 国土地理院平成30年度調査研究年報, pp.180-183, 2019.

4) 電子国土基本図 (オルソ画像): <https://www.gsi.go.jp/gazochosa/gazochosa40001>, (参照 2022-8-25).

5) J.Long, E.Shelhamer and T.Darrell: Fully Convolutional Networks for Semantic Segmentation, CVPR, 2015.

6) Hengshuang Zhao et al. Pyramid Scene Parsing Network, CVPR, 2017.