

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1年次）

実施期間 令和元年度～令和5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

1. はじめに

本研究は、10年後の地理空間情報整備環境を睨んで、正確さを保持しつつ、低コスト、高生産性で基盤情報を整備可能な技術開発につなげる観点に立って基礎研究を実施するものである。本年度は、DNN (Deep Neural Network) を用いた画像分類 (Classification) の活用可能性に関する研究を実施した。

2. 研究内容

2.1 研究開発の概要

画像分類 (Classification) は、画像に映った主題を自動的に分類するタスクを言い、DNN と深層学習の有効性が示され、近年の深層学習躍進のきっかけとなった画像認識の分野のひとつである。具体的には、あらかじめ決められた分類項目名 (Class) に対し、入力した画像の各項目の分類結果を確率として出力するというもので、上位5個までの分類結果に正しい分類項目が含まれないケースの割合 (Top 5 Error) が DNN の分類性能の指標として用いられることも多い。

画像分類を用いると瞬時に画像に映った内容を分類することが可能となること、また、教師画像さえ準備できれば極めて低コストで実装可能であるため応用範囲は広く、医療分野や各種製品検査、キュウリの選果 (小池, 2019) などにも用いられている。また、画像分類に適用可能な DNN の実装のソースファイルが多数 GitHub 等で公開されていたり、深層学習用フレームワークである Tensorflow では、Google による Inception-v3 という DNN の学習済モデルがすぐに利用できる状態で公開されていたりするなど、画像分類を導入しやすい環境が整っている。

筆者は、緊急撮影された多数の空中写真から災害が映っている写真の抽出や、数十万枚の空中写真の中から CNN (畳み込みニューラルネットワーク) を用いて地物抽出を行う研究に用いる材料を素早く選定可能とすることを目指して画像分類に関する研究を行ってきた。その中で、画像分類で得られる分類確率と、空中写真に写っている対象地物のピクセルの比率の関連及びその応用方法について調査した。

2.2 調査方法

調査は2段階で実施した。まず、画像分類による分類確率と対象地物のピクセル比に相関がみられるか調査した。DNN には Inception-v3 (Szegedy et al., 2016) を使用し、教師データとして、2007年から2019年までにデジタル航空カメラで撮影された地区の撮影画像を 572×572 pixel に分割した画像群から9カテゴリ各225枚の画像を選定した。カテゴリは、building, field, flood, forest, parking, residentialarea, ricefield, wasteland, water とし、画像全域に当該カテゴリのみが映っているものを優先的に選定した。教師データのサンプルを図-1に示す。

深層学習は、教師データの80%をトレーニング用に、10%を検証用に、10%をテスト用に分け、ミニバッチサイズ100で4000ステップ実施した。

学習済モデルを用いて、AIを活用した地物自動抽出に関する研究 (以下「AI特研」という。) で平成30年度に作成した検証用データセット (以下「GSI検証データ」という。) 547枚を推論にかけ、9

カテゴリの分類確率を得たうえで、水部（floodと water の分類確率を合算した値）に関して GSI 検証データの項目「07 水部」のピクセル数の比率とを比較して相関係数を算出した。

次いで、ある程度の相関係数が得られた場合に、フルサイズの空中写真画像に映っている水部のピクセル数と画像分類確率から得られる推定ピクセル数を比較し、評価することとした。



図-1 教師データのサンプル

3. 得られた成果

3.1 画像分類確率と画像ピクセル比率の相関

GSI検証データ 547 枚の各画像について、water と flood を合計した水部としての画像分類確率（Inference）を横軸、水部の画像ピクセル比率（W）を縦軸にとった散布図を図-2 に示す。ばらつきが大きく見えるが、 $W \geq 0.95$ 、 $Inference \geq 0.95$ の領域に 83 枚、 $W \leq 0.05$ 、 $Inference \leq 0.05$ の領域に 315 枚のデータが集中している。W=0、 $Inference > 0.1$ の範囲にみられる分布は、水部が存在しないにもかかわらず、flood 又は water と分類された画像を示している。画像分類確率と水部の画像ピクセル比率の間の相関係数は、 $R = 0.91163$ と、強い正の相関が得られた。また、切片を 0 とした 1 次式に近似したところ、式-1、

$$W = 0.8881 \times Inference \quad (\text{式-1})$$

が得られた。

3.2 フルサイズ空中写真画像を用いた検証

GSI 検証データによる調査で高い相関係数が得られたことから、フルサイズの空中写真画像に映っている水部のピクセル数に対して、式-1 を用いて画像分類確率により推定水部ピクセル数を求めた値と比較した。使用した空中写真は、AI 特研で全域の水部のピクセル範囲を特定している 3 枚の空中写真で、その諸元を表-1 に、画像のサムネイルを図-3 に示す。

各空中写真画像は、両辺が 572 で割り切れるピクセル数(9420×14430pixelの画像は9724×14872pixel, 11200×12096pixel の画像は 11440×12584pixel) になるようバイリニア法でリサンプリングした後、572×572pixel の画像に分割し、分割された画像毎に 3.1 で使用したものと同一トレーニング済モデル

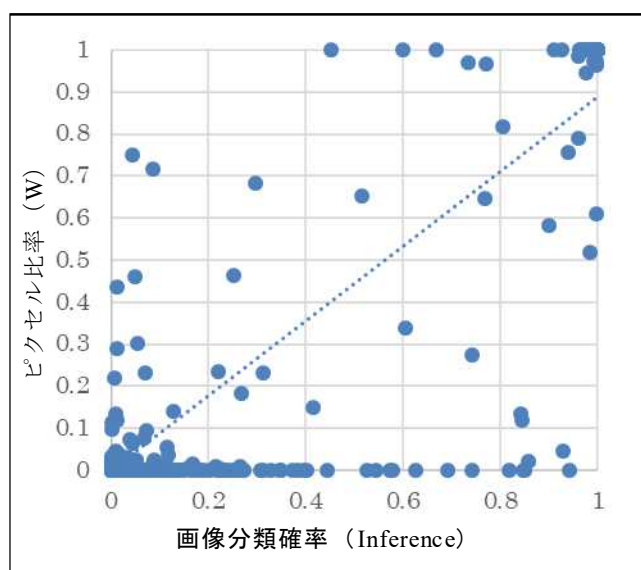


図-2 画像分類確率と水部のピクセル比

を用いて 9 カテゴリーの画像分類を行った。その結果から flood 及び water の画像分類確率を合算した値に式-1 を適用し、画像のピクセル数である $572 \times 572 = 327,184 \text{pixel}$ を乗じて得た分割画像毎の推定水部ピクセル数をすべて合計したうえで、リサンプリングによる画素増加分を補正して、各空中写真の推定水部ピクセル数とした。推定水部ピクセル数と、空中写真の実際の水部ピクセル数（正解値）の比較表を表-2 に示す。

表-1 使用した空中写真画像の諸元

写真番号	撮影日	カメラ名称	画像サイズ (pixel)	設計地上画素寸法
CHO20181-C4-9	2018/7/17	UltraCam-X	9,420×14,430	20cm
CHO20182-C5-11	2018/7/27	UltraCam-X	9,420×14,430	20cm
CHO20183-C4-7	2018/7/8	DMC II 140	11,200×12,096	20cm




図-3 空中写真画像のサムネイル

表-2 画像分類により推定した水部ピクセル数と実際のピクセル数の比較

写真番号	推定水部ピクセル数 (A)	実際の水部ピクセル数 (B)	比率 A/B
CHO20181-C4-9	28,100,892	30,071,528	0.934
CHO20182-C5-11	6,238,511	1,312,313	4.754
CHO20183-C4-7	8,928,417	5,607,200	1.592



図-4 画像分類が不良なケース（左の画像は全域が field である）

CHO20181-C4-9 は、実際の水部ピクセル数に対して良好な値が得られているが、CHO20182-C5-11 は明らかに過大、CHO20183-C4-7 はやや過大となっている。CHO20182-C5-11 が過大となった原因は、図-4 のような画像分類の段階で誤った推論結果が多数得られたためと考えられる。これは図-2 の $W=0$, $Inference>0.1$ の範囲にみられる分布に該当するケースにあたるものとみられ、使用した教師データの数が各カテゴリ 225 枚と少なく、画像分類の精度が不十分であったことが要因であり、十分な数の教師データを追加することで改善が可能と考えられる。

4. 結論

DNN と深層学習による画像分類を地理空間情報の解析に応用できるかどうかの基礎的検討を実施し、水部に関して、画像分類確率と画像に実際の地物が占める割合（面積比）との間に強い相関があることを確認した。一方、実画像への応用では、現時点での画像分類の分類精度が不十分なことから良好な成果は得られなかった。

画像分類による実画像に対する分類精度比率が安定して 0.8~1.2 程度のレベルに到達することができれば、従来よりも相当迅速に写真内の対象物の概略面積を算出することが可能になる。これは、現時点は自動的な地理情報解析が困難な、カメラパラメータを撮影と同時に計測できないカメラによる撮影画像からでも対象物の面積をごく短時間で自動算出を可能にする技術と考えている。実事業への応用面では、一眼レフカメラによる緊急撮影時の概略浸水面積や火山灰の概略堆積面積などの自動解析につながる技術であることから、画像分類の精度向上及びカテゴリ数の増加を図ったうえで、再度フルサイズの空中写真を用いた検証を実施したいと考えている。

参考文献

Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jon Shlens (2016): Rethinking the Inception Architecture for Computer Vision, CVPR2016 (Poster).

小池誠 (2019) : 静岡のスマート農業の今とこれから, 日本土壌肥料学会講演要旨集, 65, 182.