

深層学習を用いた土地用途判定システムの構築 及び現地調査への利活用

屠 芸豪¹ 浦田 真由¹ 遠藤 守¹ 安田 孝美¹ 島崎 寛和² 木村 智行² 片山 高也³

名古屋大学 大学院情報学研究科¹

日本土地評価システム株式会社 システム開発部²

半田市 総務部税務課³

1. はじめに

・土地評価の現状

全国の市町村において、固定資産税は非常に重要な財源である。利用用途により評価額や課税標準額が決定される。平成 29 年度の市町村税の内訳[1]によると、固定資産税は 9 兆 254 億円で、全体の 42.0%を占める重要な財源である。土地の用途は地目という。土地への固定資産税の課税については、原則、土地登記簿において、1 個の土地を指す単位である筆単位に課税される。土地の所有者は登記簿に記載される登記地目を自ら申請するが、一方、市町村は登記地目に関わりなくその土地の現況を調査し課税地目を決定する。固定資産税は地目によって大きく課税額が変わるが、市町村はその決定した課税地目に応じて課税額を決定する。

固定資産税を決める際に、地方税法第 408 条では年 1 回の実地調査が義務付けられている。市町村職員は、適正な評価を行うために、実地調査に多くの時間と労力を費やしている。

・先行研究

深層学習を土地の地目判定[2]や利用判別及びカーバ検出に応用する研究が多く行われている。また、ソーラーパネルの研究に応用した研究もある[3]。鶴飼らによる先行研究[2]では、深層学習を用いた画像認識を活用して、農地 5 値分類について研究が行われた。

・研究目的

自治体が所有する多種多様なデータを利用し、深層学習を用いた土地用途の自動判定システムを構築する。自治体での土地評価業務への支援を行うことにより、業務内容の負担軽減及び効率化を図り、評価の精度向上を目的とする。また、判定結果を基に現地調査の実証実験を行い、本システムの土地評価業務支援への応用及び現地調査業務の効率化に対する有効性を確認する。

2. 学習手法

・畳み込みニューラルネットワーク (CNN)

画像認識を行うために、ResNet[4]と MobileNetV2[5] という 2 種類の CNN モデルを用いる。本研究でマシンの

Construction of Land Use Judgment System Using Deep Learning and Utilization for Field Survey.
Yunhao TU¹, Mayu URATA¹, Mamoru ENDO¹, Takami YASUDA¹, Hirokazu SHIMAZAKI², Tomoyuki KIMURA², Takaya KATAYAMA³.
1 Graduate School of Informatics, Nagoya University.
2 System Development Department, Japan Appraisal System INC.
3 General Affairs Taxation Division, Handa City.

スペックと学習時間を考慮し、ResNet18 と ResNet34 を用いる。また、モバイルデバイスでの使用や自治体のパソコン環境でも使うことを考慮し、MobileNetV2 という軽量モデルも使用する。最適化方法は SGD である。

・転移学習

転移学習は 1 つのタスクで学習済みのモデルを他のタスクに転用する手法である。それによって新しいタスクに対して学習を行う際に、ゼロから大量のデータを学習しなくても複雑なネットワークが構築できるので、有効な手法として多くの研究で使われている。本研究では、ImageNet[6]を学習したモデルを用いる。それらのモデルを基にし、航空写真画像と土地のデータを学習し直す。

・アンサンブル法

基本学習器を複数組み合わせ、全体的に精度を向上する方法である。本研究では、3 つの CNN モデルを学習させる中で、各モデルにおいてそれぞれ一番認識精度が良かったモデルを選ぶ。それらの出力の単純平均を取り、その結果を最終的な予測結果として出力する。

3. データ前処理

本研究では、自治体から航空写真画像、シェープファイル、課税地目データという 3 種類のデータを提供して頂いた。データセットを作成する方法を説明する。航空写真画像とシェープファイルを用いて、地番ごとに航空写真画像から各土地の画像データが切り出せる。また、シェープファイルと課税地目データとを紐付け、教師ラベルをつけることができる。

1 年分のデータには約 30 種類のカテゴリーがあるが、4 章で説明する実験タスクに合わせて作成する。土地は 2 種類の単位があり、筆単位と画地単位である。筆単位は土地登記簿上の単位であり、1 個の土地を指す。画地単位は土地評価上の単位であり、1 筆の土地を 1 画地とするが、地形および実際の利用状況などにより 1 体をなしていると認められる土地について 1 画地とされる[7]。

4. 実験

実験タスクを以下の 3 つに分ける。

- ①宅地 2 値分類：家屋の固定資産への利用。
- ②農地 4 値分類：農地(畑, 田)と宅地を識別する。
- ③農地 5 値分類：農地 4 値分類に加えて、ソーラーパネルの検出応用を想定した雑種地の判別を識別する。

実験結果を評価するために、F1-score と Accuracy を用いる。カテゴリーによってデータ数に違いがあるので、それを考慮した F1-score を導入し、結果を評価する。また、Accuracy は全部のデータに対して、モデルがどのくらい正確に判定できるかを表す評価である。使用した筆

単位と画地単位のデータ量を表 1 と表 2 に記述する。なお、農地多クラス分類では、学習と検証データ量をそれぞれ同じ数にする。実験結果を表 3 に記述する。

表 1 各タスクで使用した筆単位のデータ数

タスク		宅地	その他	一般畑	一般田	雑種地
ラベル						
宅地 2 値	学習	67,532	96,560			
	検証	28,942	41,382			
	テスト	59,467	50,238			
農地 4 値	学習	20,000	20,000	20,000	20,000	
	検証	5,000	5,000	5,000	5,000	
	テスト	7,555	7,698	59,467	34,985	
農地 5 値	学習	28,000	28,000	28,000	28,000	28,000
	検証	7,000	7,000	7,000	7,000	7,000
	テスト	7,555	7,698	59,467	7,096	42,081

表 2 各タスクで使用した画地単位のデータ数

タスク		宅地	その他	一般畑	一般田	雑種地
ラベル						
宅地 2 値	学習	31,524	38,993			
	検証	7,882	9,749			
	テスト	39,660	47,977			
農地 4 値	学習	28,000	28,000	28,000	28,000	
	検証	7,000	7,000	7,000	7,000	
	テスト	39,660	32,976	7,374	7,627	
農地 5 値	学習	28,000	28,000	28,000	28,000	28,000
	検証	7,000	7,000	7,000	7,000	7,000
	テスト	39,660	27,416	7,374	7,627	5,560

表 3 実験結果

ラベル	タスク	F1-score					F1-average-score	Accuracy (%)
		宅地	その他	一般畑	一般田	雑種地		
宅地 2 値	筆	0.8381	0.8280				0.8330	83.32
	画地	0.8941	0.9192				0.9066	90.83
農地 4 値	筆	0.8374	0.6825	0.4499	0.5497		0.6299	73.95
	画地	0.8872	0.7649	0.4535	0.5431		0.6622	76.82
農地 5 値	筆	0.8344	0.6965	0.4317	0.5626	0.3491	0.5749	72.00
	画地	0.8847	0.7867	0.4675	0.5691	0.3710	0.6158	75.66

各タスクでアンサンブル法を用いた結果が一番良かった。宅地 2 値分類では、筆単位よりは画地単位データを用いた結果で約 7% 正解率が高くなり 90.83% になった。1 つの宅地は複数の筆単位の土地に建てられる場合があり、個々の画像に分けられたら認識しにくくなったと考える。それに対し、1 体をなしている画地単位で認識しやすくなったと考える。農地多タスク分類の場合、農地 5 値分類よりは「雑種地」がない農地 4 値分類の結果がよかった。「雑種地」は決まった 23 種類の地目以外の土地を指し、様々な物が含まれる土地がある。それにより、他のカテゴリと区別しにくくなったと考える。

愛知県半田市においてシステムの判定結果を基に現地調査の実証実験を 2 回行った。事前に調査ルートと対象土地リストを作成しておき、調査を行った。対象土地を絞り込む際に、システムが高い確信度で判定した土地や低い確信度で判定に迷う土地を対象とした。

2019 年 11 月 13 日に半田市役所周辺の土地を対象に 1

回目の現地調査を行った。また、2019 年 12 月 16 日に半田市全域の土地を対象に 2 回目の現地調査を行った。図 1 と図 2 は調査した 1 つの土地の例である。図 1 は航空写真画像から見た様子である。青い線で囲まれた所は対象の土地である。図 2 は現地の様子である。システムが出した結果を表 4 に示す。



図 1 航空写真画像

図 2 現地の様子

表 4 確信度ごとの認識結果

正解	一般畑
確信度の結果(農地 4 値分類)	一般畑 49%
	一般田 24%
	その他 23%
	宅地 4%

5. 考察と結論

本研究では表 4 のように各土地に対して確信度をつけて判定結果を出した。それにより、確信度が低い土地を確認し、航空写真画像だけから判定しにくい所を絞り込み、優先的に現地調査で確認した。このように、疑わしい所を見つけるツールとして本システムを活用することが考えられる。判定結果と 2 回の現地調査を通じて、土地評価業務支援への応用及び現地調査業務の効率化に対する一定の有効性を確認した。今後、航空写真画像のみならず、衛星写真や植物のリモートセンシングデータも導入し、総合的に判定を行いたいと考える。

謝辞

本研究の一部は JSPS 研究費 18H03493 の助成を受けたものである。

参考文献

- [1]総務省：平成 31 年版地方財政白書，http://www.soumu.go.jp/main_content/000605637.pdf (2019/6/2 日アクセス)
- [2]鶴飼 凌央, 島崎 寛和, 遠藤 守, 浦田 真由, 安田 孝美, 木村 智行. 産官学共同研究による AI を活用した航空写真画像診断に基づく現況地目調査の効率化への取組みと今後の利活用. 第 22 回固定資産評価研究大会, pp. 11-22, 2018.
- [3]N. Kussul, M. Lavreniuk, S. Skakun, and A. Shelestov. Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data. In IEEE Geoscience and Remote Sensing Letters, Volume: 14, Issue:5, pp. 778-782, May2017.
- [4]K. He, X. Zhang, S. Ren, and J. Sun. Deep residual learning for image recognition. In CVPR, 2016.
- [5] Mark Sandler, Andrew G. Howard, Menglong Zhu, Andrey Zhmoginov, and Liang-Chieh Chen. Mobilenetv2: Inverted residuals and linear bottlenecks. mobile networks for classification, detection and segmentation. CoRR, abs/1801.04381, 2018.
- [6] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. FeiFei. Imagenet: A large-scale hierarchical image database. In CVPR2009.
- [7] 土地評価に関する専門用語，<https://www.jasinc.co.jp/glossary> (2019/12/23 アクセス)