

# 建物外観画像と機械学習を用いた建物単位の空き家判定手法の開発

武田 洸明\*・秋山祐樹\*\*

## Development of Vacant House Determination Method for Each Building Using Building Exterior Images and Machine Learning

Komei TAKEDA\*, Yuki AKIYAMA\*\*

In recent years, the number of vacant houses has been increasing in Japanese cities, and understanding their spatial distribution is an important task for local governments. However, the survey of vacant house distribution has been a heavy burden for local governments since it is mainly based on visual inspection of the exterior of buildings. In this study, we develop a method to integrate exterior images of buildings and distribution data of vacant houses on a digital map. In addition, we also propose a machine learning method using a convolutional neural network (CNN) with exterior images of buildings created by the method as training data to accelerate visual inspection of vacant houses. Using the method developed in this study, in the target area of this study; Maebashi City, Gunma prefecture, we could discriminate building exterior images between vacant and non-vacant houses with more than 90% accuracy.

**Keywords:** 空き家 (vacant house)、目視調査 (visual inspection)、建物外観画像 (exterior view of building)、空間結合 (spatial integration)、機械学習 (machine learning)、畳み込みニューラルネットワーク (CNN)

### 1. はじめに

日本は少子高齢化が進みつつあり、2008年以降は人口減少社会に突入した。少子高齢化の進展により、都市空間における空き家や空き店舗といった遊休不動産の増加や、都市機能の低下といった都市のスポンジ化につながるものが危惧されている(氏原ほか, 2016)。このような背景を受け、空き家対策の推進や利用の促進を目的として「空家等対策の促進に関する特別措置法」が2015年より施行された。同法では、自治体の努力義務として、空き家の所在や所有者の把握を目的とした調査や、他自治体に空き家の情報を提供するための、空き家に関するデータベースの整備が課せられることになった。

現状の空き家調査の手法の多くは、調査員による現地調査、すなわち建物外観の目視調査で行われている。そのため、広域の空き家分布を迅速に把握することは多くの人員と時間が必要となる。また、調査員による外観目視という調査方法であるため、多少なりとも調査員の主観に左右されることから、誤判定

につながる可能性もある。これらの要因が今日の空き家調査の取り組みにおいて課題となっている。

#### 1.1 既存研究

空き家の空間分布を把握、推定する手法に関する既存研究としては、自治体が保有するデータである上下水道の使用状況のデータを使用した手法(山下・森本, 2015)や、住民基本台帳などを用いた手法(秋山ほか, 2021)などが挙げられる。しかし、自治体が保有するデータは個人情報に該当するものも多いため、これらのデータの入手や活用は困難な場合もあり、自治体によっては同手法を採用することが困難な場合がある。また、不動産登記情報を購入することで、建物に関する様々な情報を把握することが可能だが、同情報は非常に高価かつ利用上の制約が多いため、少なくとも研究での利用は困難である。さらに、都市計画基礎調査の建物利用現況のデータは、固定資産課税台帳、登記簿、住宅地図、空中写真、現地調査等を用いて収集、整備されているが、空中写真や現

---

\* 学生会員 東京都市大学大学院総合理工学研究科 (Tokyo City University)

〒158-8557 東京都世田谷区玉堤 1-28-1 Tel : 03-5707-0104 E-mail : g2181641@tcu.ac.jp

\*\* 正会員 東京都市大学建築都市デザイン学部都市工学科 (Tokyo City University)

地調査データ収集の効率化と高頻度化が課題となっている（汐澤ほか，2019）。

以上の課題の解決策として注目されているのが、車載カメラで撮影した 360 度全方位画像（以下「360 度画像」）である。すでに民間の地図会社や調査会社により、高頻度かつ大量の 360 度画像が撮影されている。また、近年のカメラの高性能化やデータ処理の高速化により、画像の高精細化も進んでいる。これらの画像データは、道路の計測調査やカーナビゲーションの道路データベースの更新に利用されている。道路の標識や道幅の把握を目的として、道路沿いの建物を含めて撮影しているため、建物現況調査などの情報として幅広く利用することが期待できる（株式会社ゼンリン，2022）。また、建物外観画像を用いた手法としては Google Street View の画像と不動産データを用いた建物の構造分類の事例（倉田，2018）が挙げられるが、同研究の画像は解像度が低いことや建物の正面の画像ではないため、推定精度に課題があることが指摘されている（小川ほか，2018）。それらの課題は 360 度画像データを用いることで解決することが期待できる。

## 1.2 本研究の目的

以上を踏まえて、本研究では、まず 360 度画像と後述する住宅地図から得られる建物頂点の座標データを組み合わせ、画像内から建物外観を自動的に抽出する技術を開発する。そして、抽出した大量の建物画像と、空き家の空間分布情報を組み合わせ、空き家と非空き家の画像データベースを構築し、これらを教師データとする機械学習により、建物外観画像から空き家を判定する技術を開発する。前述の既存研究とは異なるデータソースを用いたアプローチによる空き家判定手法が実現することで、既存研究で指摘されていた主にデータ利用上、あるいはデータ収集における制約を取り除き、同時に広域の空き家分布状況の把握を実現することで、現状の空き家調査の負担軽減に寄与できるものと期待される。

## 1.3 研究対象地域

本研究の研究対象地域は群馬県前橋市（以下「前橋

市」）全域とする。これは後述する空き家判定の正解値となる市全域の空き家分布データを、前橋市より提供頂けたためである。また、前橋市は城下町に端を発する中心市街地、その周辺を取り巻く郊外住宅地、赤城山麓に広がる農村地帯、中山間地域と、地理的に多様性に富んでおり、さらに市域全体に亘って空き家が分布している。加えて人口規模が約 30 万人の中核市であることから、日本全国に見られる典型的な中規模都市といえる。以上の理由から本研究の対象地域として適切であると判断した。

## 2. 本研究で使用したデータ

### 2.1. 住宅地図

本研究では建物の形状を把握するために、株式会社ゼンリンの住宅地図（Zmap TOWN II）を使用した。同データは住宅地図をデジタル化したものであり、コンピュータ上で利用可能になった住宅地図データベースである。市区町村単位で 1～3 年ごとに整備・更新されている。なお、本研究では後述の通り 360 度画像の撮影時期が 2011～2012 年頃のため、この撮影時期に近い 2013 年の前橋市の住宅地図を使用した。

### 2.2. 空き家分布データ

空き家分布データは、前橋市が市全域の空き家分布状況を把握するために、2016 年度に前橋市全域で実施した空き家実態調査の結果である。空き家の空間的位置情報を経度、緯度の座標情報として保有している。また、空き家の状態に関する情報が 5 段階で格納されている（A：流通中、B：流通可能、C：要改修、D：特定空き家およびその候補、F：調査不能）。本研究では、まずは損壊度の高い空き家を判定するモデルを構築することを目的とするため、非空き家の建物の外観に近い状態である、A と B の状態の空き家は非空き家に分類するものとした。なお、空き家分布データは 2.1 の住宅地図と空間結合処理を行い、住宅地図に空き家判定情報を与えておく。

### 2.3. 360 度画像

株式会社ゼンリンが 360 度全方位高精細カメラで撮影した 360 度画像から、建物部分を抽出すること

で、建物外観画像を取得した。この360度画像は道路の計測調査や誘導画像・交通規制や道路標識などのカーナビデータベース用コンテンツの情報収集を目的として、360度カメラを搭載した自動車で撮影したパノラマ画像データである(図1)。また、計測時データとして、撮影地点の位置情報やカメラの方向、勾配なども参照できる。5400×2700の解像度で進行方向の反対側を画像の左端として時計回りに360度パノラマ撮影した画像であり、日本全国の主要道路を2.5mの間隔で撮影したデータである。そのため道路沿いの建物の外観を高解像度で把握することが可能である。なお、前橋市における360度画像の撮影時期は2011～2012年頃である。

### 3. 手法

#### 3.1. 360度画像と住宅地図の結合技術の開発

機械学習で空き家と非空き家の建物外観画像を学習させて、建物外観画像から空き家・非空き家を判定させるモデルを構築するためには、空き家と非空き家の建物外観画像を大量に生成する必要がある。そこで本研究では、まず住宅地図内の建物が360度画像のどこに存在するのかということを判定し、360度画像内から住宅地図に掲載された建物を抽出して、住宅地図の建物データと空間結合する技術を開発することで、大量の建物外観画像を作成する。また、2.2に前述した通り、住宅地図には空き家判定の情報が与えられているため、その属性を建物外観画像に与えることで、建物外観画像に空き家か非空き家かという判定情報も与えることができる。以上の処理により、空き家と非空き家の建物外観画像を生成することが実現する。

##### (1) 建物頂点の座標データ作成

本研究では(2)以降の処理を行うために、まず住宅地図から得られる建物の形状をポリゴンデータとして収録した建物レイヤから、建物ポリゴンを抽出する。続いて、同ポリゴンデータの全頂点座標を抽出してポイントデータ化することで、建物頂点の座標データ(以下「建物頂点座標データ」)を作成した。図2にその結果の一部を示す。



図1 360度画像の例

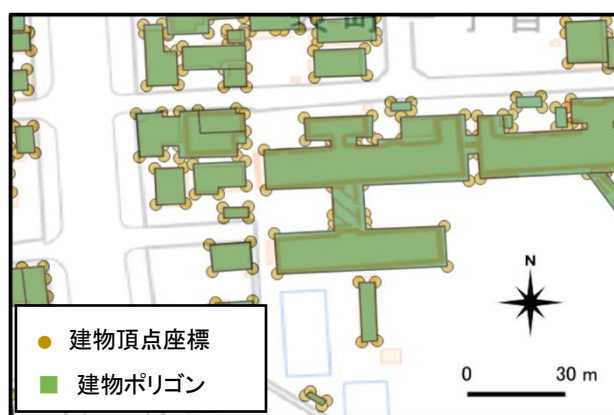


図2 建物ポリゴンデータの建物頂点にプロットされた建物頂点座標データ

##### (2) 360度画像からの建物抽出

続いて、360度画像から建物部分を抽出する。建物部分を抽出する際には、まず撮影地点から半径20m以内に存在する建物頂点座標データを抽出することで、撮影地点周辺の建物のみを抽出した。続いて、360度画像の特性上、90度方向と270度方向がレンズによる歪みの影響が最も少なくなることから(図3)、撮影地点から建物頂点までの角度の最大値と最小値の間に90度および270度を含む建物を抽出候補として絞り込んだ。そして、撮影地点と建物頂点の各座標の間から角度を求め、その角度をピクセル値に変換することで、360度画像内における建物の範囲を把握できると同時に、住宅地図の建物との紐づけが可能になる。なお、本研究で使用した画像の横幅は5400pxであるため、角度1度は15ピクセルとなる。そして、撮影地点からの建物の頂点までの角度の最大値と最小値を算出し(図4)、これらの角度に15pxを乗じることで、画像端部から建物範囲を示すピクセル値を取得することができる。

以上の手法を用いて、360 度画像から建物を抽出した結果を図 5 および図 6 に示す。図 5 では建物の両端で画像が切断されていることから、抽出対象の建物の範囲を良好に抽出できたことが分かる。ただし、図 6 に示すように抽出に失敗した例も見られる。これはレンズによる歪みが大きくなる画面端の座標を取得してしまっただけが原因であると考えられる。また、マンションやアパートといった共同住宅や雑居ビルなどの一軒家以外の建物の画像の混在が確認された。これは 360 度画像の撮影時期と住宅地図の作成時期のずれが影響しているものと考えられる。そのため、本研究ではこうした建物の画像はモデルの精度に影響を与える可能性があるため、機械学習を行う前に目視で予め排除した。

以上の処理により作成した前橋市全域の建物画像数を表 1 に示す。前橋市全域の 360 度画像の枚数は約 141 万枚であったが、以上の処理を行うことで、住宅地図と紐づいた 360 度画像は約 64 万枚であり、それらから得られた建物外観画像の枚数は約 11 万枚であった。また、このうち空き家分布データと紐づいた画像は 1,274 枚であり、さらにそのうち空き家の状態が C か D である空き家と判定される外観画像の枚数は 596 枚であった。

### 3.2. 畳み込みニューラルネットワークモデルの構築

本研究では、画像分類に強いことで知られている畳み込みニューラルネットワーク（以下「CNN」）（Simonyan and Zisserman, 2015）を用いて、空き家判定モデルの構築をした。CNN による画像処理の手順は、まず特徴を検出するフィルターで 1 ピクセルごとに位置を変えながら画像をスキャンし、畳み込み層に特徴量をマッピングする。次に畳み込み層の情報をプーリング層で集約することで、抽出した特徴が画像内で位置が変化しても影響を受けないようになる。この 2 つの層を繰り返すことで予測モデルが構築される。CNN はこの構造により、特徴量の不変性を持つ。

また、本研究では画像応用の代表的なモデルである VGG16 と呼ばれる深さが 16 層の CNN をチューニングしたモデルを作成する。さらに、モデルの分類

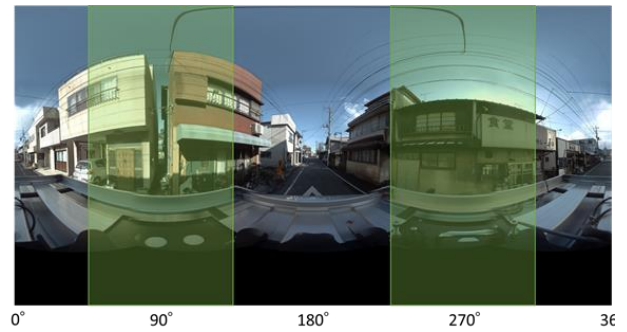


図 3 360 度画像における歪みが少ない範囲




図 4 カメラ座標と建物頂点座標との角度の関係




図 5 360 度画像から空き家の抽出に成功した例




図 6 360 度画像から空き家の抽出に成功した例

表 1 本研究で使用する建物外観画像の枚数

	画像枚数(枚)
360度画像全データ	1,409,878
住宅地図と紐づいた画像	639,556
建物外観画像	112,090
空き家画像数	1,274
空き家判定CまたはD	596

精度の検証のために混同行列を用いて評価を行った。加えて、モデルが予測を行う際の根拠を可視化するため、特徴量をヒートマップとして出力する Grad-CAM (Ramprasaath, 2017) を用いた。

## 4. 結果

### 4.1. モデルの精度評価

まず、構築した空き家判定モデルの精度を評価する。表 2 に本研究で構築したモデルによる空き家判定結果についての混同行列を示す。空き家である建物を空き家であると判定できたのは、空き家数 437 件中 394 件であり、その精度は 90.16%であった。また、非空き家を非空き家であると判定できたのは、非空き家数 492 件中 444 件であり、その精度は 90.24%であった。すなわち、本研究で開発したモデルを用いることで、空き家、非空き家ともに高精度で判定できることが明らかとなった。

図 7 に非空き家の建物外観画像をモデルに判定させた結果、非空き家と正しく判定された画像におけるヒートマップの例を示す。ヒートマップの値が高い箇所ほど、特徴量が高いことを示している。この結果から、モデルは窓や外壁を根拠として非空き家であると判断していることが分かった。同様に図 8 に空き家の建物外観画像をモデルに判定させた結果、空き家と正しく判定された画像におけるヒートマップの例を示す。この結果から、モデルは空き家の場合でも非空き家と同様に、窓や外壁を根拠として空き家であると判断していることが分かった。

一方、図 9 に判定が失敗した例を示す。誤判定になった理由は、人間の判断でも外観からの空き家・非空き家の判定が困難な建物であるためであると考えられる。外観は老朽化しているが居住可能な建物や、逆に外観は綺麗だったとしても補修等が必要で居住に適さない建物などの判定に課題があることが明らかとなった。

## 5. 結論

本研究では、建物外観画像と機械学習を用いた建物単位の空き家判定手法を行うために、まず 360 度画像と空き家データが付与された住宅地図を空間結

表 2 データの総数と抽出した空き家画像枚数

		予測値	
		空き家	非空き家
真値	空き家	394	43
	非空き家	48	444

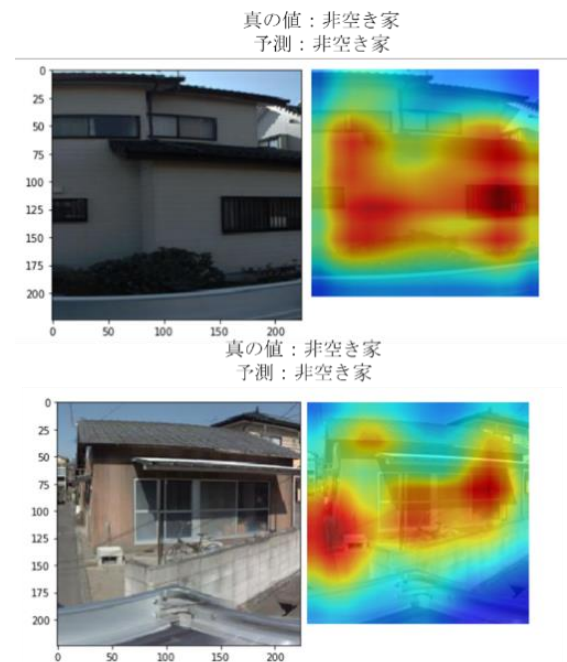


図 7 非空き家と正しく判定された非空き家の建物外観画像におけるヒートマップ

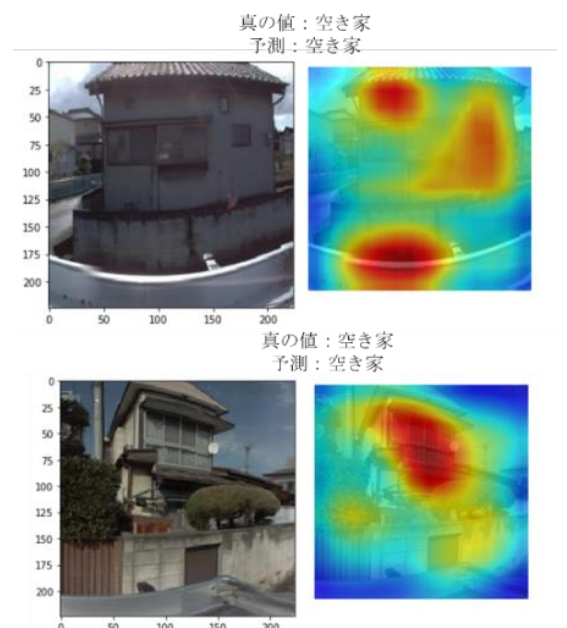


図 8 空き家と正しく判定された空き家の建物外観画像におけるヒートマップ

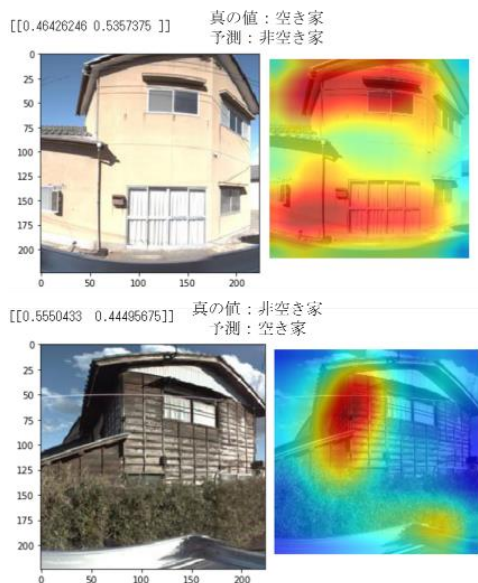


図9 正しく判定できなかった建物外観画像の例

合することで、空き家と非空き家の外観画像を大量に生成する技術を開発した。また、これらの画像データを学習データとする畳み込みニューラルネットワークを用いた空き家判定モデルの構築を行った。その結果、人の目で判断しても判定が困難な外観画像を除けば、高い精度で空き家、非空き家の判定が可能になった。今後は他の都市においても構築したモデルで空き家の判定が可能かの有効性を検証していく予定である。

## 謝辞

本研究では、群馬県前橋市より2016年度の空き家実態調査結果をご提供頂いた。また、前橋市において2011年から2012年までに撮影された360度画像は株式会社ゼンリンよりご提供いただいた。さらに、本研究は東京大学CSIS共同研究(No.992)による成果の一部である(利用データ：Zmap TOWN II(2013/14年度 Shape 版) 群馬県 データセット)。以上、ここに記して謝意を表したい。

## 参考文献

秋山祐樹・馬場弘樹・大野佳哉・高岡英生(2021)機械学習による空き家分布把握手法の更なる高度化自治体の公共データを活用した空き家の分布把握手法に関する研究(その3),「日本建築学会計画

系論文集」, 86(786), 2136-2146.

氏原岳人・阿部宏史・村田直輝・鷺尾直紘(2016)地方都市における都市スポンジ化の実証的研究,「土木学会論文集」, 72(1), 62-72.

小川芳樹・沖拓弥・関本義秀・柴崎亮介(2021)不動産に関する地理空間情報と建物画像を用いた建物の構造・築年代推定手法の検討,「日本建築学会計画系論文集」, 86(779), 357-367.

株式会社ゼンリン(2022)ゼンリンのテクノロジー ADAS <<https://www.zenrin.co.jp/product/category/technology/adas/index.html>>(最終閲覧日2022年8月30日)

倉田和己(2018)Google Street View と機械学習を用いた建物構造データベース自動生成の試み,「地震工学シンポジウム」, 15, 3552-3558.

国土交通省(2016)空き家対策の促進に関する特別措置法について <<https://www.mlit.go.jp/policy/shingikai/content/001385948.pdf>>(最終閲覧日2022年8月27日)

汐澤隆・寺木彰浩・坂田知彦・土久菜穂(2019)建物写真を用いた用途判断に関する基礎的研究,「日本都市計画論文集」, 54(3), 1556-1561.

山下伸・森本章倫(2015)地方中核都市による空き家の発生パターンに関する研究,「都市計画論文集」, 50(3), 932-937.

Li, Y., Chen, Y., Rajabifard, A., Khoshelham, K. and Aleksandrov, M. (2018) Estimating Building Age from Google Street View Images Using Deep Learning, "Proceeding of 10th International Conference on Geographic Information Science", 40, 40:1-40:7.

Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D. and Batra, D. (2017) Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization, "2017 IEEE International Conference on Computer Vision (ICCV)", 618-626.

Simonyan, K. and Zisserman, A. (2014) Very deep convolutional networks for large-scale image recognition, "arXiv preprint arXiv:1409", 1556.