

# 建物周辺の地域特性を考慮した建物ごとの空き家予測モデルの構築 - 群馬県前橋市を対象として -

水谷昂太郎\*・富田健人\*\*・秋山祐樹\*\*\*・馬場弘樹\*\*\*\*・谷内田修\*\*\*\*\*

## Developing a Prediction Model for Vacant House Which Consider the Geographical Characteristics Around Each Building -A Case Study of Maebashi City, Gunma Prefecture-

Kotaro MIZUTANI\*, Kento TOMITA\*\*, Yuki AKIYAMA\*\*\*, Hiroki BABA\*\*\*\*, Osamu YACHIDA\*\*\*\*\*

In recent years, the number of vacant houses has been increasing throughout Japan. Therefore, local governments require a quick and inexpensive method to survey the spatial distribution of vacant houses. In this study, we developed a machine learning model to predict the probability of vacant houses for each building in Maebashi City, Gunma Prefecture. This model considers geographical characteristics such as census data for each subregion, an angle of inclination and linear distance between each building and various convenient facilities, in addition to data owned by the local government (basic resident registers and water consumption data). The accuracy of the model was about 90%, and the correlation between geographical characteristics and the occurrence of vacant buildings was confirmed.

**Keywords:** 空き家 (vacant house)、地域特性 (geographical characteristics)、生活利便性 (convenience of living)、機械学習 (machine learning)、自治体 (municipality)

### 1. はじめに

我が国では少子高齢化と大都市への人口移動などの社会的背景から、全国的に空き家が漸増している。平成30年住宅・土地統計調査によれば、全国の空き家数は848万9千戸と過去最多となり、空き家率は13.6%と推計された(総務省統計局, 2019)。空き家には別荘などの二次的利用の住宅や流通している空き家、倒壊の危険性がある空き家まで様々あり、十把一絡げに扱うことはできない。しかし、特に適切に管理されていない空き家は「老朽化による発災時の倒壊の危険性」、「公衆衛生の低下」、「景観の阻害」、「治安の悪化」など、周辺住民の生活環境を悪化させてしまうリスクを孕むほか、地域全体の魅力の低下にもつながる可能性があることから、以前からその対策が求められてきた。

以上のような状況を受けて、2015年5月の「空家

等対策の推進に関する特別措置法」の施行により、適切な管理が成されていない空き家を「特定空家」として、所有者に対して適切な管理を行うための助言や勧告、また場合によっては行政代執行が可能となった。さらに、同法により全国の自治体は、空き家等に関する対策計画を策定し、施策を総合的かつ計画的に推進していくことが求められることになった(国土交通省 住宅局住宅総合整備課, 2021)。

本法の施行により、自治体の空き家対策に対する関心を高める結果となり、全国の自治体ではその対策が進められている。そうした自治体における空き家対策に関する具体的な取り組みの一つとして、空き家の所在と状態を確認し、利活用を推進していくことが挙げられる。しかし、空き家の所在を確認するための現地調査は、多大な時間と予算を要し、かつ建物の概観目視による調査のため調査員により判

---

\* 学生会員 東京都市大学 工学部都市工学科 (Tokyo City University)  
〒158-8557 東京都世田谷区玉堤 1-28-1 E-mail: g1918082@tcu.ac.jp

\*\* 学生会員 東京都市大学 総合理工学研究科建築・都市専攻 (Tokyo City University)

\*\*\* 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)

\*\*\*\* 正会員 京都大学 東南アジア地域研究研究所/白眉センター (Kyoto University)

\*\*\*\*\* 非会員 前橋市 未来政策課 (Maebashi City)

定にばらつきがでてしまうという問題を抱えている（秋山ほか，2018）．そのため，現状の空き家の所在を迅速かつ安価に，精度よく把握する手法が求められている．

## 2. 既往研究の整理と本研究の位置づけ

### 2.1. 既往研究

外観目視による現地調査による手法では前述の通り効率的ではないという問題を抱えている．そのため，官民の保有する統計情報や空間情報を用いて空き家の所在を効率的に把握・予測する手法について，既に幾つかの手法が提案されている．

例えば金森ほか（2015）は，住宅土地統計調査と住宅着工統計から導いた住宅の余剰率と，人口・世帯構成等の地域性から，都道府県単位で重回帰分析による空き家の予測を実施した．しかし同手法は都道府県単位と空間的にマクロな空き家分布把握に留まっており，空き家現地調査の代替手法となることは難しい．また石河ほか（2017）は，建物ポイントデータの住戸数と国勢調査等を活用した町丁・字単位の空き家推計を行っているが，データの一部が推計値であることや，扱っているデータ間に作成年度の違いがあるため，場所によっては精度が必ずしも高いとは言えないという課題がある．

このような潮流の中で，建物のポイントデータと自治体保有データを空間結合させて，よりピンポイントに空き家を空間把握する研究例も見られるようになった．例えば山下・森本（2015）は栃木県宇都宮市を対象に固定資産台帳，水道利用状況データを活用して，ロジステック回帰分析による空き家予測を実施した．ただし，同手法は水道使用データのうち停水中，休止中となっている物件を全て空き家と定義している．しかし，これらの状態は経年により変化するため，実情に見合ったものであるかどうかについて検証する必要があるほか，空き家予測精度検証についても十分に議論が成されていない．秋山ほか（2021）では鹿児島県鹿児島市と福岡県朝倉市を対象に住民基本台帳情報，水道利用情報，建物登記簿情報を用いて，XGBoost と呼ばれる機械学習手法を用いて 4 次メッシュ（500m メッシュ）単位での

空き家数と空き家率の予測が可能となった．しかし，同手法は建物ごとに与えられた空き家確率について空き家とみなす確率の閾値を手動で定めなくてはならないという課題を有している．また，本研究の直接的な先行研究である馬場ほか（2021）では，群馬県前橋市（以下「前橋市」）の中心市街地を対象に，住民基本台帳情報等を用いて 8 分の 1 地域メッシュ（125m メッシュ）ごとの空き家数を非常に高い精度で予測している．しかし，同手法は対象地域が前橋市の中心市街地のみを対象としていることや，空き家の発生に寄与すると考えられる交通利便性や地理的特性などの条件を加味できていないという課題を有している．

なお，空き家の分布と生活利便施設および地理的特性などの地域特性の関連性を検討した研究事例も見られる．例えば馬場ほか（2022）は，前橋市を対象に期間別空き家率と地域特性との関連について，回帰分析を実施した．同研究によると，最寄り駅またはバス停までの距離や，500m または 2,000m 圏内の食料品関連施設数は市街化区域で空き家期間が経過するほど重要因子となるものの，それ以外の地域では統計的に有意ではなかったという結果が報告されている．また，水沢ほか（2021）は，広島県呉市の斜面市街地を対象に空き家の発生要因を分析しており，空き家の発生の大きな要因として標高，道路幅員，傾斜度，築年代を挙げている．

### 2.2. 本研究の目的

本研究では，馬場ほか（2021）を受けて研究対象地域を，前橋市全域に拡張する．利用データは前橋市に協力いただき自治体保有のビッグデータ（住民基本台帳，水道使用量）を活用し，さらに民間保有の建物データとオープンデータを用いて地域特性を考慮したデータを統合する．そして，実際の空き家現地調査結果を教師データとする機械学習による，空き家の予測モデルの構築を行う．モデル構築後に，前橋市内全域の空き家の空間分布を把握するとともに，同手法の信頼性，利点，課題について議論する．

### 3. 研究方法

#### 3.1. 本研究の利用データ

本研究では後述する官民が保有するデータと国土数値情報をはじめとするオープンデータを活用した。これらのデータの特徴として、官民保有のデータは建物一棟ごとの情報を有しているのに対して、オープンデータは町丁字等の小地域や地域メッシュなどで集計された、建物周辺の状況（地域特性）を示すデータであることが多い。なお、これらのデータはそれぞれ住所または座標（経度・緯度）を有しているため、空間結合を行うことにより、データベースを構築した。以下にデータベースに組み込んだ各データの詳細を記す。

##### (1) 建物データ（民間保有データ）

2016年のゼンリン住宅地図（Zmap-TOWNII）の建物ポリゴンを利用した。建物ポリゴンには建物IDや建物名称などの他に建物用途に関する情報が付与されている。本研究の対象は戸建て住宅に限定するため、建物用途が戸建て住宅の建物に限定して空き家予測モデルを構築した。本研究における分析対象となる建物数は、前橋市全域の全建物194,315件のうち83,551件（全建物のうち約43.0%）であった。図-1に前橋市全域の個人家屋の空間分布を示す。また、建物ポリゴンの面積を算出し、空き家確率を説明する特徴量として使用した。

##### (2) 住民基本台帳（自治体保有データ）

住民基本台帳とは住民一人ひとりの住所、年齢、性別等が記載された住民票を編成したものであり、自治体が住民に関する各種事務的処理を行う際に活用するものである。本研究では、2017年3月31日現在の前橋市の全居住者（337,595人）の住民基本台帳データを利用した。なお本データは、予め個人情報に直接抵触する情報を秘匿化処理されたものを使用している。本研究では、世帯内の最高年齢および最低年齢、世帯人員総数、若年人口・生産年齢人口・老年人口別の世帯人員、世帯内の男性率を、空き家確率を説明する特徴量として利用した。

##### (3) 水道使用量（自治体保有データ）

前橋市内全域の水道栓（251,562件）の2014年度から2019年度にかけて2か月ごとの水道ID、水道使用量、水道栓住所が収録されたデータである。本研究では空き家の現地調査が実施された2016年度とその前後2015年度、2017年度それぞれの水道最大使用量を集計して利用した。加えて2015年度の水道最大使用量を基準とした2016年度比、2016年度を基準とした2017年度比を計算および集計し、空き家確率を説明する特徴量として使用した。

##### (4) 用途地域（オープンデータ）

2019年度の用途地域ポリゴンを、国土数値情報（国土交通省）より取得した。前橋市内の用途地域の面積は全域の面積のうちの約17%にあたり、JR前橋駅、上毛電気鉄道中央前橋駅を中心とする地域（以下：中心市街地）周辺が対象となっている。用途地域の種類として第二種低層住居専用地域と田園住居地域を除く11種類が指定されている。

##### (5) 国勢調査（オープンデータ）

国勢調査は日本に住むすべての人と世帯を対象に、国内の人口や世帯の実態を把握する調査として5年に1度行われている。

総務省がオープンデータとして公開している2015年度の前橋市の小地域単位の国勢調査データには、それぞれの項目の総数と区分別の集計結果の2種類が収録されている。本研究では各項目の総数当たりの区分別の割合を再集計して、その地域の特徴として建物ごとに付与した。例えば、小地域ごとの一般世帯総数あたりの一人世帯数（単身世帯数）の割合を把握した（図-2）。この結果から一人世帯は、中心市街地でその割合が大きくなっていることが分かる。このような情報を用いることで、一人世帯割合の多い地域かどうかをはじめとする地域特性が空き家予測に与える影響を確認することができる。本研究では国勢調査から、人口、就業状態、世帯構成、従業地・通学地による人口・就業状態等を、空き家確率を説明する特徴量として使用した。

(6) 標高・勾配, 生活利便施設 (オープンデータ)  
 標高・勾配の情報は国土数値情報 (国土交通省) の「標高傾斜度 4 次メッシュ第 1.0 版」から 4 次メッシュごとの平均標高と平均勾配を取得した。また生活利便施設として鉄道駅と大型商業施設のポイントデータを作成した。大型商業施設のうち, 本研究では市内南部にあるパワーモール前橋みなみ, および市外にあるもの前橋市民の利用の多いイオンモール高崎の立地に着目した。

図-3 に前橋市全域の 4 次メッシュごとの平均標高と鉄道駅, パワーモール前橋みなみとイオンモール高崎の立地関係を示す。前橋市は市内北部に位置する赤城山の山頂に向けて, 標高・勾配が大きくなる傾向にあり, 生活利便施設は比較的平坦な南部に集中して立地している。水澤ほか (2021) の研究対象地域である呉市ほど顕著な傾斜の多様性は見られないものの, 前橋市内の高齢化率が 2015 年度の国勢調査で 27.7% である (前橋市, 2019) ことを考慮すると, 僅かな標高差や傾斜が高齢者にとって生活するのにバリアになると考えられる。そこで本研究では, 各個人家屋と最寄り駅, 大型商業施設であるパワーモール前橋みなみ, およびイオンモール高崎までの直線距離と, 最寄り駅までの平均勾配を, 空き家確率を説明する特徴量として使用した。

(7) 空き家現地調査結果 (自治体保有データ)  
 同データは 2015 年から 2016 年にかけて前橋市が実施した外観目視による空き家の現地調査を行った結果である。なお, 同データは表-1 に示す 5 段階の空き家の評価判定基準 (前橋市, 2015) を属性として持っている。本データが空き家予測モデルの構築をする際の正解データとなり, 全データ件数は 7,086 件である。本研究では同データを空き家の所在の正解値 (目的変数) として使用した。

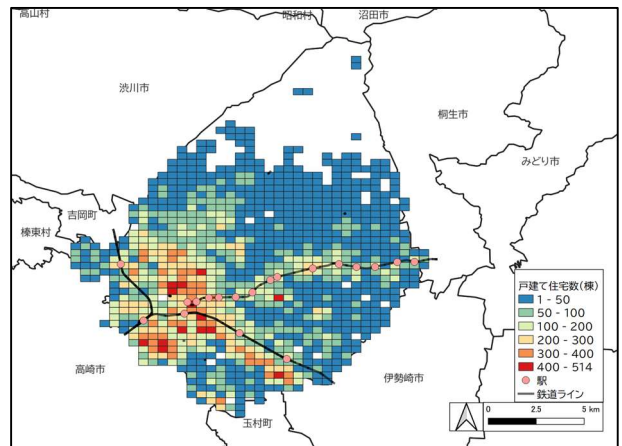


図-1. 前橋市における戸建て住宅数 (4 次メッシュ集計)

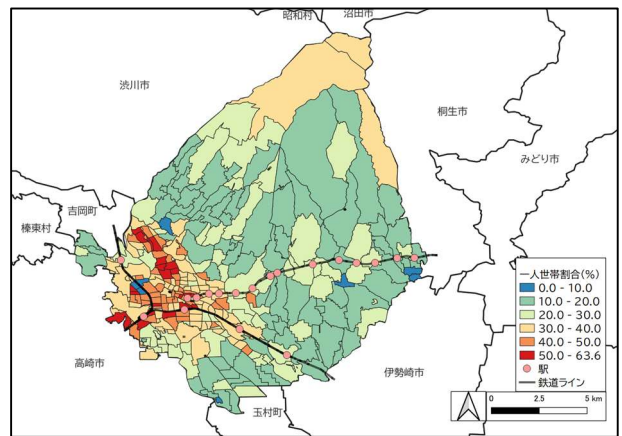


図-2. 一人世帯の割合 (小地域集計)

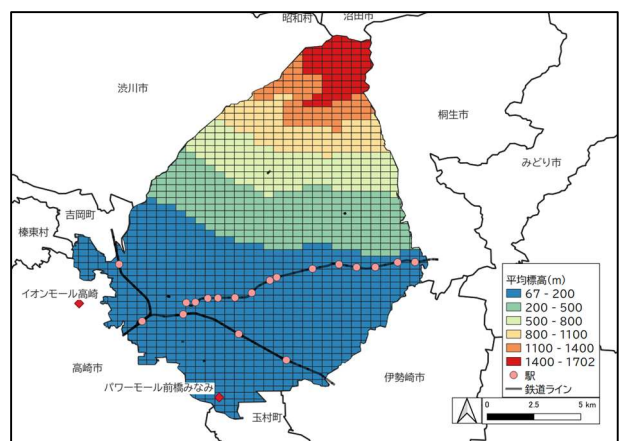


図-3. 前橋市内の 500m メッシュごとの平均標高と駅, 大型商業施設の位置関係

表-1 空き家の評価判定基準（前橋市，2015）

空き家判定	状態
ランク A	損傷は見当たらず流通に乗っている。 (入居募集の看板がある.)
ランク B	特に損傷は見当たらない.
ランク C	軽度の損傷がある.
ランク D	重度の損傷がある。 (特定空家候補)
ランク F	判定不可能 (直接確認できない住宅など)

### 3.2. データのアドレスマッチング

住民基本台帳および水道使用量データには住所情報が併記されている。本研究では Yahoo! Japan が提供する Yahoo! 地図と照らし合わせて、住所が号精度で一意的に住所が定まるデータのみ、緯度経度座標に変換をし、利用した。

### 3.3. 空間結合

最後に各建物に 3.1 のデータを空間結合させた。なお、空き家現地調査結果については、表-1 の空き家の評価判定基準が F（外観目視では状態の判断のつかなかった建物）は、空き家かどうかの判断がつかない可能性を含むため分析から除外し、また建物用途が戸建て住宅ではない建物に吸着したものについても除外した。その結果、空き家現地調査結果の約 32.3% (2,287 件) が建物データに吸着し、分析対象建物数は 83,533 件となった。続いて、住民基本台帳データが分析対象建物数のうち約 79.6% (66,489 件)、水道使用量データは分析対象建物数のうち約 78.3% (65,402 件) の建物と吸着し、これらが吸着しなかった建物については欠損値として処理した。

### 3.4. 機械学習を活用した空き家予測モデルの構築

#### 3.4.1. 本研究で使用する機械学習モデル

本研究では、決定木ベースの機械学習的分類手法の 1 つである「XGBoost (eXtreme Gradient Boosting)」(Chen and Guestrin, 2016) を用いて、建物ごとの空き家の分類を行った。XGBoost は最初に作成した決

定木モデルの誤差が小さくなるように、重みをつけながら学習をし、次の決定木モデルを作成することを逐次繰り返してモデルを確定させる、アンサンブル学習と勾配ブースティングという手法を組み合わせた手法である。

#### 3.4.2. XGBoost を採用した理由

XGBoost を採用した理由は、大きく秋山 (2021) や馬場 (2021) による以下の 2 点の知見によるものである。

1 つ目は、本研究に用いたデータのうち住民基本台帳データや水道使用量データが欠損値を含んでいるが、同手法は欠損値を補完することなく予測することができるためである。例えば約 22% の建物では水道使用量データが欠損しているが、欠損値であることによって必ずしも水道使用量は確定しないため、欠損しているという特徴をモデルに与えることが可能である。

2 つ目は、より現実に即した予測モデルを構築するためである。回帰分析による分析はモデルが単純であり、解釈性が高いという利点を有するものの、例えば水道使用量が少ない場合は空き家が単調増加することを仮定することになる。しかし、実際は非線形である可能性も考えられる。同手法では決定木モデルのため、特徴量の値の変化に応じて柔軟に空き家を予測できるため、そのような問題は生じず、比較的推定精度を高くすることができるという利点がある。

#### 3.4.3. モデル構築の前提条件

本検証では全データのうち、学習用データとテスト用データを 8:2 に分けた。なお、非空き家件数と空き家件数に大きく差があり、そのまま学習してしまうと非空き家件数にバイアスがかかるため、学習用データの非空き家件数: 空き家件数を 3:1 になるようにアンダーサンプリングを行ってから学習を行った。また XGBoost ではハイパーパラメータの設定が必要となるため、ベイズ最適化アルゴリズムの一種を利用してハイパーパラメータを最適化するためのフレームワークである「Optuna」(Akiba et al, 20

19) によるハイパーパラメータチューニングを行った。ハイパーパラメータチューニングは、決定木の深さを決める max\_depth を 3-10、過学習を防ぐための min\_child\_weight を 1-5、gamma を 0-5、subsampling を 0.5-1、各決定木でランダムに抽出されるテーブルデータの列の割合を決める colsample\_bytree を 0.5-1、学習率である learning\_rate を 0-1 の範囲でそれぞれ試行した。次に学習データを 5 つのグループに分け、クロスバリデーションによる学習により、推定空き家確率を算出した。そして推定空き家確率が 0.5 よりも大きいものを空き家 (1)、0.5 以下を非空き家 (0) と 2 値分類した。

## 4. 結果

### 4.1. モデルの評価

ハイパーパラメータを最適化した結果を表-2 に示す。学習データによる学習後、テストデータによる検証を行ったところ正解率 (Accuracy) は約 89.8% であった。この結果に基づき、全データに対する予測を実施した結果、正解率 (Accuracy) は約 90.0% であり、テストデータの正解率と同じ精度で予測ができた。また空き家か非空き家かどうかの判別性能の高さを示す AUC は約 89.2% と非常に高い水準で予測することができた。

次に全データの判別結果を表-3 に示す。非空き家と予測したものが実際に非空き家であった割合を示す特異度 (TNR) は約 90.8%、空き家と予測したものが実際に空き家であった割合を示す再現率 (Recall/TPR) は約 61.6% であり、推定モデルの信頼性が一定水準担保された。しかし、空き家と予測したものが実際は非空き家であった件数は 7,474 件と真値の空き家件数の約 3.3 倍にあたる過大評価となった。

本予測による誤差と過大評価についてはいくつかの原因が考えられるが、その大きな要因の一つとして、空き家の現地調査結果の精度が挙げられる。前述の通り、空き家現地調査結果は表-1 の水準に基づいて、人の目による外観目視によって空き家か否かの判断が行われている。特定空き家など状態が悪い空き家 (空き家ランク C・D) は外観による特徴が顕著に

表-2 ハイパーパラメータを最適化した結果

ハイパーパラメータ	パラメータ値
max_depth	4
min_child_weight	5
gamma	4.25
subsampling	0.76
colsample_bytree	0.60
learning_rate	0.091

表-3 全データの判別結果 (混同行列)

		予測値 (棟)	
		非空き家	空き家
真値 (棟)	非空き家	73,772	7,474
	空き家	878	1,409

現れるため、比較的正確に判定が可能であるが、状態が良い空き家 (空き家ランク A・B) は、空き家としての外観的な特徴が少なくなるため、判定の難易度が上昇する。そのため、判定のばらつきが発生している可能性が十分に考えられる。この結果は見方を変えれば、本推定モデルにより統計データに基づく、潜在的な空き家の発見の一助ともなりうる可能性を秘めていると言える。そのため、本予測による誤差は、その原因や有用性についてさらに検討を続ける必要があると言える。

### 4.2. 前橋市全域の推定空き家分布

図-4 に前橋市全域の 500m メッシュ単位の推定空き家数の空間分布を示す。推定空き家数は中心市街地に多く存在し、郊外にかけてその数を減らしていく分布となっている。これは図-1 で示したように一般住宅の分布に類似しており、その分布と関連した結果といえる。次に図-5 に前橋市全域の 500m メッシュ単位の推定空き家率の空間分布を示す。推定空き家率は赤城山麓付近で他の地域に比べて特に高くなっていた。また、中心市街地でも比較的空き家率の高いメッシュの分布が確認できた。



#### 4.3. 本モデルにおける特徴量の重要度と地域特性

本モデルの特徴量の貢献度を明らかにするために、「Shapley Additive exPlanations (SHAP)」(Scott, M, L. and Su-In, L., 2017) と呼ばれる手法を採用し、空き家かどうかを判断する特徴量の重要度の把握や、モデルがなぜそのような予測値を出したかという予測の裏付けを行った。図-6 は特徴量の重要度順に並べた上位 10 項目のヒストグラム、図-7 は特徴量の重要度上位 10 項目ごとのビームウォーム図を示した。なお、ビームウォーム図とは、特徴量の大きさによって、SHAP 値 (各特徴量の寄与度) との相関を把握するために使用する。SHAP 値の正の値が大きいほど、本検証では空き家である確率をより大きくし、負の値が大きいほど空き家である確率を小さくしたことを示している。例えば「水道\_2017 年水道最大使用量」であれば、水道使用量が少ないほど SHAP 値が大きくなる、すなわち、水道使用量が少ないほど空き家である確率を高めてことが分かる。

SHAP 値における分析結果は以下の通りである。水道使用量データは 2015 年、2016 年、2017 年いずれの年でも水道使用量が低いほど空き家になる傾向にあった。また、2016 年/2015 年水道使用量の使用量比は水道使用量が 2016 年にかけて負の方向に大きく変化した建物、2017 年/2016 年使用量比の変化が大きい建物が空き家になる傾向にあった。

住民基本台帳データは重要度の大きいものとして、世帯人員が少なく、世帯の男性率が高い建物ほど、あるいは住民基本台帳データが欠損値である建物が空き家になる傾向にあった。

国勢調査データは、小地域ごとの地域特性が空き家数と相関する特徴量がみられた。例えば 65 歳以上のみの世帯が多い地域や、自宅での従業員割合や自営業割合が大きい地域、共同住宅で建物全体の階数が 1・2 階建の主世帯数の割合が小さい地域ほど空き家になる傾向にあった。

各建物とそれぞれの最短距離データは、まず最寄り駅までの距離が小さいほど空き家になる傾向にあった。また、パワーモール前橋みなみ、イオンモール高崎までの距離が遠いほど空き家になる傾向にあった。中心市街地では、前橋市内でも特に地価が高

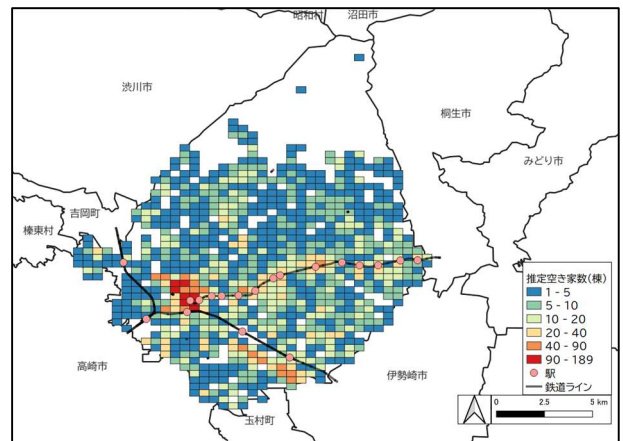


図-4. 前橋市全域の推定空き家数

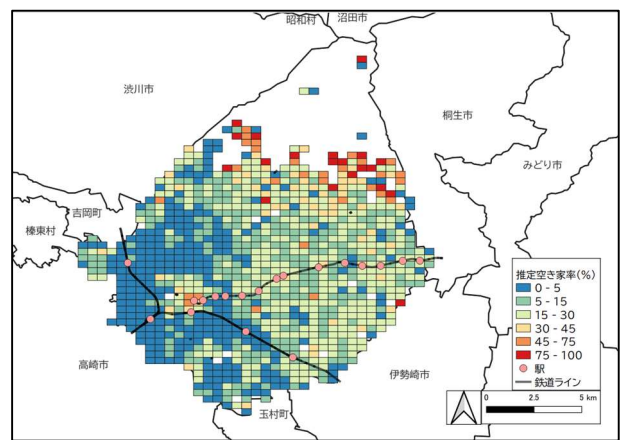


図-5. 前橋市全域の推定空き家率




図-6. 特徴量の重要度上位 10 項目




図-7. 特徴量の重要度上位 10 項目のビームウォーム図

くなる地域となる一方、車社会である前橋市では、駅までの距離は重要ではなく、車での移動のしやすさや地価の低さが居住性を高める上で重要であることが示唆される。また、各建物と駅との直線平均勾配は、赤城山麓付近の空き家率が高い地域については特徴量としての寄与が見られるが、前橋市全体では市の多くの地域で大きな起伏の変化は見られないため、大きく寄与はしなかった。

## 5. まとめ

本研究では現状の空き家を迅速かつ安価に、精度よく把握する手法として、前橋市全域を対象に官民保有のビッグデータとオープンデータを用いて地域特性を考慮したデータを作成し、実際の空き家現地調査結果を教師データとする機械学習による、空き家の予測モデルの構築を行った。馬場ほか (2021) の中心市街地に限定したモデルから、市全域へと拡張した結果、モデルの精度は約 90% と高い水準で予測が可能であることが確認できた。また、これらの予測にどのような特徴量がどの程度影響するのかを可視化することで、地域的特性と空き家の関係性についても議論することが可能となった。

また本研究では、ある地点の空き家を空間的にミクロなスケールで把握することを目的としていたが、今後の展開として、本研究の知見の一つである空き家が増加傾向にある地理的特徴が把握可能となったことから、現在空き家が発生しやすい地域の推定にも利用できる。このような結果は、現地調査による空き家調査を実施する際に、どの地域から優先的に空き家の状況を調査・確認すべきかという優先順位をつける際に、有用であるものと期待される。

さらに現在多くの地方公共団体では、EBPM (証拠に基づく政策立案) の推進に取り組んでいる一方で、空き家に関する政策に関しては、現状では人の主観に大きく左右される空き家の現地調査結果のデータに基づいて実施されている状況にある。本研究により、なぜ空き家と判断できるのかということが水道使用量や住民基本台帳の情報などの客観的な事実に基づいて説明可能となり、空き家に関する政策形成に大きな変化を促せると考えている。

今後取り組むべき課題として、XGBoost 以外にも分析手法は幾つか存在するため、他の手法によるモデル構築による精度評価を行うことが挙げられる。また、空き家と各特徴量との相関の強さが偶々発生しているのか、あるいは因果関係が含まれているかどうかについての検証も必要である。さらに、空き家と予測した住宅について改めて現地調査を行い、どの程度潜在的な空き家が存在するのかを現地調査の結果と比較し、より現実に即した空き家予測モデルの構築を進めていきたい。

## 謝辞

本研究は東大 CSIS 共同研究 (No.880) の一環として実施した。また、本研究は前橋市における超スマート自治体研究協議会および前橋市未来政策課より、前橋市の自治体保有データ (住民基本台帳、水道使用量データ、空き家現地調査結果) の提供を受けることで実現した。さらに、東京都市大学総合研究所デジタル都市空間情報研究開発ユニットの成果の一部でもある。ここに記して謝意を表したい。

## 参考文献

- 秋山祐樹・上田章紘・大野佳哉・高岡英生・木野裕一郎・久富宏大 (2018) 鹿児島県鹿児島市における公共データを活用した空き家の分布把握. 「日本建築学会計画系論文集」, **83** (744), 275-283
- 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. 「日本建築学会計画系論文集」, **86** (786), 213-2146.
- 石河 正寛・松橋 啓介・金森 有子・有賀 敏典 (2017) 住戸数と世帯数に基づく空き家の詳細地域分布の把握手法, 「都市計画論文集」, **52** (3), 689-695.
- 金森 有子・有賀 敏典・松橋 啓介 (2015) 空き家率の要因分析と将来推計. 「都市計画論文集」, **50** (3), 1017-1024.
- 国土交通省 住宅局住宅総合整備課 (2021) 空家等対策特別措置法について. <<https://www.mlit.go.jp/policy/shingikai/content/001385948.pdf>>.



総務省統計局 (2019) 平成 30 年住宅・土地統計調査 住宅及び世帯に関する基本集計 結果の概要. <[https://www.stat.go.jp/data/jyutaku/2018/pdf/kihon\\_gaiyou.pdf](https://www.stat.go.jp/data/jyutaku/2018/pdf/kihon_gaiyou.pdf)>.

馬場弘樹・秋山祐樹・谷内田修 (2021) 自治体保有データを活用した空き家の空間分布の将来予測モデル構築 -群馬県前橋市を対象として-. 「土木学会論文集 D3 (土木計画学)」, **77** (2), 62-71.

馬場弘樹・秋山祐樹・清水千弘 (2022) スマートメータを利用した空き家機関と地域特性との関係分析 -群馬県前橋市を対象として-. 「GIS—理論と応用」, **30** (1), 39-50.

前橋市 (2015) 前橋市空家等対策計画. <<https://www.city.maebashi.gunma.jp/material/files/group/63/akiyataisakukeikaku.pdf>>.

前橋市 (2019) 平成 27 年国勢調査結果. <<https://www.city.maebashi.gunma.jp/soshiki/seisaku/johoseisaku/gyomu/8/2/3231.html>>.

水沢克哉・田村将太・田中貴宏 (2021) 斜面市街地における空き家の発生要因に関する研究 -広島県呉市両城地区を対象として-. 「都市計画論文集」, **56** (3), 897-904.

Chen, T. and Guestrin, C. (2016) Xgboost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794.

Scott, M, L. and Su-In, L. (2017) A Unified Approach to Interpreting Model Predictions. *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 4768-4777

Takuya, A., Shotaro, S., Toshihiko, Y., Takeru, O. and Masanori, K. (2019) Optuna: A Next-generation Hyperparameter Optimization Framework. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2623-2631.