

〈一般研究課題〉 機械学習を用いた都市空間の安全対策に資する
建物構造データベース構築
助成研究者 名古屋大学 倉田 和己



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

倉田 和己
(名古屋大学)

Automatic generation tool for building structure database using machine learning and google street view.

Kazumi KURATA
(Nagoya University)

Abstract :

In earthquake damage prediction survey, “Construction Year” and “Structure Type” are important parameters. But, such kind of information is “Non-Open data” because of privacy issue. In this research, we apply "Google Street View" to machine learning as a new idea for generating building structure database. These technologies may realize new and seamless (beyond administrative district) method in earthquake damage prediction.

1. はじめに

地震被害予測調査では、建物の被害量を正確に推定することが特に重要である。内閣府および、各自治体が行っている地震被害予測調査では、建物被害量を算出するために建物の強度にまつわるデータの収集およびデータベース化が行われる。具体的には、課税台帳等の行政資料から建物一棟一棟の構造種別や建築年、階数といったデータを整理し、あるメッシュサイズで集計することで建物構造データベースが得られる。これに、地震動などの外力および建物の被害率曲線を組み合わせることで、メッシュごとの建物被害棟数が得られ、これをもとに人的被害などについて算出される(図1)。従って、このような建物構造に関するデータベースの品質は、地震被害予測調査における被害の推定に直結する、極めて重要な要素の一つであるといえる。また、実際の被害地震においても、各建物の耐震性能と被害の対応を正しく把握することは、建築構造技術の発展のために欠かせ

ない。

このように、被災前の被害予測や被災後の被害調査にまつわる各種の研究においては、しばしば対象となる都市空間の建物構造データベースが必要となってくる。しかしながら、こうしたデータベースは課税台帳等の行政資料を原典としており、それらは個人情報と密接に関係するため、特段の理由がない限り研究開発目的では自由に活用できない。そこで本研究では、Web上から得られるオープンデータをもとに、都市空間の建物構造データベースの自動生成を目的としたソフトウェアの開発を行った。将来的に、任意の地域において、ある程度の精度を持った建物構造データベースが容易に入手できるようになれば、地震被害予測調査の高度化につながるような新たな被害予測手法の開発や、行政区単位(データ提供元の単位)に依存しない、柔軟な被害予測調査の実施などが期待される。

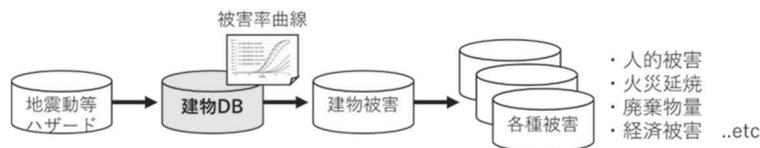


図1. 地震被害予測調査における建物構造データベースの位置づけ(イメージ)

2. 既往の研究と本研究のアプローチ

2.1 既往の研究

まず、地震被害予測調査に関連して建物データベースを取り扱った研究について整理する。石田ら¹⁾は愛知県の地震被害予測調査に関連して建物データベースシステムを整備し、その元データは愛知県総務部および名古屋市消防局から特別に提供された。阪田ら²⁾は事業所系建物の集積度状況を広域的に把握するために東京都GISのデータを用いており、論文中において「現状では固定資産税家屋台帳の個別の家屋に関する延べ床面積を閲覧・転記することが最も高精度にこの種のデータを取得することが出来る方法である。しかし、一般的に都市計画研究のためにこのデータを大量に取得することは極めて困難であり、仮に大量に取得できたとしても、地理的分析のために地図上にこの情報を布置していくことは莫大な労力と時間が必要である」と記している。境ら³⁾は人口集中地区ほど非木造 高層の建物の割合が増加するという仮定のもと、関東圏を対象に、国勢調査の人口絶対値と中夜間人口比によって建物棟数を推定した上で、この手法では団地などで精度が悪くなるとしている。また中村⁴⁾は住宅地図データ、不動産物件情報、固定資産概要調書等の資料を用いて、全国5,600万棟の建物構造モデルを作成している。このように、本研究でも指摘したとおり、建物構造データベースの重要性は認識されつつも、研究目的でそれを整備することには多大な苦勞が伴うといえる。

また、昨今では新たな情報技術を活用した建物構造データベース構築や建物被害把握の試みがなされている。峰後⁵⁾らは自動車等からの地上レーザー測量に基づく3次元点群データを用いて、市街地建物モデルを構築するために、機械学習によるデータの分類を行っている。具体的には、市街地に存在する建物、電柱、街路樹等の各オブジェクトの特徴量を算出することでオブジェクトを自動的にセグメンテーションする手法を提案しており、航空レーザー測量等との併用による精度改善の可能性を示唆している。後右近⁶⁾らは衛星からの合成開口レーダー(SAR)画像を用いて津波被災建物を抽出する手法において、機械学習を用いている。SAR画像から得られる複数のパラメータ

に基づき、機械学習による決定木の最適化処理を行うことで、流失建物の判定処理を最適化するものである。ただし、この手法でも被災時の正確な建物輪郭データが必要であることを付記している。これらに共通するのは、大規模な原典データ(ビッグデータ)から機械学習を用いて、建物の特徴を識別・判定し、望むデータベースを構築しているという点である。

2.2 本研究のアプローチ

本研究では、先行研究と同様に、大規模な原典データから機械学習で建物データを抽出するアプローチを用いることとする。原典データには、Googleが公開している市街地の360度カメラ映像をもとにしたGoogle Street Viewを用いる。さらにGoogle Street View画像を、事前に学習させたモデルを用いて機械学習により判別することで、対象建物の構造種別等を判定し、建物構造データベースを構築することが目標である。次章以降で、具体的な手法について述べる。本研究の独自性は、無料で利用可能なGoogle Street View画像を原典データとして用いることと、機械学習の現在最もポピュラーな活用方法の一つである画像分類を活用することである。Google Street Viewは全国を対象に(Volume)、頻繁に更新がなされ(Velocity)、多様な情報(Variety)を含む代表的なビッグデータ(3つVを持つデータ)であり、今後もデータの充実と活用が期待される。また、機械学習を用いた画像分類は多くの分野で既に活用されており、優れた既存のライブラリや学習済みモデルの活用が可能である。これにより、本手法は低コストかつ、将来に向けての精度向上が期待できると考えた。

3 Google Street View画像ライブラリの作成

3.1 画像ライブラリ作成の基本的な考え方

Google Street View画像取得には、Street View APIを用いる。これは、URL文字列でGoogleのサーバにリクエストを送信すると、リクエストに応じたGoogle Street View画像がレスポンスとして得られるものである。リクエストと得られた画像の例を図2に示す。sizeは画像サイズ、locationは画像の位置(緯度経度)、headingは東西南北の方角、pitchは仰角を示している。keyはAPIを利用するための個人キーである。レスポンスとして、パラメータに応じたGoogle Street View画像ファイルが得られる。



図2. Street View APIのリクエストおよびレスポンスの例

本研究で開発する建物データベースは、被害予測調査で用いることを念頭に、GISで取り扱うことのできる空間データベースとする。そのため、Google Street View画像を建物ポリゴンGISデータと紐付けるプロセスが必要である。これについては図3のように行う。まず、建物ポリゴンにおいて平面形状の重心点を算出し、そこから道路中心線に向けて、最短となる垂線を下ろす。続いて道路中心線と垂線の交点を観測点と定義し、観測点の緯度経度を算出する。この観測点の緯度経度

が、Street View APIでリクエストする際のlocationパラメータとなり、建物ポリゴンとGoogle Street View画像は、それぞれ対応する重心点、観測点の固有IDの対応によって紐付けられる。なお、本研究では建物ポリゴンについては市町村の都市計画基礎調査で作成されるGISデータを、道路中心線はルート検索用のデータであるDRMを用いた。

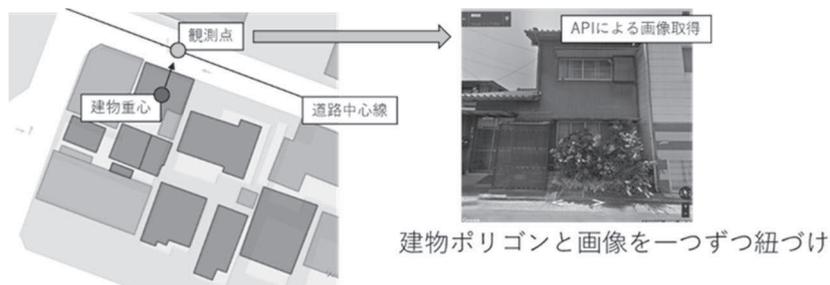


図3. 建物ポリゴンとGoogle Street View画像の紐づけの考え方

3.2 画像ライブラリにおける教師用データ作成の考え方

機械学習モデルの学習を行うための訓練データおよび検証用のデータ、すなわち教師用データセットを生成するためには、建物構造に関する真の値が必要である。本研究では、愛知県碧南市および岡崎市から建物構造情報を含む都市計画基礎調査GISデータの提供を受け、教師用データセットを作成した。訓練データとしては提供された都市計画基礎調査GISデータを前項の手法でGoogle Street View画像に紐づけし、構造種別と階数を画像にタグ付けすることで生成した。また検証用データの生成においては、Google Street View画像を訓練データによって学習させた機械学習モデルによって分類し推定された構造種別と階数を画像にタグ付けした後紐付けられた都市計画基礎調査GISデータに記された正しい情報と推定された情報を比較・検証する(機械学習モデルについては4章で詳述する) なお、推定精度を正しく評価するために、訓練データと検証データでは画像が重複しないようにする必要がある 以上の教師用データ生成フローを図4に示す。

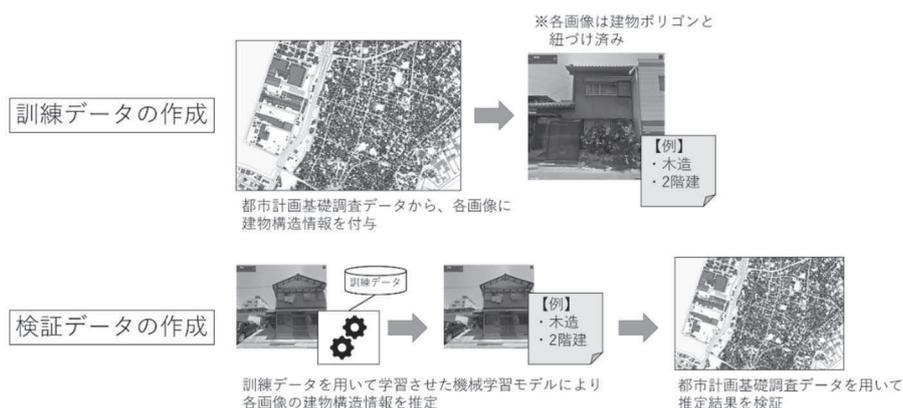


図4. 機械学習のための教師用データ生成フロー

3 3 画像ライブラリ構築における課題と対応結果

図3に示した方法を用いて、自動的にGoogle Street View画像を取得し建物ポリゴンと関連付けるプログラムを作成し実行したところ、複数の課題が明らかになった。1点目は、図5に示すとおり、観測点においてリクエストした位置(緯度経度)と、レスポンスで得られた位置(緯度経度)が異なるという問題である。これは、Google Street Viewの仕様に基づく結果であり、Google Street

View画像は道路上に等間隔かつ離散的にしか存在していないことに起因する。2点目の課題は、沿道から離れた建物の場合、観測点と対象建物の距離が長くなり、得られた画像において建物の占める部分が非常に小さくなってしまふものである。さらに3点目の課題は、対象とする建物と観測点の間に別のポリゴン(別の建物などの遮蔽物)がある場合、映像が取得できないというものである。以上について、1点目の課題はStreet View APIのリクエストと、レスポンスにおける緯度経度の差分から、heading(方角)のリクエストパラメータを修正し、正確に建物重心へ向かった画像が取得できるよう画像取得プログラムにフィードバック処理を追加した。2点目と3点目の課題は、そもそもそういった画像を利用しないこととし、画像取得プログラムにおいて特定条件の建物ポリゴンを除外するようにした。本論では課題2の場合、観測点から建物ポリゴン重心までの距離50mを閾値とした。また、観測点と建物ポリゴン重心を結んだ直線状に交差するポリゴンがある場合、対象建物を除外することとした。さらに、平面形状の面積が30㎡未満の建物についても、住居である確率が低いとみなし処理対象から除外するようにした。

この結果、表1に示す通りの画像ライブラリが取得された。都市計画基礎調査データの提供を得られた碧南市、岡崎市とも、対象建物ポリゴンのうち約6割について、画像と建物ポリゴンの紐づけに成功したが、一方、3割弱の対象建物ポリゴンが、別のポリゴンで遮蔽されGoogle Street View画像が取得できなかった。このことは、Google Street Viewが道路を走行する車両からの画像取得に基づいて構築されているため、車両の入ることの出来ない細街路を有する旧市街地で、処理対象外となったポリゴンが多いと推察される。他方、沿道建築物の倒壊は道路閉塞に繋がり、復旧の遅れを引き起こすため、これらの耐震性を優先的に把握することは、本研究の目的に一致するものである。



図5. Street View APIを用いた際の観測点リクエストとレスポンスのずれ

表1. 碧南市および岡崎市における画像ライブラリの構築結果

	碧南市	岡崎市
対象建物総数 (30㎡以上)	33,632件	157,390件
【課題2】沿道ではない	4,591件 (14%)	22,248件 (14%)
【課題3】別建物で遮蔽	9,603件 (29%)	41,282件 (26%)
Street View画像なし	379件 (1%)	2,692件 (2%)
APIエラー	1件 (0%)	4,444件 (3%)
画像取得成功	19,058件 (57%)	86,724件 (55%)

4. 機械学習による建物構造の分類と考察

4.1 Google Street Viewで得られた画像の分類結果と考察

前章で構築した画像ライブラリを用いて、建物構造の機械学習による分類がどの程度可能かを検証する。機械学習のソフトウェアライブラリにはGoogleが公開しているオープンソースのTensorFlowを用い、学習済みモデルとして一般公開されている汎用画像分類モデルのVGG-16(畳み込み13層 全結合相3層のニューラルネットワーク)を適用した 訓練データを用いて、第5ブロックの畳み込み層および全結合層の再学習を行うファインチューニングを実施した上で、検証データを用いて学習結果を評価した後、検証データとは別のテストデータを用いて正解率を算出した。検証データを最終的な正解率の評価に用いない理由は、検証データに関する過学習を避けるためである。以下では建物構造の分類は木造/非木造の2クラスまたは1階建/2階建の2クラスとし、訓練データ数は各クラス4000件、検証データ数およびテストデータ数は各クラス1000件とした。

表2に、碧南市の画像ライブラリを用いた結果を示す。ファインチューニングしたVGG-16による分類では 正解率は70%程度となった。2クラス分類のため期待値は50%なので、決して良い精度とは言えない。他のモデルを用いたり、予めモノクロ化した上で分類したりするなどしたものの、精度は向上しなかった。そこで、Google Street View画像から物体検知モデル(SSD: Single Shot MultiBox Detector)を活用して建物部分だけを抽出し、同様にしてVGG-16による分類を試みた。結果は同様に70%程度の正解率であり、そもそもGoogle Street View画像に映っている建物画像をうまく分類できていない可能性が考えられる。例えば、比較的新しい戸建て住宅であれば、それが木造なのか非木造の軽量鉄骨造等であるのか、人間の目をもってしても画像から正確に判断できない場合が多い。今回の対象地域はそうした建物が比較的多く、誤分類が生じているものと考えられる。

表2. 碧南市における画像分類結果

Street View画像の分類結果例 (碧南)	
VGG16のファインチューニング	畳み込み層3層と全結合層3層を再学習
訓練データ数	4000件×2クラス
検証データ数	1000件×2クラス
テストデータ数	1000件×2クラス
画像の下処理	建物部分の物体検出によるトリミング
木造/非木造の正解率	71.0%
1階建/2階建の正解率	72.4%

4.2 建物画像ビッグデータによる分類結果と考察

より一般的な建物画像ビッグデータを用いて、そもそも外観写真を使って機械学習による構造種別分類がどの程度できるかを検証した。データセットとしては、株式会社LIFULLが研究目的で提供している、不動産物件画像のビッグデータである「LIFULL HOME'Sデータセット」のうち、建物構造が明記されており、かつ建物外観が識別できる画像を抽出して用いた。画像解像度はすべて120×90ピクセルに統一されている。用いた分類は木造/非木造の2クラスであり、訓練データ数は各クラス2000件、検証データ数およびテストデータ数は各クラス500件である。学習モデルは前節と同様にVGG-16を用い、同様にファインチューニングを実施した。

その結果、正解率は85%程度となった。Google Street View画像よりも15%程度上回っていることから、本研究で提案する手法では、Street View APIで得られる画像の精度を改善することが手法の改善につながると考えられる。現時点では3.3節に記した以上の工夫ができていないものの、Street View APIの改善やGoogle Street View元データの高精度化によって改善されることも期待

される。

5. まとめと今後

本研究では、Google Street Viewと機械学習を用いた、都市空間の建物構造データベース構築へ向けた試みについて、これまでの結果を概説した。現時点では地震被害予測調査等に用いることはできないが、Google Street Viewについては、特に都市部で頻度高く新たなデータが整備されており、今後は過去のデータについてもAPIで取得できるようになると期待される（Web上での閲覧は既に可能となっている）。例えば、複数年時点のGoogle Street View画像を比較するなどして、建物の築年数を高精度に推定するなどの活用が想定される。また、本研究は対象を変更し、例えば地震時の危険物としての看板や自動販売機、電柱、電線等の配置を空間的に把握する等の用途も考えられる。引き続き、改善や検討を行っていく所存である。

謝辞

本研究では、株式会社LIFULLが国立情報学研究所の協力により研究目的で提供している「LIFULL HOME'Sデータセット」を利用しました。記して謝意を表します。

参考文献

- 1) 石田栄介・福和伸夫・荒川政知・小出栄治, 愛知県地震被害想定のための建物データベース活用GISの構築に関する研究, 日本建築学会学術講演梗概集. B-2, pp.69-70, 1996
- 2) 阪田知彦・吉川徹, GIS建物データとメッシュシステムに立脚した東京都区部における延べ床面積規模別事業所系建築物の地理的分布の分析, 日本建築学会計画系論文集, 66(545), pp.189-196, 2001
- 3) 境有紀・福川紀子・新井健介, 地震被害推定をより正確に行うための構造種別や層数を考慮に入れた建物群の構築, 日本地震工学会論文集, 9(5), pp.21-28, 2009
- 4) 中村洋光, リアルタイム地震被害推定システム(J-RISQ)の開発, 表面科学, 37(9), pp.457-458, 2016
- 5) 峯後俊秀・伊達宏昭・金井理, 市街地MMS点群からの機械学習手法によるセグメンテーションと建物LODモデリング, 精密工学会学術講演会講演論文集, 2016S(0), pp.148-159, 2009
- 6) 郷右近英臣・越村俊一・松岡昌志, TerraSAR-X画像の建物一棟ベース・解析区画ベース解析の融合による津波被災地の建物流失被害の把握, 日本地震工学会論文集 16(3), pp.147-156, 2016

