

深層学習による衛星データを用いた人口統計データ作成手法の開発と検証（ジャカルタを事例に）

伊東 里保・原 香代・飯野 翔太・島崎 康信・彦坂 修平・森 紀之・可児 好宏・藤田 航
(株式会社パスコ)

1. はじめに

製造業・卸売業を中心として、日本企業が海外、特にASEAN地域に対しての進出を進めており、2016年までにASEANに進出した日本企業は1万1328社にのぼる¹⁾。出店計画等のエリアマーケティングのために各地域の人口分布等の情報が必要となるが、開発途上国においては各種統計データの入手が困難である。統計データの一例として国勢調査の結果を入手できる地域もあるが、更新は不定期でありエリアマーケティング等に必要な最新の統計データを得ることが難しい。例えば図1に示すようなインドネシアのジャカルタ市の国勢調査結果に着目すると最近の更新は2000年と2010年であり、それ以降の最新の統計データは更新されていない。また国勢調査の統計データは村などの大きな単位で作成されており、エリアマーケティング等で求められる数百メートルメッシュ単位での統計データは存在しないのが実情である。

2. 衛星画像を用いた人口推定の先行研究

人口推定の先行研究は主に土地利用図を利用しているが、各国の政府等が公開する土地利用図は更新が不定期で最新のものを入手するのが困難である。そのため、衛星画像や建物ポリゴンなどを用いて居住地を推定する方法が継続的に研究されており、近年は画像認識分野で高い性能を得ている深層学習を用いて衛星画像から人口を推定する手法なども提案されている。Bastらは、OpenGeoDBのセンサス統計データとオープンストリートマップ（以下OSM）の建物ポリゴン・Point of Interest（以




図1 ジャカルタ市における2010年度国勢調査結果（世帯数）

下POI）・道路ネットワーク・土地利用図等を用いて、回帰ツリーによる欧州やアメリカの都市について人口推定を行った²⁾。この研究では、OSMのデータが整備されているエリアを対象にしているが、開発途上国の人口推定においては、OSMのデータがエリアによって欠損しているなどの問題点がある。また、Robinsonらは米国の衛星画像から切り出したパッチ画像内に含まれる人工物の多寡を14クラスに分類し、クラスごとに人口係数をかけ合わせることで、人口を推定する手法を提案した³⁾。

しかしこれら既存の手法では、地域の疎密度・高層マンションの世帯・非居住地などを考慮していないため、実情の世帯数・人口とは誤差が大きくなってしまふ。例えば、高級住宅が並ぶ低密度地域やスラム地域等の高密度地域において、誤差が大きくなる。また特定のエリアにおいては中高層マンションが立地しており、その世帯数・人口を衛星画像のみを用いて推定した結果と実情の統計データでは、誤差が大きくなってしまっていた。

3. 提案する手法

3.1 手法の概要

建物数推定フェーズでは深層学習の手法を用いる。深層学習は画像分類、物体検出、領域分割などコンピュータビジョンの分野既存手法よりも高い性能を得ている人工知能の技術の一つである⁴⁾。深層学習の利点の一つは、学習データから自動的に特徴量を学習し、特徴抽出と識別を一括で行うことができる点である。また、一度モデルを作成すれば、一定の判断基準において推定を行うことができるという利点もある。

世帯数・人口を推定するために、まずは深層学習により建物ポリゴンを推定しポリゴンの数をカウントする手法を検討したが、建物ポリゴンを推定するためには建物数だけでなく衛星画像から見える建物の形状に即した建物ポリゴンの教師データが必要となる。

そこで本研究では、教師データとして建物数そのものを与えることで、衛星画像のテクスチャの特徴から100mメッシュ内に含まれるおおよその建物数を推定できるような深層学習モデルについて検討を行った。そして、その推定結果に対して政府発表のゾーンマップや光学衛星画像、SAR衛星画像を基に作成した非居住地マップやエムポリスの高層建物情報などの統計情報を用いた補正や、雲の影響を受けている箇所の補正などを行うことで、最終的な人口・世帯

数の推定結果を高精度化する手法を提案する。本研究ではインドネシアのジャカルタ市全域を対象として、建物数および世帯数を推定する手法について検討を行った。

3.2 手法のフロー

提案手法のフローを図2に示す。本手法は以下の5ステップから成る。

1. 深層学習を用いて光学衛星画像からジャカルタ市全域における100mメッシュごとの建物数を推定し、係数をかけ合わせて推定世帯数/人口を算出。
2. 光学衛星画像・土地利用状況を示したゾーンマップ・Google mapの建物名称を利用して非居住地エリアマップを作成し、推定世帯数/人口を補正。
3. 高層マンションのPOIデータを用いて高層マンション世帯数補正マップを作成し、推定世帯数/人口を補正。
4. 雲がかかっている地域について推定世帯数/人口を補正。
5. 建物数が異常値を示すメッシュについて地域に合った補正。

4. 深層学習による建物数推定

4.1 建物数推定の教師データ作成

深層学習において、モデルの学習を行うには




図2 提案手法のフロー



図3 SPOT衛星画像およびOSMの建物ポリゴンの例

教師データが必要となる。建物数を推定するためには、建物の形状が判別できる程度の空間分解能を持った衛星画像を用意する必要があるだろう。一方で、分解能が高くなるほど処理すべきデータ量が増え、時間的・金銭的成本が増加する。そこで本研究では、図3に示すような建物の境界は曖昧であるが、形状はある程度判別できる1.5m分解能のSPOT衛星画像（ジャカルタ市全域、2017年度撮像）を用意した。

また、衛星画像に対する建物数の教師データとしてOSMの建物ポリゴン（2017年度更新）を加工して作成した100mメッシュごとの建物数マップを用意した。この時、建物数のカウントは建物の大きさに寄らず、各建物の中心点のみを用いて行った。つまり、メッシュ内に大きい建物が1つあった場合も、小さい建物が1つあった場合も、建物数の推定結果としては1が期待される。建物の面積や階数による人口の補正については5章に示す後処理によって行う。

教師データを作成するにあたりOSMの建物ポリゴンを未加工で利用することも検討したが、OSMの建物ポリゴンは任意の市民の手によって作成されたデータであり、対象地域にある全ての建物が網羅的に抽出されているわけではない。例えば図3において建物は白いポリゴンで示されているが、過密地域では隣接する建物が1つのポリゴンに纏められている、または抽出漏れがあるなど、建物ポリゴンが衛星画像

に即していない地域が多く存在する。そこで本研究ではジャカルタ市の一部地域においてOSMを補正し、教師データとして3種類のデータを作成した。

1. OSMデータが信頼できる地域: 国勢調査の結果から算出した村単位の人口密度と、OSMから算出した村単位の人口密度の誤差が15%以内のメッシュ。
2. 高密度地域: OSMの建物ポリゴン数と光学衛星画像からわかる建物数の乖離度が高いため、OSMから算出した建物数に補正をかけたメッシュ。
3. 低密度地域: OSMの建物数と光学衛星画像からわかる建物数がおおよそ一致しているため、OSMから算出した建物数を採用したメッシュ。

4.2 深層学習のモデル

本研究で用いた深層学習のモデルを図4に示す。モデルへの入力は光学衛星画像から切り出した100mメッシュの小パッチ、出力は入力された小パッチ内に含まれる建物数の推定値とした。

本モデルは6層の畳込み層、3層のプーリング層および全結合層からなる。畳込み層及びプーリング層では建物数推定に最適な特徴量を学習し、全結合層では建物数の推定を行う。全結合層の活性化関数は線形関数とし、回帰




図4 建物数推定用の深層学習のモデル




図5 非居住地エリアマップの作成フロー

を行った。学習時において、教師データの建物数とモデルが推定した建物数の誤差の算出には最小事情誤差関数を用いた。

5. 建物数推定結果の補正

5.1 非居住地エリアマップによる補正

非居住地エリアマップの作成フローを図5に示す。光学衛星画像から建物数を推定する場合、小パッチ内に含まれる建物が居住用であるか、もしくは商業・工業・政府機関の非居住用であるかの判別が難しい。そこで、非居住地エリアマップを新しく作成することとした。

5.1.1 SAR画像からの人工物抽出

非居住地エリアマップ作成時の参考情報の一つとして、深層学習を用いてSAR衛星画像から抽出した人工物マップを使用した。SAR衛星画像は光学衛星画像とは違い雲を透過するため、雲の影響を受けずに人工物を抽出することができる。SAR衛星画像は空間分解能0.5mのTerra SAR-Xを用いた。学習に用いた教師データは、ジャカルタ市の一部領域に対して手動でラベル付けを行った人工物マップである。深層学習のモデルの基本的な構造は建物数推定のモデルと同様であるが、入力された小パッ




図6 SAR衛星画像からの人工物の抽出結果




図7 高層住宅世帯数補正マップ

チが人工物であるかどうかの分類ができるように最終層にSoftmax関数を追加し、学習時のLoss関数をCross Entropyに変更した。人工物の抽出結果を図6に示す。

5.1.2 非居住地エリアの補正

深層学習を用いてSAR画像から抽出した人工物マップの他に、建物名称、光学衛星画像、インドネシア政府が出しているゾーンマップ、統計調査の村別世帯数などを組み合わせることによって非居住地マップ作成した。非居住地エリアと建物推定をしたメッシュを重ね、メッシュの8割に非居住地エリアが重なった場合は、非居住地メッシュとして世帯数・人口総数を0とした。

5.2 高層建物情報による補正

高層マンションは建物1棟あたりの世帯数が戸建ての住居と大きく異なる。そこで高層マン

ションPOIと重なったメッシュの世帯数は現地不動産サイトや不動産冊子から調査した世帯数（又は、調査データから作成した1Floorあたり世帯数×建物階数）で計算することとした。図7にPOIから算出した補正が必要な領域および世帯数の補正値を示す。

5.3 雲がかかっている地域の補正

光学衛星画像を用いて処理を行う場合、雲の影響について考慮しなければならない。本研究では、雲および雲の影がかかる地域はOSMの建物数を採用する。ただし、OSMは必ずしも正確ではないため、時点の近い他の衛星画像もしくは航空写真とOSMを比較することで建物数の補正を行った。

5.4 地域に合った補正

乖離度は、推定した世帯数に対して2010年




図8 世帯数乖離率が高い地域




図9 地域に合った補正後の世帯数乖離度

度国勢調査の世帯数がどの程度かけ離れているかの度合を示す。例えば、推定世帯数よりも国勢調査の世帯数が多い場合は乖離度がプラス方向に大きくなり、少ない場合はマイナス方向に大きくなる。5.1から5.3節で示した補正を行った結果、ジャカルタ市の264個中254個の村については、国勢調査の世帯数と比較して良好な結果が得られた。一方で、図8に示す通り、残りの10個の村においては国勢調査との乖離率が高い結果となった。そこで、高密度地域・低密度地域はある程度連続して存在するという想定のもと、建物数推定結果において隣接する8メッシュと著しく数値が異なるメッシュは異常値として扱うこととし、Google Mapや時点の近い衛星画像で異常の有無を目視で確認し、値の補正を行った。

結果を図9に示す。乖離度の特に高かった10

個の村の内、7個の村においては、乖離度を小さくすることができた。残りの3個の村は全て推定世帯数に対して国勢調査の世帯数が極端に多かった地域である。他の地域と同様に目視で異常値の調査したところ、この地域については高層マンションなど世帯が密集する要因となる特徴を発見できず、補正を行うことができなかった。

6. 世帯数推定結果の評価

作成した各補正後の100mメッシュごとの世帯数の推定結果を図10に示す。本手法によるジャカルタ市全域の推定世帯数の合計は2,164,945世帯であり、2010年の国勢調査の合計世帯数の2,404,745世帯に対する乖離度は10%であった。ただし、国勢調査は2010年の更新が最後であるのに対して、本手法による推




図10 100mメッシュの世帯数推定結果

定結果は2017年を対象としている。そのため、実際の乖離度は多少変動する可能性がある。

乖離度が10%となった理由の一つとして、インドネシアの多様な建物の特性にあると考える。インドネシアは超高密集地に住む人から1000㎡以上のスペースに居住する人まで居住地の特性に大きな開きがある。居住する建物の屋根も、トタン屋根・コンクリート・煉瓦など多様な形で存在する。また、建物そのものも、1棟、1棟単独のものから、家と家の間の壁を共有し、数十件が繋がって形でたれてられているものもある。例えば、4章で述べた建物数教師データ補正や5章で述べた各補正の一部は、村単位で補正値を決めており、村の中で建物特性の揺らぎがあった場合補正が有効に作用せず、ノイズが増え、最終的な乖離率に影響した可能性がある。

7. まとめおよび今後の展望

本提案手法は、深層学習による建物推定結果から世帯数に変換する際に様々な補正を介しており、その多くは手動によるものである。手動補正を最小限に抑えるには、建物数の推定精度を向上させる必要がある。推定の精度に影響を与える要因の一つとして、光学衛星画像の分解能や画質が挙げられる。図3に示す通り、今回使用した分解能1.5mのSPOT画像では建物の密集地域において建物の境界が曖昧になってしまう場合があった。建物数を正確に推定するには、建物一棟一棟の境界線が認識できるような高分解能衛星画像を使用する必要があるだろう。薄雲等がかかっている箇所や日照条件などの影響により色が変わっている場所などでは建物数推定の誤差が大きい。今後は光学衛星画像だけでなく、画質が均一で天候に

影響を受けないSAR衛星画像の解析結果を使った補正方法も検討する必要があるだろう。また、東南アジアを中心に他の国のデータを用いて世帯数・人口推定の検証と評価を行い、汎化性能の向上も目指していく。

■参考文献

- 1) 帝国データバンク、ASEAN進出企業実態調査、2016/5/17
- 2) Bast, H., Storandt, S., & Weidner, S. (2015, November). Fine-grained population estimation. In Proceedings of the 23rd SIGSPATIAL International Conference on Advances in Geographic Information Systems (p. 17). ACM.
- 3) Doupe, P., Bruzelius, E., Faghmous, J., & Ruchman, S. G. (2016, November). Equitable development through deep learning: The case of sub-national population density estimation. In Proceedings of the 7th Annual Symposium on Computing for Development (p. 6). ACM.
- 4) Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In Advances in neural information processing systems (pp. 1097-1105).

■執筆者

伊東 里保 (いとう りほ)
株式会社パスコ

(共著者) 所属は筆頭執筆者に同じ

原 香代 (はら かよ)

飯野 翔太 (いいの しょうた)

島崎 康信 (しまざき やすのぶ)

彦坂 修平 (ひこさか しゅうへい)

森 紀之 (もり のりゆき)

可児 好宏 (かに よしひろ)

藤田 航 (ふじた わたる)