

TSUBAME 共同利用 平成 30 年度 学術利用 成果報告書

利用課題名 高解像度画像を使った広域の家屋及び道路の深層学習による自動判別システムの開発(2)
英文: System development of automatic building and road network detection using high resolution
imagery by deep-learning 2

柴崎亮介
Ryosuke Shibasaki

東京大学 空間情報科学研究センター
Center for Spatial Information Science, University of Tokyo
<http://csis.u-tokyo.ac.jp>

本プロジェクトでは衛星画像データ内に見られる建物・家屋を深層学習によって自動認識する処理を、地図データとして利用するためのマッピング処理を自動化することで、広域に展開するためのシステム開発を実施した。TSUBAME の GPU クラスタと連携したシステムを開発し、ラオス・サワナケート県、ルワンダ全土、ケニアの 17 県を対象として、約 2,000,000 の画像タイル(256 px × 256 px)におよぶ領域について建物・家屋をマッピングした。品質や精度にばらつきはあるものの、広域にわたって一定のモデルで自動処理することができた。今後は、品質管理・改良を効率的に進める手順・方法を研究開発し、当システムへの実装を進める。

This project aims to apply automated building mapping from satellite images by deep learning to large-scale geographical extent, such as national and provincial scale. We developed the system with TSUBAME's GPU cluster and applied the building-mapping algorithms to the extent of Savannakhet Province in Laos, the whole land of Rwanda, and 17 provinces in Kenya with more than 2,000,000 image times of 256 × 256 pixels. The process was succeeded with models applied to the broad areas while the quality and accuracy varied by region. We will develop the system further on methods and processes of quality control and improvement and implement it on the system.

Keywords: deep learning, satellite images, building mapping, large-scale processing

背景と目的

持続可能な開発課題(Sustainable Development Goals; SDGs)に Goal 11 “Make cities and human settlements”として掲げられているように、都市の成長を適切に管理するためのデータ基盤の整備には早急な対応が求められている。地球観測データは、このようなニーズに対応するデータ資源として、特に広域性と高頻度の特長が、都市成長の観測において高い有用性が期待されている。近年、Google Earth をはじめとした高分解能衛星画像データの普及により、個別の建物を衛星画像から検出し、衛星画像データの位置情報とあわせることで正確にマッピングする可能性が議論され、機械学習や深層学習の適用によって、自動的に衛星画像内の建物を検出する研究がなされてきた。建物や道路のマッピングの自動化は、広域にわたる地図作成を低コストで実現し、インフラ開発や公衆衛生の課題において、都市部だけでなく郊外の社会経済の状況を

概観するのに有用である。

広域にわたる自動マッピングへのニーズは高まる一方、これまでの研究の成果は、単一シーンの衛星画像データといった限られた領域でのみ処理されており、全国土といった広域を対象とした処理は未だ試みられていない。

本プロジェクトでは、昨年度の成果等をもとに、深層学習による自動マッピングアルゴリズムを、広域に適用するためのシステムを開発し、ラオス・サワナケート県、ルワンダ、ケニアを対象に広域処理を試行し、全国・全県スケールでの家屋マップを作成した。

概要

社会基盤情報として人口分布、交通ネットワークの整備は必須であるが、途上国、僻地の情報基盤の整備は乏しい状況にある。オープンな利用が広まりつつある高解像度衛星画像から機械学習、ディープラーニングなどの手法で家屋や道路ネットワークを自動検出

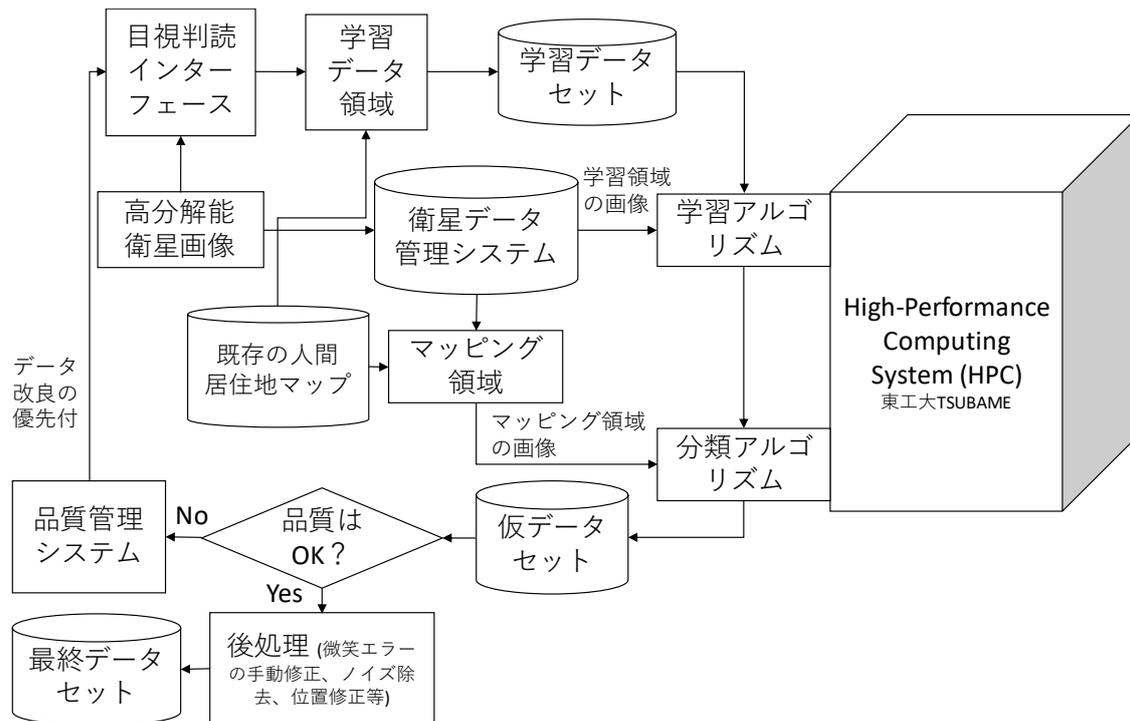


図 1 システム開発の全体像

し、地図データと利用することによる広域・社会基盤情報の整備に寄与する。

本プロジェクトでは、東工大 TSUBAME をデータ処理の基幹とし、データ収集・管理の機能を連携させることで、任意の領域について、家屋マッピングを自動化することができた。図 1 にシステム開発の全体像を示す。

結果および考察

昨年度に開発した画像収集・管理システムを用いて Google Maps の衛星画像を収集した。画像データは、1.2 m 分解能で取得し、256 ピクセル × 256 ピクセルを単位としたタイルとして画像ファイルに保存した。全ての画像ファイルのファイル名には、全世界のタイル位置に対して一意的であるタイル番号が付与され、データ処理で画像ファイルの参照が容易になるようにした。収集した画像ファイルの数は表 1 の通りである。

家屋検出の自動化は、学習データ内にみられる家屋の画像パターンに基づいて、入力データ内の家屋を認識することによってなされる。したがって、家屋の画像パターンが地理的背景によって、異なる場合には誤って検出されることになる。

本事業では、県レベル境界別と、グローバルデータセットから得られる居住地密度別に家屋検出モデルを構築することで影響を低減した。具体的に以下のデー

タを用いた。

全世界の行政区域 GIS データを収集した成果である GADM のうち国レベルの次に下位の行政区域(県・州・省など; 以下、県レベルとする)の境界データ

European Commission Joint Research Centre が Landsat 衛星データから作成したグローバル居住地データセット(Global Human Settlement Layer)のうち、250 m グリッドに密度を集約したデータを用いて居住地密度を以下の 5 段階に分類した。

- 1) 居住地密度 = 0
- 2) $0 < \text{居住地密度} \leq 0.1$
- 3) $0.1 < \text{居住地密度} \leq 0.2$
- 4) $0.2 < \text{居住地密度} \leq 0.4$
- 5) $0.4 < \text{居住地密度}$

表 1 地域別画像ファイル数

地域	画像ファイル数
ラオス・サワナケート県	250,844
ルワンダ	272,594
ケニア(17 県)	1,546,594

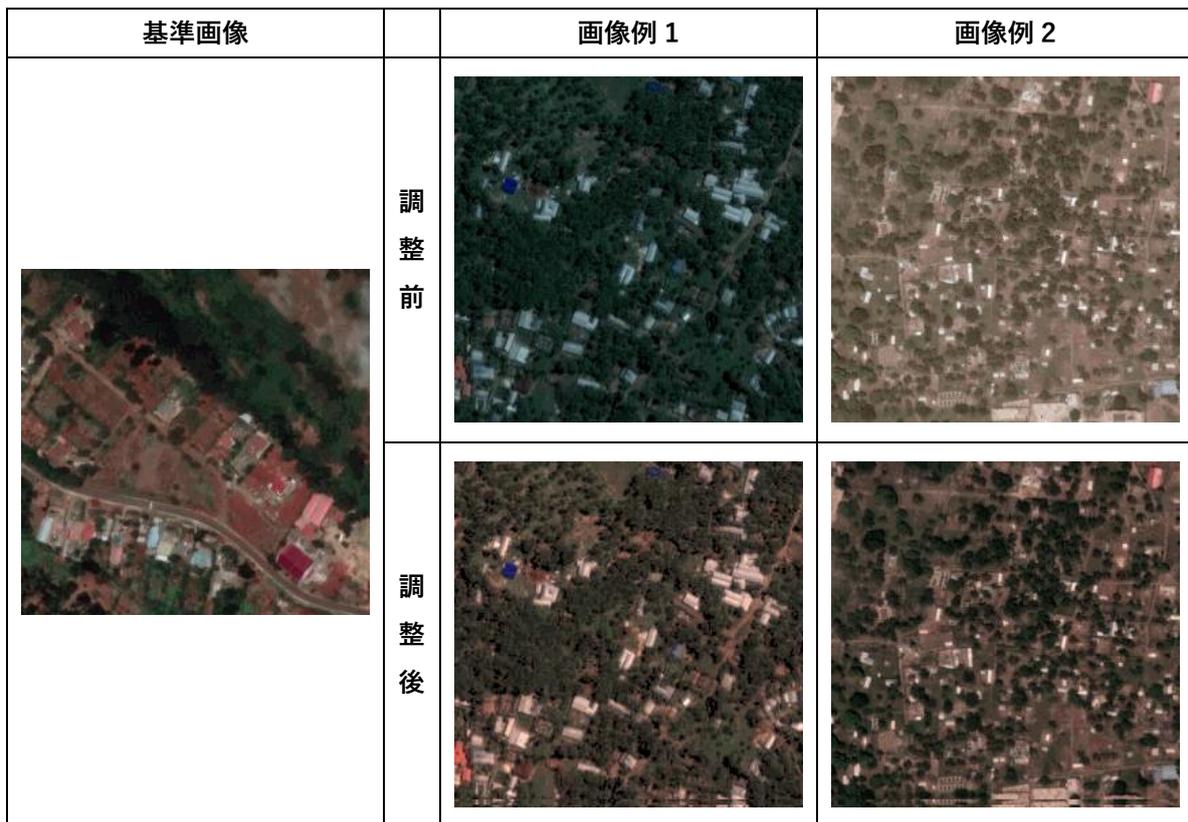


図 2 コントラスト調整の処理例

したがって、表 2 に示される区分の学習データを使ってディープラーニングで家屋検出モデルが構築され、それぞれ同様の地理的区分に該当する衛星画像データにモデル適用し、家屋マッピングを処理する。

原則として、全ての区分に十分な数の学習データが分布するように、学習データはサンプリングされたが、一部の区分では学習データがゼロとなる場合があった。その場合には、同居住地密度段階のうち、その県から

最近隣の学習データ 64 タイルを、その区分の学習データとした。

Google Maps の画像ファイルはタイル間でコントラストが異なることが多く、家屋検出の精度に著しい影響を及ぼす。本事業では、高速フーリエ変換を経ることで、高い精度でコントラストを同調にするアルゴリズムを適用することで、モデルごとのコントラストが同様になるよう調整した。この際、コントラストの基準

となる画像には、画素値の標準偏差値が第 2 四分位点 (50%) になる画像を選定するようアルゴリズムを構築した。図 2 に処理結果の例を示す。

上述のアルゴリズム等を TSUBAME の GPGPU を使ったディープラーニングを実装し、ラオスのサワナケート県、ルワンダ全域、ケニア全域を対象に処理を実施した。実装にあたって使用したアルゴリズム、ソフトウェア等の詳細は以下の通りである。

Keras – 代表的なディープラーニングのライブラリである TensorFlow をベースに、汎用的なアルゴリズムを関数として整備したフレームワーク。本事業では、Keras を使って UNet アーキテクチャによるセマンティックセグメンテーションを実装した。

GNU Parallel – 多数のデータ処理の並列化を簡

表 2 検出モデルの地域区分

県レベル行政区域	居住地密度
県 A	居住地密度 = 0
県 A	$0 < \text{居住地密度} \leq 0.1$
県 A	$0.1 < \text{居住地密度} \leq 0.2$
県 A	$0.2 < \text{居住地密度} \leq 0.4$
県 A	$0.4 < \text{居住地密度}$
県 B	居住地密度 = 0
県 B	$0 < \text{居住地密度} \leq 0.1$
...	...
県 C	居住地密度 = 0
...	...

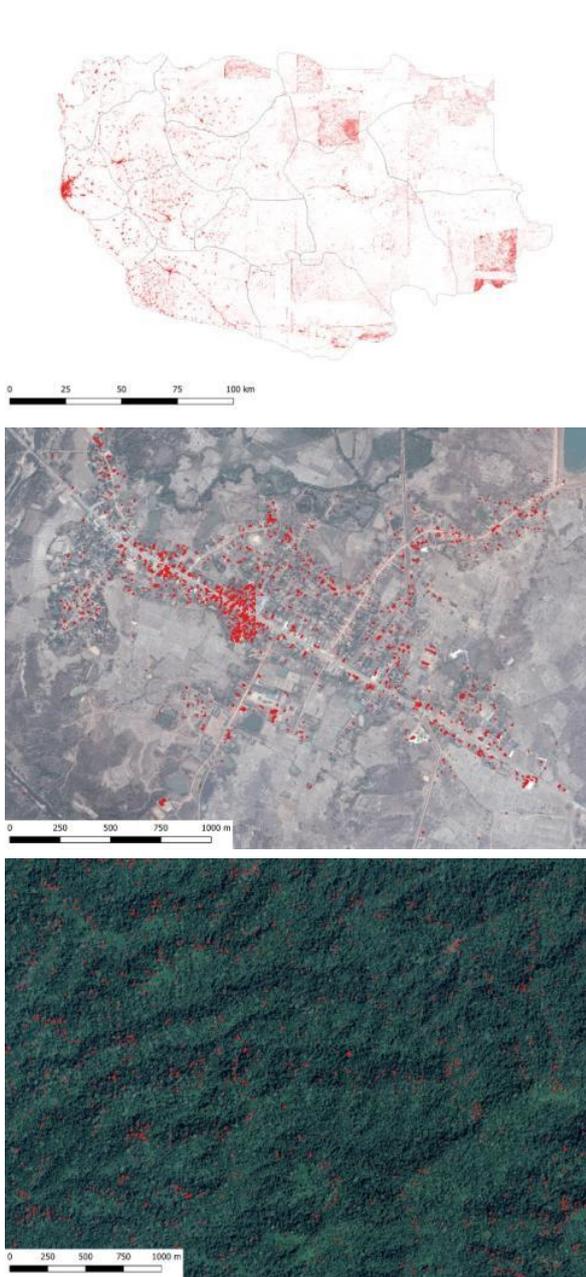


図 3 サワナケート県のマッピング結果。上: 全域、中: 良好な結果の例、下: 不良な結果の例。中段と下段の背景は Google Map より引用した。全域についてはポリゴンを強調したため、誤検出も強調されている。

易に行うためのソフトウェア。本事業では、TSUBAME 上で多数の GPGPU クラスタで同時に処理を実行するために使用した。

Adam オプティマイザの学習率を 0.00003 に設定し、学習データのうち最小の検出精度が Accuracy > 85% かつ IoU > 80%、または学習エポック数が 100 を超えるまで学習を反復させた。学習にかかる時間は、1 エポックあたり 250 秒~280 秒程度であった。なお、面積

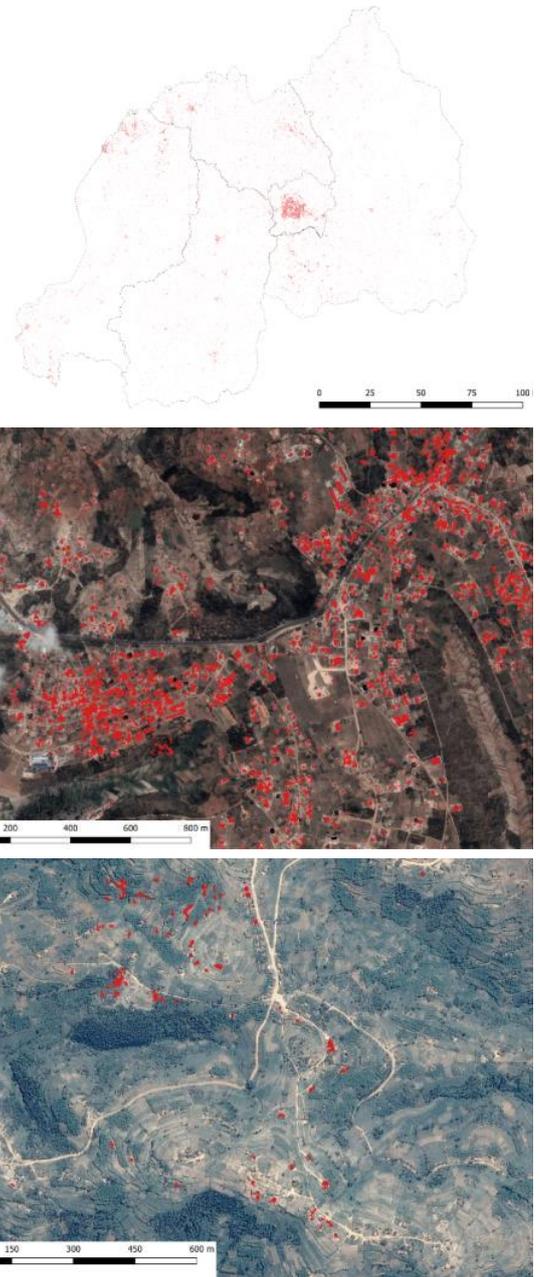


図 4 ルワンダ全域のマッピング結果。上: 全域、中: 良好な結果の例、下: 不良な結果の例。中段と下段の背景は Google Map より引用した。

が 45 m²未満および 5000 m²以上のポリゴンは家屋の大きさに見合わないため、検出結果から除いた。

ラオス・サワナケート県についてマッピングした結果を図 3 に示す。概ね集落の位置を捉えられているが、森林のテクスチャを建物として誤認識している区域がある(図 3 上および図 3 下)。郊外の集落を拡大すると幾分かの取りこぼしはあるが、概ね全ての建物を検出したことが確認できた。

ルワンダ全域についてマッピングした結果を図 4 に示す。集落の位置を概ね捉えているが、裸地等が家屋

データと組み合わせることで、このような誤検出を除外することができる。

まとめ、今後の課題

本プロジェクトでは深層学習を用いた家屋・建物の自動検出アルゴリズムを広域に適用するためのシステム開発を実施し、ラオス・サワナケート県、ルワンダ全土、ケニアの 17 県について Google Maps の衛星画像に適用した。その結果、精度や品質にある程度のばらつきはあるものの、一定のアルゴリズムによる処理を広域に適用した結果が得られた。今後は、品質管理・改良を効率的に進める手順・方法を研究開発し、当該システムへの実装をおこなう。



図 5 ケニア(17 県)のマッピング結果。上: 全域、中: 良好な結果の例、下: 不良な結果の例。中段と下段の背景は Google Map より引用した。

として誤認識されたケースが見られた。都市部に一部取りこぼしが見られたが、大半の家屋を検出したことを確認した。

ケニア国土のうち 17 県についてマッピングした結果を図 5 に示す。都市部や集落の位置や規模を概ね捉えているが、県によっては森林等を家屋として誤検出する例が見られた。また、ケニアには 68,800 km² を占めるビクトリア湖があるが、湖面のまばらな画素値が家屋として誤って検出される例が見られた。水域については正確な地図が整備されているので、そのような地図