

SAR 衛星画像を用いた深層学習による地理情報識別に
基づく都市変化モニタリング

2021年 3月

飯野 翔太

SAR 衛星画像を用いた深層学習による地理情報識別に
基づく都市変化モニタリング

飯野 翔太

システム情報工学研究群

筑波大学

2021年 3月

概要

本論文では、広範囲を雲の影響なく撮影できる合成開口レーダ (SAR) 衛星画像を用いて深層学習により地理情報識別を行うことで、都市的土地利用への土地利用転換を把握するための情報を得る手法について提案し、その有効性について検証を行った。

都市計画区域内においては、定期的に都市計画基礎調査を通じた自然的土地利用や都市的土地利用の把握が行われている。その一方で、都市計画区域外では、市町村により土地利用の管理方法が異なり、なかには無秩序な宅地化やスプロール現象が進んでいる地域もある。農業的土地利用から都市的土地利用に転換されれば、再び戻すことは不可能であるため土地利用の転換は慎重にする必要があり、どこをどのように転換するかを計画することは土地利用計画上極めて重要である。また日本の JICA 等の機関は海外の都市開発支援のための調査において、土地利用の抽出、市街地の拡がりの抽出、人口分布の把握などを行っているが、分析に使えるデータは限られている。これらのユースケースにおいて必要な精度・頻度・観測範囲を明らかにし、提案した手法を用いることでそれらの要求を満たすことができるか検証を行った。

提案手法は、最初に 1 偏波または 2 偏波の SAR 衛星画像から深層学習により 5 クラスの地理情報識別を行う。地理情報識別の精度を上げるため、深層学習の画像分類に重要であるコンテキスト領域を考慮したパッチサイズの検討、高さ情報である DSM の追加、2 偏波 SAR 衛星画像の偏波画像からの細部特徴強調の活用、深層学習のモデルの再学習を行う方法を示した。次に、GIS ツールや作成したプログラム等を用いて、都市的土地利用として識別されたピクセルを抽出する。抽出された都市的土地利用のピクセルの情報を時系列で分析し、都市的土地利用への土地利用転換の把握を行う。

提案手法の有効性を検証するため、アジア 4 か国の 1 偏波・2 偏波の SAR 衛星画像を用いた都市的土地利用への土地利用転換の分析を行い、要求を満たすことを示した。また光学衛星画像、オープンストリートマップ (OSM) の建物データ、統計データを学習データとして深層学習による世帯数の推計を行い、世帯数の補正に SAR 衛星画像からの非居住地エリアの識別結果等を用いることで世帯数を十分な精度で推計できることをインドネシアジャカルタのデータを用いた検証により示した。

本研究は、時系列の 1 偏波、2 偏波の SAR 衛星画像を用いて、深層学習を用いた都市的土地利用への土地利用転換の把握を行うという新しい使い方を示したとともに、SAR 衛星画像と DSM を組み合わせて、深層学習により地理情報を識別する方法を新たに示した。

目次

第1章	序論	1
1.1.	背景	1
1.1.1.	農村における土地利用転換.....	1
1.1.2.	海外都市の開発支援.....	1
1.2.	都市的土地利用への土地利用転換の把握を行うための関連手法.....	2
1.3.	問題設定	2
1.4.	リサーチクエスチョン.....	3
1.5.	課題	3
1.6.	目的	3
1.7.	本論文の構成.....	3
第2章	要求分析	5
2.1.	都市変化モニタリング手法のユースケース.....	5
2.2.	都市計画区域外の土地利用の把握.....	6
2.3.	世界の人口増加.....	6
2.4.	SDGs の住み続けられるまちづくり	7
2.5.	都市開発支援における衛星画像の利用.....	7
2.6.	ヤンゴン都市圏開発プログラム形成準備調査における衛星画像の利用	7
2.7.	ヤンゴン都市圏開発プログラム形成準備調査における人口分布の把握	8
2.8.	衛星画像から確認できるインドネシアの都市変化.....	10
2.9.	海外都市の人口推計.....	12
2.10.	都市変化モニタリングへの要求定義.....	14
2.11.	2章のまとめ.....	15
第3章	関連技術研究.....	16
3.1.	リモートセンシング技術の比較.....	16
3.2.	光学衛星画像と SAR 衛星画像の比較.....	20
3.3.	SAR 衛星画像を用いた観測の利点.....	21
3.4.	深層学習を用いた画像分類の関連研究.....	22
3.5.	光学衛星画像からの地理情報の識別に関する関連研究.....	22
3.6.	SAR 衛星画像からの地理情報の識別に関する関連研究	23
3.7.	3章のまとめ.....	23

第 4 章	提案手法	24
4.1.	概要	24
4.2.	提案手法のフロー	26
4.3.	データの作成	27
4.4.	深層学習による地理情報識別	28
4.5.	深層学習モデルの再学習	29
4.6.	パッチサイズの検討による識別精度の向上	30
4.6.1.	パッチ画像の作成	30
4.6.2.	パッチ画像サイズの検討	30
4.7.	DSM の追加による識別精度の向上	32
4.8.	複数の偏波情報を組み合わせた精度の向上	33
4.8.1.	SAR 衛星画像の偏波	33
4.8.2.	偏波画像の組み合わせを利用した地理情報の識別	35
4.9.	時系列の SAR 衛星画像を用いた都市的土地利用への土地利用転換の把握	35
4.10.	光学衛星画像と SAR 衛星画像を用いた世帯数の推計	37
4.11.	提案手法の利点	38
4.12.	検証方法	39
4.13.	4 章のまとめ	40
第 5 章	1 偏波 SAR 衛星画像からの都市的土地利用への土地利用転換の把握	41
5.1.	概要	41
5.2.	利用するデータ	42
5.3.	学習とテスト用のパッチ画像の作成	42
5.4.	検証方法	43
5.5.	パッチ画像の分類結果に対する定量的評価	43
5.6.	ヤンゴンのピクセルベースの都市的土地利用への土地利用転換の把握	45
5.7.	ヤンゴンのメッシュベースの都市的土地利用への土地利用転換の把握	46
5.8.	マニラの都市的土地利用への土地利用転換の把握	49
5.9.	光学衛星画像からの水域抽出結果を用いた精度向上	50
5.9.1.	手法	50
5.9.2.	利用するデータ	50
5.9.3.	正解データとの比較による定量性評価	52
5.10.	水域の誤分類の改善	54
5.11.	5 章まとめ	55
第 6 章	2 偏波 SAR 衛星画像からの都市的土地利用への土地利用転換の把握	56
6.1.	概要	56

6.2.	利用するデータ	56
6.3.	学習とテスト用のパッチ画像の作成.....	56
6.4.	深層学習の超パラメータ設定.....	56
6.5.	偏波の組み合わせ別の地理情報の識別精度の評価.....	57
6.6.	地理情報の識別精度の定量的評価.....	58
6.7.	時系列画像を用いたジャカルタの地理情報の識別.....	60
6.8.	DSM の利用についての考察	61
6.9.	深層学習と最尤推定の推測結果の比較.....	61
6.10.	メッシュベースでの都市的土地利用への土地利用転換の把握.....	63
6.11.	深層学習モデルの再学習.....	67
6.12.	異なる周波数の衛星画像を用いた地理情報の識別.....	68
6.13.	6 章まとめ	69
第 7 章	光学衛星画像と SAR 衛星画像を用いた世帯数の推計	70
7.1.	概要	70
7.2.	インドネシアの統計データ	70
7.3.	使用したデータ	71
7.4.	関連研究	71
7.5.	世帯数・人口推計の全体フロー.....	71
7.6.	建物数推定の教師データ作成.....	72
7.7.	深層学習のモデル.....	73
7.8.	建物数推定結果の補正.....	74
7.8.1.	非居住地マップの作成.....	74
7.9.	考察	77
7.10.	今後の展望	78
7.11.	7 章まとめ	78
第 8 章	結論	79
8.1.	まとめ	79
8.2.	本研究の学術的意義.....	80
8.3.	本研究の貢献.....	80
参考文献	84	
研究実績	90	

目次

図 2.1	都市変化モニタリングのユースケース図.....	5
図 2.2	世界の人口増加.....	6
図 2.3	JICA 調査団によって作成された新規市街地及び開発予定地.....	9
図 2.4	Landsat 衛星画像で確認できるブカシの約 1 か月半毎の変化	10
図 2.5	Landsat 衛星画像で確認できるブカシの約 1 年毎の変化	11
図 2.6	JICA 調査団が行ったヤンゴンの将来人口推計の方法	12
図 3.1	5ha と 50ha を撮影する際の UAV・航空機・衛星画像のコスト比較	17
図 3.2	段階に応じたりモートセンシング技術の使い分けの例.....	17
図 3.3	2010 年から 2014 年までの ILSVRC における画像分類の分類エラー率.....	22
図 4.1	提案手法の概要.....	24
図 4.2	都市計画調整調査実施要領.....	25
図 4.3	深層学習の学習と推論のフロー	26
図 4.4	正解データの作成方法.....	27
図 4.5	本研究で利用した深層学習のモデル.....	28
図 4.6	再学習モデルを用いた推論のフロー.....	29
図 4.7	パッチ画像の作成イメージ.....	30
図 4.8	パッチサイズ別のパッチ画像の例.....	31
図 4.9	パッチサイズ別の各クラスの見え方の違い.....	31
図 4.10	SAR 画像と DSM 画像を組み合わせた地理情報の識別.....	32
図 4.11	偏波の違いによる明るさのイメージ.....	33
図 4.12	偏波の異なる SAR 衛星画像の見え方の違い	34
図 4.13	時系列の SAR 衛星画像を用いた都市的土地利用への土地利用転換の把握 ..	36
図 4.14	ピクセルベースの変化抽出からのメッシュベースでの変化抽出	37
図 5.1	1 偏波 SAR 衛星画像を用いた都市変化の把握のフロー	41
図 5.2	混同行列.....	43
図 5.3	ヤンゴンの増加した人工物.....	45
図 5.4	2010 年から 2016 年のヤンゴンのメッシュベースでの都市変化.....	46
図 5.5	2016 年から 2017 年のヤンゴンのメッシュベースでの都市変化.....	47
図 5.6	JICA 調査団が作成した 2025 年のヤンゴン土地利用予測図.....	47
図 5.7	ヤンゴンにおける 2010 年から 2016 年の人工物変化と分析結果の比較	48
図 5.8	ヤンゴンにおける 2016 年から 2017 年の人工物変化と分析結果の比較	48
図 5.9	マニラにおける 2014 年から 2016 年の人工物変化と分析結果の比較	49

図 5.10	水域の誤分類の例.....	49
図 5.11	水域と他クラスのピクセル値の違い.....	51
図 5.12	各指標のピクセル値.....	52
図 5.13	検証用の正解データ.....	53
図 5.14	水域の識別結果と作成した正データの比較評価.....	53
図 5.15	光学衛星画像と SAR 衛星画像からの水域識別結果の比較.....	54
図 6.1	偏波の組み合わせ別の分類精度.....	57
図 6.2	各偏波による見え方の違い.....	58
図 6.3	人工物のパッチサイズ別の精度の比較.....	58
図 6.4	ジャカルタの地理情報の推測結果.....	60
図 6.5	ハノイの地理情報の推測結果.....	60
図 6.6	ジャカルタ全体の深層学習と最尤推定による推測結果の比較.....	62
図 6.7	深層学習と最尤推定による推測結果の比較.....	62
図 6.8	メッシュベースの都市の分析結果.....	63
図 6.9	大きな都市的土地利用への土地利用転換が起きていると推測されるエリア ..	64
図 6.10	実際に変化が確認できた場所 (1/3).....	64
図 6.11	実際に変化が確認できた場所 (2/3).....	65
図 6.12	実際に変化が確認できた場所 (3/3).....	66
図 6.13	再学習に必要なデータ数.....	67
図 6.14	バンド別の電波の反射イメージ.....	68
図 6.15	3 種類の SAR 衛星画像からの地理情報の識別結果の比較.....	69
図 7.1	ジャカルタ市における 2010 年度国勢調査結果（世帯数）	70
図 7.2	世帯数・人口推計の全体フロー.....	72
図 7.3	SPOT 衛星画像および OSM の建物ポリゴンの例	73
図 7.4	世帯数推計のための深層学習のモデル.....	74
図 7.5	非居住地マップ作成のフロー.....	75
図 7.6	SAR 衛星画像からの人工物の抽出結果.....	75
図 7.7	世帯数の推定結果.....	76
図 7.8	推計世帯数と 2010 年の統計データとの乖離.....	77

表目次

表 2.1	ヤンゴンのタウンシップグループ毎の人口等のデータ	8
表 2.2	JICA 調査団の推計した人口	13
表 2.3	都市変化モニタリングに対する要求一覧	14
表 3.1	精度に関する比較	18
表 3.2	頻度に関する比較	18
表 3.3	観測範囲に関する比較	19
表 3.4	雲量のレンジ別の画像数と 1 枚当たりの平均雲量	20
表 3.5	光学衛星画像の受動型センサと SAR 衛星画像の能動的センサの違い	21
表 4.1	検証マトリックス	39
表 5.1	利用した衛星画像のデータ	42
表 5.2	作成したパッチ画像の学習データ数	43
表 5.3	パッチ画像の分類結果	44
表 5.4	各指標の名称と説明	50
表 5.5	正解データと比較した水域の抽出精度	53
表 6.1	利用した超パラメータ	57
表 6.2	各クラスのパッチサイズ別の精度	59
表 8.1	各要求に対する検証結果	80

第1章 序論

1.1. 背景

1.1.1. 農村における土地利用転換

都市計画法第五条により、一体の都市として総合的に整備し、開発し、及び保全する必要がある区域が都市計画区域として定義されており [1]、これらの区域では都市計画により土地利用の状況が管理されている。

都市計画区域内では、都市計画基礎調査が行われており、都市計画法に基づき、都市における人口、産業、土地利用、交通などの現況及び将来の見通しを定期的に把握し、客観的・定量的なデータに基づいた都市計画の運用を行うための基礎となる調査が行われている。都市計画基礎調査の一つである土地利用現況図は各都道府県の土地利用計画に向けた土地利用の把握に有効である。土地利用計画現況図の用途区分は自然的土地利用と都市的土地利用に分類される。自然的土地利用はさらに田・畑・山林・水面・その他自然地（原野・牧野、荒れ地など）に分けられる [2]。

一方で日本の面積の 73.6% (平成 17 年末) [3]を占める都市計画区域外においては、地域によって土地利用方針が定められていなく、無秩序な宅地化や異なる土地利用種が混在してさまざまな支障を生み出す現象であるスプロール現象が進んでいるところもある [4]。

改訂農村計画学によると、農業的土地利用から都市的土地利用に転換されれば、再び戻すことは不可能であるため、土地利用の転換は慎重にする必要があり、どこをどのように転換するかを計画することが、土地利用計画上極めて重要であるとされている。

また、異なる土地利用種が混在してさまざまな支障を生み出す現象である土地利用のスプロールを防止することも土地利用計画上重要な課題である [5]。

平成 29 年の農林地及び埋立地から都市的土地利用（住宅地、工業用地、公共用地等）への転換面積は全国で約 15,400ha である [6]。

1.1.2. 海外都市の開発支援

日本の JICA 等の機関は、海外の都市開発分野の協力の重点内容として、経済活動に寄与する基幹インフラ整備を目的としたマスタープランの作成やインフラ整備などを行っている [7]。

しかし開発途上国などでは日本の都市計画基礎調査のような調査が定期的に行われていなく、都市計画を行うための基礎データが入手できない国々も多い。また入手可能な人口や世帯数などのセンサスデータについても、更新頻度・粒度の点で課題がある。

JICA 等の機関が海外の開発支援のために行っている調査の事例については、2.5 章で分析を行う。

1.2. 都市的土地利用への土地利用転換の把握を行うための関連手法

土地利用転換の把握や人口・世帯数の把握のためには、国勢調査や都市計画図、地理院地図等のデータを使うことが考えられるが、定期的に更新されないこと、地理情報の分解能が低いことが課題である。また海外の国々ではそれら公的な地理情報が整備されていないところも多々ある。

それらの課題を解決し、定期的に把握するための方法としては、公開されているオープン土地被覆マップや航空画像・光学衛星画像の利用が考えられる。最も分解能が高いオープン土地被覆マップの一つにドイツのドイツ航空宇宙センター(DLR)が公開した Global Urban Footprint [8]があるが、分解能は 12m と詳細な人工物の変化を捉えるのは難しく、さらに時系列のデータを見ることができない。

また航空画像や光学衛星画像の利用も行われているが、光学航空画像や光学衛星画像では、雲がかかっている地域については分析できず、定期的に観測ができないことも多い。そこで雲の影響を受けない合成開口レーダ (SAR) 衛星画像の利用が考えられる。

リモートセンシング技術の比較については 3 章で詳細を述べる。

1.3. 問題設定

本研究では以下 2 つの問題を設定する。

1. 土地利用転換の把握に必要な精度・頻度・観測範囲で都市的土地利用への土地利用転換の把握ができていない
2. 利用可能な衛星画像からでも都市的土地利用への土地利用転換に必要な精度・頻度・観測範囲で把握することは難しい

都市的土地利用への土地利用転換を把握する為に必要な精度・頻度・観測範囲については、2 章で分析を行い、要求を定義する。

1.4. リサーチクエスション

本研究のリサーチクエスションは、「衛星画像により得られる画像情報と都市的土地利用への土地利用転換を把握するための情報の関係とは何か」である。

1.5. 課題

1.3 章で設定した問題においては、以下の3つの課題が挙げられる。

1. 都市的土地利用への土地利用転換の把握に必要な精度・頻度・観測範囲のデータが限られる
2. 得られた画像情報から地理情報を識別できない
3. 地理情報から都市的土地利用への土地利用転換を把握することができない

1.6. 目的

本研究では、広範囲を雲の影響なく撮影できる SAR 衛星画像を用いて深層学習により地理情報識別を行うことで、都市的土地利用への土地利用転換を把握するための情報を得ることを目的とする。

1.7. 本論文の構成

本論文の構成は以下の通りである。

第2章では、本研究が目的とする都市的土地利用への土地利用転換の把握に必要な精度・頻度・観測範囲を定義するために、どのようなユースケースが考えられ、それぞれのユースケースでどのような要求が求められるかについて分析を行った。

第3章では、本研究に関連する様々なリモートセンシング技術や、画像情報から地理情報を識別するための関連研究との比較分析を行った結果を示す。

第4章では、SAR 衛星画像から深層学習による地理情報識別を行い、必要な精度・頻度・観測範囲での都市的土地利用への土地利用転換を把握するための提案手法について述べる。

第5章では、提案手法を用いて、1 偏波の SAR 衛星画像から 5 分類の地理情報識別を行い、そこから都市的土地利用の場所の抽出を行う。その抽出結果を用いて都市的土地利用への土地利用転換の状況を把握できるかを、アジアの衛星画像を用いた実験によって検証を行い、評価結果を示す。

第6章では、提案手法を用いて、2 偏波の SAR 衛星画像からより高い精度での地理情報識別を行い、都市的土地利用への土地利用転換の把握に利用できるかをアジアの衛星画像を用いた実験によって検証した結果を示す。

第7章では、光学衛星画像・オープンストリートマップ(OSM)の建物ポリゴンを基に作成した建物数を学習データとした深層学習による推計を行い、世帯数を算出する手法を提案する。世帯数の補正に SAR 衛星画像からの非居住地エリアの識別結果等を用いることで世帯数を十分な精度で推計できるかを検証する。

最後の第8章では、SAR 衛星画像を用いた深層学習による地理情報識別に基づく都市変化モニタリングについてのまとめ、学術的意義、本研究の貢献について述べる。

第2章 要求分析

2.1. 都市変化モニタリング手法のユースケース

本論文で提案する都市変化モニタリング手法の利用法を図 2.1 のユースケース図に示す。代表的なユーザーとしては、自治体または JICA 等の調査団が考えられ、ユースケースとして以下の 4 点を挙げることができる。それぞれのユースケースで、現状どのように土地利用の把握が行われているか分析を行う。

○一部の自治体

1. 都市計画区域外の土地利用の把握

○海外都市の開発支援のための JICA 等の調査団

2. 土地利用の抽出
3. 市街地の拡がりの抽出
4. 人口分布の把握

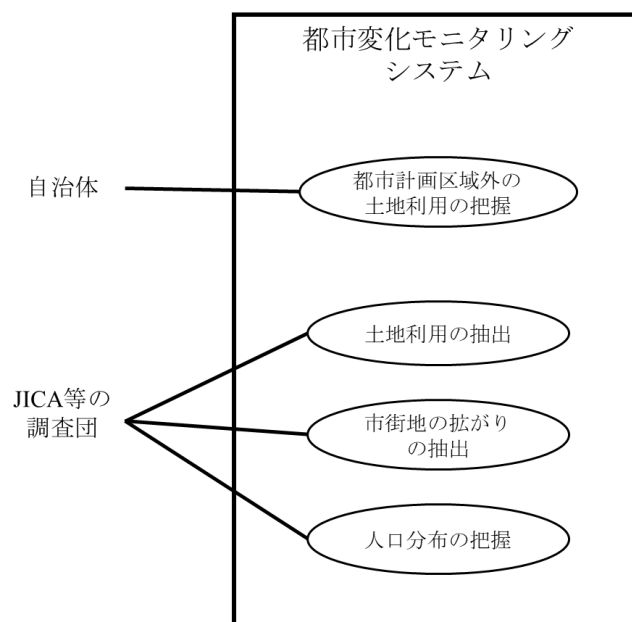


図 2.1 都市変化モニタリングのユースケース図

2.2. 都市計画区域外の土地利用の把握


和多くの研究によると、土地計画外地域における開発コントロールの方法としては主に 3 つに分けられる [9].

1. 都市計画法や建築基準法の枠内で、用途地域内や線引き区域における基準を適用
2. 都市計画法以外の法令によってもしくは農業サイド等と調整により管理
3. 自治体が条例や要綱を制定

これらの開発コントロールのためには、土地利用の状況を定期的に把握していく必要がある。土地利用の把握の方法としては、国土数値情報を利用した非農業土地利用の把握等がある [10]. この分析では 3 次メッシュ (1km²) が用いられており、土地利用転換の把握に必要な分解能としてもこの程度が求められる。

2.3. 世界の人口増加

図 2.2 のように世界人口は 1950 年以降増加しており、アジアでは 2040 年頃まで増加傾向にあり [11], 人口増加に伴い都市は拡大している。本研究では、ASEAN 諸国の中でも人口が多いインドネシア(27,063 万人)、フィリピン(10,812 万人)、ミャンマー(5,405 万人)、ベトナム(9,646 万人)の代表的都市であるジャカルタ、マニラ、ヤンゴン、ハノイを事例として扱う。



[11]

図 2.2 世界の人口増加

2.4. SDGs の住み続けられるまちづくり

2015 年 9 月、持続可能な開発のための 2030 アジェンダが策定、世界共通の目標とした SDGs が合意された。SDGs の Goal 11 には「住み続けられるまちづくり」として、包摂的で安全かつ強靱（レジリエント）で持続可能な都市及び人間居住を実現することが挙げられている [12].

2.5. 都市開発支援における衛星画像の利用

JICA の都市開発支援としては、経済活動に寄与する計画的な都市開発が重要であるとし、都市開発に合わせたインフラ整備等を行っている [13]. その調査の中では、森林の状況把握、流域の地形や土地利用状況の継続的な把握のために衛星画像が利用されている [14].

例えばマレーシアやベトナムの Defense Mapping Agency などにおいては小縮尺（1/10,000 や 1/25,000）の土地利用の地図の定期的な更新が必要とされており、そのためには、以下の 4 つの要件が挙げられている [15].

- ① 高精度な位置情報を有する.
- ② 土地利用を抽出できる.
- ③ 同時期の雲の無い画像データをアーカイブできる.
- ④ 必要な周期で繰り返し同じ場所を観測できる.

2.6. ヤンゴン都市圏開発プログラム形成準備調査における衛星画像の利用

ヤンゴンの経済活動促進、物流の活性化、及び生活環境の改善への寄与を意図し、ヤンゴン都市圏の開発を効率的に進めるためのヤンゴン都市圏開発プログラムを形成し、その中心的計画となる都市開発計画を策定するため、「ヤンゴン都市圏開発プログラム形成準備調査」が 2012 年 8 月～2013 年 3 月にかけて実施された。

大統領は、土地の管理・活用に関連して住宅開発やプロジェクト投資に関連する動きの中で、土地利用、土地投機は難しい局面に直面するであろうと述べ、都市開発、およびその他の開発プロジェクトに関する土地利用と活用に関する提案を求めた。

そこで、JICA の調査プロジェクトでは、既存土地利用に関する現状と課題について、衛星画像等を分析することで整理を行った。その中で、Yangon City Development Committee (YCDC) の市街地開発を空間的な視点から検討を行い、南部ではなく、北部へ向かって開発が進んでいることがわかった。特に中心市街地から 15～20km 圏に新しい都市的土地利用の地域が多くみられた。市街地及び開発予定地の 2002～2012 年の変化を空間的に示してお

り、左図の濃い橙色が新規市街地、右図の濃い紫色が新規開発予定地を現している。新市街地は既存市街地の周辺に、北へ向かって拡大する傾向がこの比較分析からも明らかになった [16]。

2.7. ヤンゴン都市圏開発プログラム形成準備調査における人口分布の把握

JICA の調査では、市街化のための開発余地と、都市人口の増加についての分析も行った。各地区での 1998 年と 2011 年の人口を YCDC の資料を基に JICA 調査団がまとめたタウンシップグループ毎の面積、人口、年増加率、人口密度を表 2.1 に示す。

表 2.1 ヤンゴンのタウンシップグループ毎の人口等のデータ

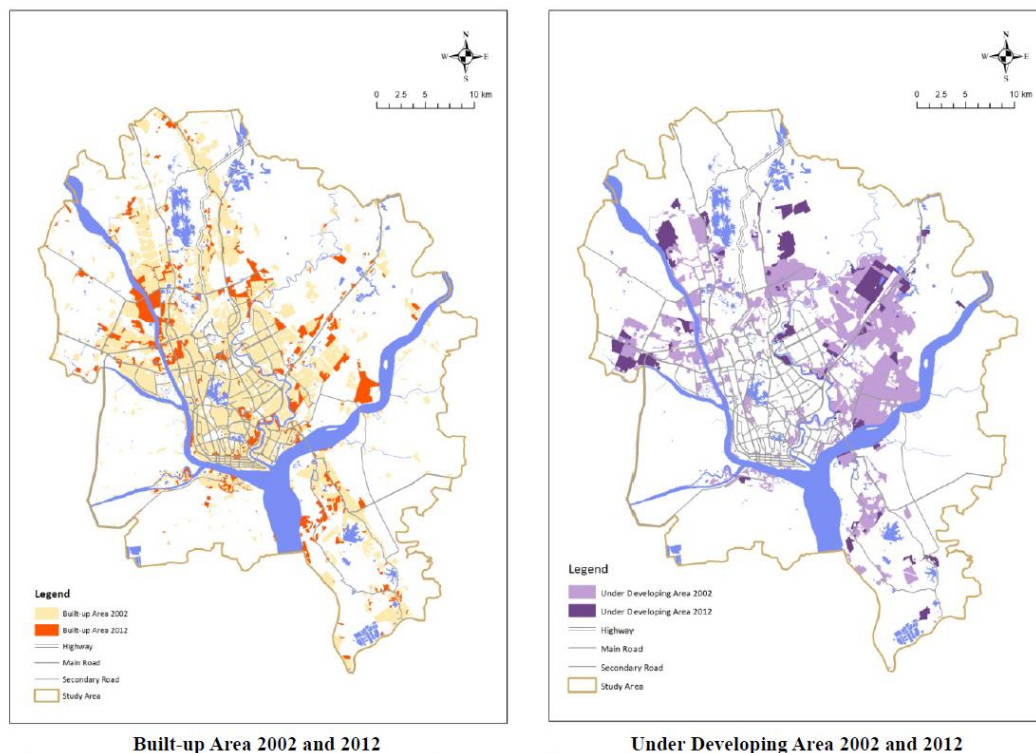
タウンシップグループ	面積(ha)	人口 (1,000)		年増加率 (%)	人口密度 (人/ha)
		1998	2011		
CBD	691	256	252	-0.10	365.5
Inner Urban Ring	3,794	664	848	1.90	223.6
South of CBD	11,050	103	220	6.01	19.9
Older Suburbs Zone	4,954	689	778	0.94	157.1
Outer Ring Zone	3,421	598	596	-0.03	174.4
Northern Suburbs	18,530	595	805	2.36	43.5
New Suburbs Zone	40,468	687	1,642	6.93	40.6
Periphery Area	70,582	(no data)	1,072	(no data)	15.2
合計	153,488	3,692*	6,214 5,142*	2.58*	40.5

* Periphery Area のデータを考慮していない値

出典: YCDC の資料を基に取り纏めた JICA 調査団のデータ

[16]

図 2.3 の 2002 年及び 2012 年時の衛星画像解析を基に作成された新規市街地及び開発予定地と合わせて人口分布の把握を行うためには、同じ年のデータを基に分析することが重要であるが、国によっては現地でデータを入手することができない。



[16]

図 2.3 JICA 調査団によって作成された新規市街地及び開発予定地

2.8. 衛星画像から確認できるインドネシアの都市変化

ジャカルタの 2010 年の都市化率は 53.7%であるが、今後も増えていくことが予測されており、ジャカルタ都市圏は南東アジアでは最大の都市密集地である。急速な地方分権化に加えて、ローカル政府の土地管理能力の不足が、まとまりのない地域作りにつながっている。さらに利子利益に対するプライベートセクターと個人の圧力により地方政府の空間計画の実施についての矛盾が生じている。そのため、土地利用の観点から GIS の開発が求められる [17]。これらの現地の事情から、都市的土地利用への土地利用転換の状況を定期的に客観的にモニタリングすることが有用であると考えられる。

インドネシアの都市変化をとらえるために必要な観測頻度を明らかにするため、都市変化が多い地域を例に、Landsat 5/8 の衛星画像を用いて、目視で時系列変化の確認を行った。Landsat は 1972 年から U.S. Geological Survey (USGS) と the National Aeronautics and Space Administration (NASA) によって運用されている光学衛星である [18]。

ジャカルタ近郊のブカシでの都市変化を約 1 か月半おきの変化を目視で抽出した例を図 2.4 に示す。1 か月半毎に時系列の衛星画像を見比べると、建物を建てるための工事の進捗状況を把握することができる。青い四角で囲った箇所では、新しい道ができたり、建物が数個増えたりする状況を把握することができた。




図 2.4 Landsat 衛星画像で確認できるブカシの約 1 か月半毎の変化

一方で 1 年毎の Landsat 5/8 の衛星画像を用いて、都市変化を捉えた例を図 2.5 に示す。

青い四角で囲った箇所の都市的土地利用への土地利用転換の状況を見ると、区画レベルでの建物の増加を捉えることができる。

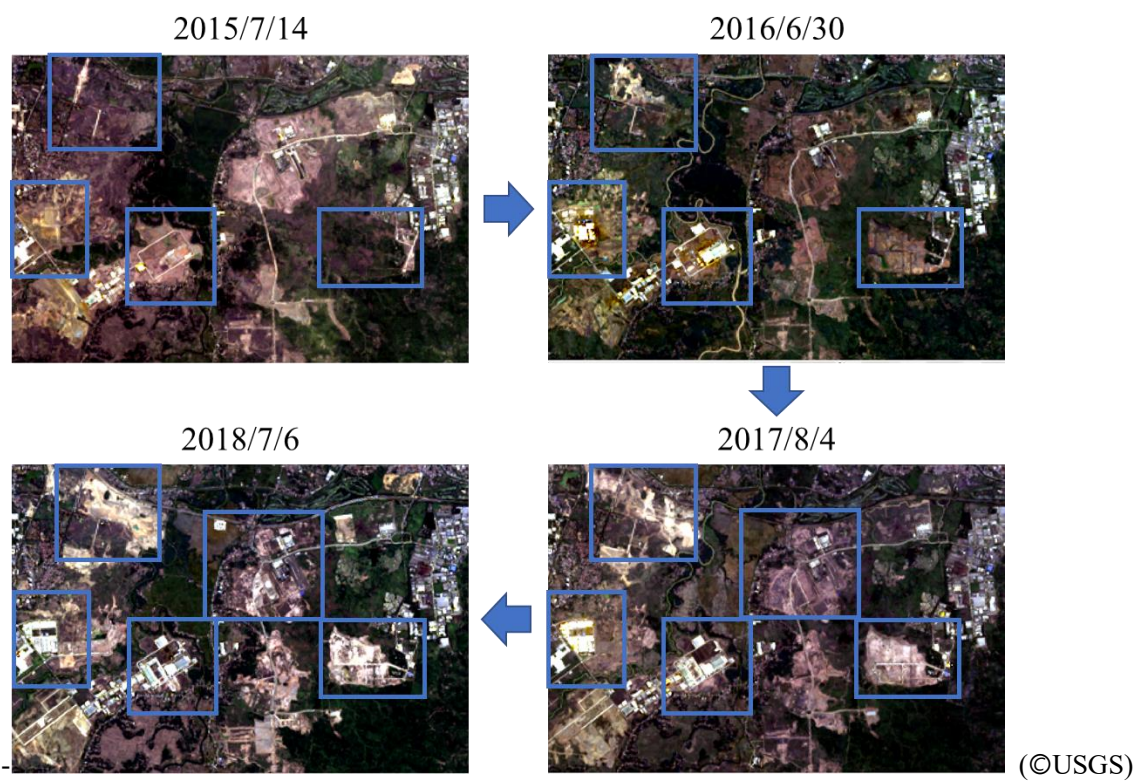
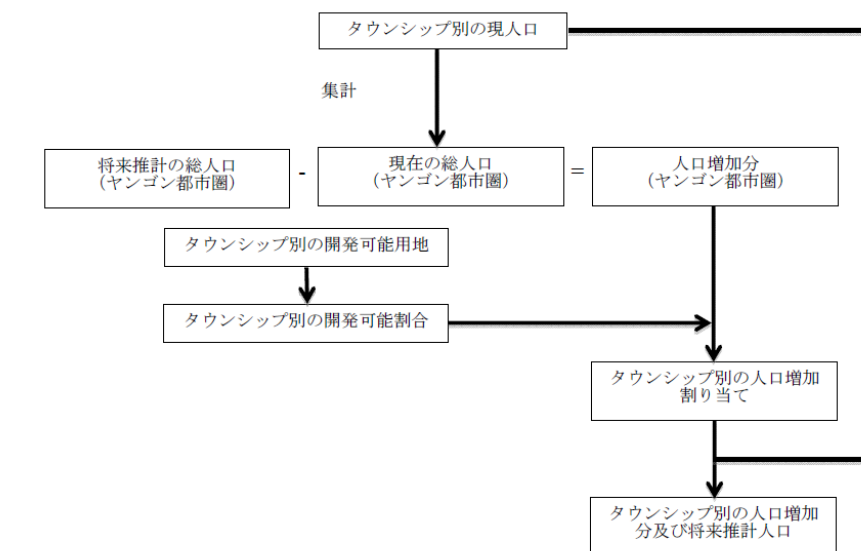


図 2.5 Landsat 衛星画像で確認できるブカシの約 1 年毎の変化

2.9. 海外都市の人口推計

JICA 調査団が行ったヤンゴンのタウンシップ別の将来人口推計の方法を図 2.6 に示す [16]. それぞれのタウンシップが有する開発可能用地の面積割合を基に, 人口成長の増加率で割り当てることで推計した各タウンシップの人口を表 2.2 に示す. しかしこの方法は, タウンシップ別の開発可能割合を基に推計しており, 各タウンシップ別で同じ速度で一定の開発が進んでいることを前提とした推計である.

より高い精度で将来人口の推計を行うためには, 各地域でどのような都市的土地利用への土地利用転換が行われているかを把握することが必要である.



出典: JICA 調査団

[16]

図 2.6 JICA 調査団が行ったヤンゴンの将来人口推計の方法

表 2.2 JICA 調査団の推計した人口

Code	Township Name	Township Group	District	No. of Wards	Area (m2)	Current	Projected							
						2011	2018	2020	2025	2030	2035	2040		
1	Latha	CBD	Yangon (West)	10	604,770	34,125	34,125	34,125	34,125	34,125	34,125	34,125	34,125	
2	Lanmadaw	CBD	Yangon (West)	12	1,310,572	43,137	43,137	43,137	43,137	43,137	43,137	43,137	43,137	
3	Pabedan	CBD	Yangon (West)	11	618,984	37,551	37,551	37,551	37,551	37,551	37,551	37,551	37,551	
4	Kyauktada	CBD	Yangon (West)	9	701,876	34,797	34,797	34,797	34,797	34,797	34,797	34,797	34,797	
5	Botahtaung	CBD	Yangon (East)	10	2,601,921	49,134	49,134	49,134	49,134	49,134	49,134	49,134	49,134	
6	Pazundaung	CBD	Yangon (East)	9	1,067,498	53,648	54,182	54,353	54,822	55,354	55,959	56,647		
			Sub total	61	6,905,623	252,392	252,926	253,097	253,566	254,098	254,703	255,391		
7	Ahlone	Inner Urban Ring	Yangon (West)	11	3,380,984	65,510	66,044	66,215	66,684	67,216	67,821	68,509		
8	Kyee Myin Daing	Inner Urban Ring	Yangon (West)	22	4,570,110	115,841	121,718	123,600	128,751	134,607	141,265	148,835		
9	Sanchaung	Inner Urban Ring	Yangon (West)	18	2,404,656	105,208	105,742	105,913	106,382	106,914	107,519	108,207		
10	Dagon	Inner Urban Ring	Yangon (West)	5	4,894,633	24,492	28,766	30,135	33,881	38,140	42,982	48,488		
11	Bahan	Inner Urban Ring	Yangon (West)	22	8,474,439	100,695	102,298	102,811	104,216	105,813	107,629	109,693		
12	Tarmwe	Inner Urban Ring	Yangon (East)	20	4,985,869	191,114	192,182	192,525	193,461	194,526	195,737	197,113		
13	Mingalar Taung Nyunt	Inner Urban Ring	Yangon (East)	20	4,943,032	155,767	157,370	157,883	159,288	160,885	162,701	164,765		
14	Seikkan	Inner Urban Ring	Yangon (West)	3	1,174,225	2,241	2,241	2,241	2,241	2,241	2,241	2,241		
15	Dawbon	Inner Urban Ring	Yangon (East)	14	3,111,295	87,284	87,811	88,338	88,990	89,595	90,283	91,000		
			Sub total	135	37,939,242	848,152	864,111	868,097	873,322	878,332	883,149	887,836		
16	Kamaryut	Outer Ring	Yangon (West)	10	6,472,493	87,881	90,511	91,038	91,565	92,092	92,619	93,146		
17	Hlaing	Outer Ring	Yangon (West)	16	9,820,283	151,014	153,111	155,208	157,305	159,402	161,499	163,596		
18	Yankin	Outer Ring	Yangon (East)	16	4,791,565	125,909	125,909	125,909	125,909	125,909	125,909	125,909		
19	Thingangyun	Outer Ring	Yangon (East)	39	13,120,302	231,621	233,718	235,815	237,912	240,009	242,106	244,203		
			Sub total	81	34,204,643	596,425	603,345	608,070	612,795	617,520	622,245	626,970		
20	Mayangone	Northern Suburbs	Yangon (West)	10	25,834,479	205,403	216,611	227,819	239,027	250,235	261,443	272,651		
21	Insein	Northern Suburbs	Yangon (North)	21	31,397,616	311,200	322,918	334,636	346,354	358,072	369,790	381,508		
22	Mingalardon	Northern Suburbs	Yangon (North)	32	127,943,855	288,858	398,911	409,964	420,017	430,070	440,123	450,176		
			Sub total	63	185,175,949	805,461	938,444	972,413	1,006,382	1,040,351	1,074,320	1,108,289		
23	North Okkalapa	Older Suburbs	Yangon (East)	19	27,755,247	333,484	349,511	365,538	381,565	397,592	413,619	429,646		
24	South Okkalapa	Older Suburbs	Yangon (East)	13	8,217,705	191,388	192,456	193,524	194,592	195,660	196,728	197,796		
25	Thaketa	Older Suburbs	Yangon (East)	19	13,448,713	253,284	258,092	259,632	263,846	268,638	274,086	280,279		
			Sub total	51	49,421,665	778,156	800,059	807,075	826,274	848,102	872,919	901,134		
26	Dala	South of CBD	Yangon (South)	46	98,400,859	181,087	236,112	253,737	301,968	356,804	419,150	490,032		
27	Seikgyihanaungto	South of CBD	Yangon (South)	9	12,101,872	38,425	44,836	46,889	52,508	58,097	66,160	74,419		
			Sub total	55	110,502,731	219,512	280,948	300,626	354,477	415,701	485,310	564,451		
28	Shwe Pyi Thar	New Suburbs	Yangon (North)	27	52,706,107	295,993	334,992	347,483	381,666	420,531	464,717	514,954		
29	Hlaing Tharyar	New Suburbs	Yangon (North)	29	77,614,147	488,768	533,109	547,311	586,177	630,366	680,605	737,724		
30	North Dagon	New Suburbs	Yangon (East)	27	24,177,408	221,200	232,953	236,718	247,019	258,732	272,048	287,188		
31	South Dagon	New Suburbs	Yangon (East)	39	37,506,127	370,403	402,457	412,724	440,819	472,763	509,080	550,371		
32	East Dagon	New Suburbs	Yangon (East)	60	170,871,278	145,505	330,348	389,553	551,573	735,779	945,210	1,183,320		
33	Dagon Seikkan	New Suburbs	Yangon (East)	48	42,035,707	120,161	169,844	185,758	229,306	278,818	335,111	399,111		
			Sub total	230	404,910,773	1,642,030	2,003,702	2,119,546	2,436,562	2,796,988	3,206,771	3,672,669		
Yangon City Total						676	829,060,625	5,142,128	5,743,669	5,936,343	6,463,609	7,063,078	7,744,637	8,519,527
34	Kyauktan	Periphery Area	Yangon (South)	13	76,120,987	48,473	67,171	73,160	89,549	108,183	129,368	153,454		
35	Thanlyin	Periphery Area	Yangon (South)	36	254,846,226	181,959	371,076	431,650	597,416	785,881	1,000,154	1,243,770		
36	Hlegu	Periphery Area	Yangon (North)	14	101,003,839	50,793	136,804	164,353	239,744	325,458	422,910	533,707		
37	Hmawbi	Periphery Area	Yangon (North)	18	84,228,570	83,719	167,059	193,752	266,802	349,854	444,280	551,636		
38	Htantabin	Periphery Area	Yangon (North)	18	81,770,250	40,234	103,807	124,170	179,893	243,247	315,277	397,170		
39	Twantay	Periphery Area	Yangon (South)	10	107,864,054	24,936	79,427	96,881	144,644	198,947	260,687	330,882		
	Periphery Township Total			109	705,833,925	430,114	925,343	1,083,966	1,518,047	2,011,571	2,572,677	3,210,619		
Greater Yangon Total						785	1,534,894,550	5,572,242	6,669,012	7,020,309	7,981,656	9,074,649	10,317,314	11,730,146

[16]

2.10. 都市変化モニタリングへの要求定義

本研究で提案する都市変化モニタリングが利用できると考えられる各ユースケースにおける要求分析の結果を表 2.3 に示す。

表 2.3 都市変化モニタリングに対する要求一覧

No	ステークホルダー	ユースケース	精度に関する要求	頻度に関する要求	観測範囲に関する要求
1	自治体 (国内)	都市計画区域外の土地利用の把握	3 次メッシュ区画 (1km ²)	定期的に変化を把握できる	自治体全域
2	JICA 調査団等 の開発 支援組織	土地利用の地図の定期的な更新	土地利用を抽出できる精度	必要な周期で繰り返し同じ場所を観測できる	都市全域
3		市街地変化の把握	数百メートルレベル	1 年～10 年毎の変化を確認できる	都市全域
4		人口/世帯数の推計	タウンシップグループ毎 (地区毎)	他のデータと同時期のデータを推計できる	都市全域

これらの要求分析結果から、要求事項として以下を挙げることができる。

【精度に関する要求】

- ・ 数百メートル～地区レベルでの土地利用の変化が抽出できること

【頻度に関する要求】

- ・ 定期的に、1 年～数年毎に分析に必要な画像を得られること

【観測範囲に関する要求】

- ・ 都市全域を観測できること

2.11.2 章のまとめ

本章では、本研究が目的とする都市変化モニタリングにおいて、どのような要求が求められるかを明らかにするため、自治体と JICA 調査団等の開発支援組織が行っている衛星画像等を用いた調査についての分析を行い、それぞれのユースケースでどのような精度・頻度・観測範囲が求められているかを定義した。

国内の自治体では、都市計画区域外の土地利用の状況を把握するために、定期的に観測することが求められる。また JICA 調査団等の海外の都市開発支援組織では、土地利用の地図の定期的な更新のベースライン、市街地変化の把握、人口/世帯数の推計等を数百メートルレベルから地区毎の粒度で、都市全域を定期的に把握することが求められる。

本章で定義した要求を、提案する手法が満たすことができるか検証を行っていく。

第3章 関連技術研究

3.1. リモートセンシング技術の比較

都市的土地利用への土地利用転換の把握を行うために利用できるリモートセンシング技術は様々なものがあり、無人航空機 (UAV)、ヘリコプタ、航空画像、人工衛星などにより取得した画像等が用いられている。それぞれの技術は特徴が異なるため、用途にあった利用法が求められる。技術を選定するための要素としては、代表的なものとしては分解能・観測領域などが挙げられる。各リモートセンシングの技術に対して、精度・頻度・観測範囲に関連する様々な項目での特性を比較した結果を 表 3.1、表 3.2、表 3.3 に示す。

近年は高分解能の画像を撮影できる UAV 等の利用が進み、災害時の被害状況の確認や物理的に人がアクセスできない箇所等の把握等に利用されており、都市の把握にも活用が考えられている。しかし場所の制限、大量のデータを処理する必要がある制約、飛行するための安全性やセキュリティに関連する規制等により、活用が進んでいないのが現状である [19]。

精度に関する要求に対しては、分解能は UAV、ヘリコプタ、航空画像が高いのに対して、衛星画像は比較的精度は低い。本研究で対象とする都市変化把握の要求としては数百メートル～地区レベルでの土地利用の変化が抽出できることであり、どれも十分な分解能を持つ。画質に対しては、自動で都市変化を把握することが必要であるため、精度よく分析するためには均一の画質の画像であることが求められる。これを満たすのは航空 SAR 画像と SAR 衛星画像である。

頻度に関する要求に対しては、UAV・ヘリコプタ・航空画像の画像は、要求があった場所を要求に応じて観測する一方で、衛星画像は定期的な観測を 1 日～1 か月の周期で常時行っており、過去に遡った画像データも入手することができる。そのため、過去も含む時系列での都市変化を把握することができる利点がある。

観測範囲に関する要求に対しては、本研究の対象としている自治体・都市全域を観測するためには相当数の画像枚数が必要である。例えば、ジャカルタ(662 km²) [20]を UAV 観測するのに必要な画像の枚数は、観測幅 500m の UAV では 2648 枚必要である一方で、観測幅 50km の衛星画像は 1 枚でカバーすることができる。

利用するリモートセンシング技術の選定にあたっては、精度・頻度・観測範囲の他にコストについても考慮する必要がある。Alessandro らの研究において、図 3.1 のように 5ha と 50ha を撮影する場合のコストが比較されており、50ha 以上では衛星画像が優位である [21]。

また UAV・航空機・衛星画像を組み合わせる事例としては、図 3.2 のように林野庁が整理した段階に応じたリモートセンシング技術の使い分けがあり、第 1 段階の概要把

握, 第4段階の全容把握に人工衛星・航空機が使われており, 第2段階の現地調査, 第3段階の応急対策, 5段階の災害復旧に UAV を利用している [22].

2章で整理した要求事項に対応する利用法としては, 過去画像も含めて天候の影響を受けず時系列での都市変化の分析が行える SAR 衛星画像をベースラインとして使うことが考えられる. その上で SAR 衛星画像から抽出した都市の変化が起きている場所を, 得たい情報の分解能に合わせた UAV, 航空機などを用いて観測し, 詳細の変化を分析する利用法が考えられる.




図 3.1 5ha と 50ha を撮影する際の UAV・航空機・衛星画像のコスト比較

対応の段階	必要な情報と主な目的等	標準的なリモートセンシング技術	求められる成果
準備・警戒			
概要把握	大規模な山腹崩壊・河道閉塞の有無、山腹崩壊の集中地区	人工衛星・航空機	山腹崩壊等の発生位置と規模
現地調査	応急対策計画策定のための情報収集	UAV	被害箇所の状況写真
応急対策	対応状況の報告等	UAV	応急対策状況の写真
全容把握	災害分布把握・被害規模把握	人工衛星・航空機	山腹崩壊発生分布図
災害復旧	災害復旧計画の策定、復旧施設の机上配置計画のための情報収集	UAV	被害箇所の写真、被害箇所の地形図、縦横段図

[22]

図 3.2 段階に応じたリモートセンシング技術の使い分けの例

表 3.1 精度に関する比較

	UAV	ヘリコプタ	航空機	人工衛星
分解能	0.5-10cm	5-50cm	0.1-2m	0.3-30m
画質	ばらつき	ばらつき	SAR 画像は 安定	SAR 画像は 安定
天気・大気の影響	有	有	SAR 画像は 少ない	SAR 画像は 少ない
精度要求 (数百メートル ～地区レベル)	◎	◎	◎	○

[23] [24] [25]を基に作成

表 3.2 頻度に関する比較

	UAV	ヘリコプタ	航空機	人工衛星
観測頻度	要求に 応じて	要求に 応じて	要求に 応じて	1 日～1 か月
軌道	全て異なる	全て異なる	全て異なる	固定軌道 (周期的)
データの 即時性	リアルタイム	リアルタイム	リアルタイム	ダウンリンク 以降に 処理
入手可能な データ	観測後	観測後	観測後	運用開始 以降
頻度要求 (定期的, ～1 年毎)	△	△	△	◎

[23] [24] [25]を基に作成

表 3.3 観測範囲に関する比較

	UAV	ヘリコプタ	航空機	人工衛星
1 枚の 観測領域	50-500m	0.2-2km	0.5-5km	10-500km
撮影場所	要求した 場所	要求した 場所	要求した 場所	定期的に観測 ＋ 要求した場所
1 枚あたりの コスト	低い	中程度	高い	非常に高い
搭乗員	不要	必要	必要	不要
観測範囲要求 (都市全域)	△	△	△	◎

[23] [24] [25]を基に作成

3.2. 光学衛星画像と SAR 衛星画像の比較

衛星画像としては光学衛星画像もあるが、雲がかかっていると分析できず、定期的に観測ができないという課題がある。Landsat 5 が 17 年間に撮った 16,540 枚の日本各地の画像の雲量を調べたところ日本全国平均の快晴率は 6.17%，すなわち 16 回に 1 回程度の確率で雲の少ないデータ（雲量 20%以下）が撮れる。Landsat の回帰日数は 16 日であり、平均すると $16 \times 16 = 256$ 日に 1 度しか快晴データを取得できない [26]。特に東南アジアインドネシアのような年中雲が多い国においては、航空画像や光学衛星画像を用いて定期的に地理情報の変化を捉えることは極めて困難である。2016 年にインドネシアのジャカルタを撮影した Landsat 画像の雲量を分析すると、表 3.4 に示す通り 15%以下の雲量の画像は 23 枚中 4 枚であった。15%程度であっても、雲によりみることができない場所が多く存在する衛星画像が多くある。

表 3.4 雲量のレンジ別の画像数と 1 枚当たりの平均雲量

	0-15%	15-30%	30-100%
画像数	4 枚	4 枚	15 枚
1 枚あたりの 平均雲量	11.3%	21.9%	64.3%

また光学衛星画像は、画質（例：光の当たり具合）が画像により異なり、機械学習の汎用的モデル作成が困難であるという課題もある。光学衛星画像等の受動型センサと SAR 衛星画像等の能動的センサの違いについて表 3.5 に示す。

表 3.5 光学衛星画像の受動型センサと SAR 衛星画像の能動的センサの違い

	光学衛星画像	SAR 衛星画像
センサの特徴	反射された太陽光を 観測する受動型センサ	マイクロ波を地表面に照射し、 地表面からの後方錯乱波を 受信する能動型センサ
判別性	直観的な判別が可能	反射強度を表すモノクロ画像で、 直観的な判別が困難
画像間の画質の 違い	大きい	小さい
雲の影響、 時間帯	雲があると観測できなく、 夜間の観測も不可	全天候で観測でき、 夜間の観測も可

[27]を参考に作成

3.3. SAR 衛星画像を用いた観測の利点

SAR 衛星画像は、雲の影響をほとんど受けず定期的に観測可能であり、画像間で画質の違いが小さく汎用的なモデルを作成しやすい。しかし、SAR 衛星画像を利用する際には、光学画像と比較して直感的にわかりづらく、画像の解釈には専門家と時間が必要であるという課題があった。SAR 衛星画像からの地理情報識別の専門的知識をもつ方々の人数も限られているため、多くの衛星画像を分析するためには自動化することが重要となる。

3.4. 深層学習を用いた画像分類の関連研究

本研究では、近年、画像分類において分類精度がよいことが様々な研究により示されている深層学習の一つである畳み込みニューラルネットワーク (CNN) [28]を用いる。

画像分類の機械学習の手法を比較する上で参考になる国際コンペティションである ImageNet Large Scale Visual Recognition Challenge (ILSVRC)の画像分類部門においては、2012年に CNN (畳み込みニューラルネットワーク) モデルである AlexNet [29]が、図 3.3 に示す通り、前年度から 10%近く精度を向上させて以来、上位を深層学習の手法が占めている [30]。




図 3.3 2010 年から 2014 年までの ILSVRC における画像分類の分類エラー率

3.5. 光学衛星画像からの地理情報の識別に関する関連研究

光学衛星画像からの地理情報の識別に関する関連研究としては、Krylov らが、都市ゾーンの分類において、CNN による識別結果とランダムフォレストによる識別結果を比較し、CNN がランダムフォレストよりも精度が高いことを示した [31]。

Huang らは、誤差逆伝搬法 (バックプロパゲーション)を用いたニューラルネットワークを用いて、QuickBird からの都市エリアの地理情報の分類を行った [32]。

Pacifici らは、QuickBird と World View-1 の光学衛星画像から、ニューラルネットワークを用いた都市の土地利用の分類を行った [33]。

Lagkvist らは、光学衛星画像と DSM を組み合わせた画像に対して、CNN によりピクセルベースの分類を行い [34]、筆者らも CNN による Landsat 画像からの土地被覆分類の手法を提案した [35]。

3.6. SAR 衛星画像からの地理情報の識別に関する関連研究

SAR 衛星画像からの地理情報の自動識別に関する関連研究としては, Lv らは Deep belief network を用いて多偏波合成開口レーダ (PolSAR) 画像から都市エリアの土地被覆分類を行い [36], Gao [37], Zhang [38], Chen [39], Wang [40] らは PolSAR 画像の分類に対する新しい機械学習モデルの提案を行った.

これらの研究では, 入手しづらい 4 偏波の画像を用いて色付けた PolSAR 画像を利用しているが, 4 偏波の SAR 画像は撮影リソースの観点から撮影できる機会が極めて少ない. またこれらの研究では同じ画像から学習データとテストデータを作成しており, 他の地域への適応, 複数の時系列画像を用いた分析などは行われていない.

Li らは人工物のエリアを検出する手法 [41], Xu らは建物の分類手法について [42], CNN を用いた手法を提案し, 他の機械学習の手法であるサポートベクターマシン (SVM) 等に比べて良い精度で分類できることを示した. Gong らは, オートエンコーダ, CNN と教師なしのクラスタリング手法を組み合わせた変化検出フレームワークを提案した [43].

これらの研究では, CNN 等を用いた様々な地理情報の識別を行うモデルやアルゴリズム等についての提案を行っているが, 時系列画像を用いた人工物・都市の変化については分析が行われていない.

3.7. 3 章のまとめ

本章では, 本研究の目的に関連するリモートセンシング技術として, UAV・ヘリコプタ・航空機・衛星から得られる画像の特徴について比較を行った.

UAV や航空機は, 高い解像度の画像を要求に応じて撮影することができ, すぐにダウンロードできることが利点である一方で, 過去の画像を得ることができず, また日により異なる軌道や環境条件による画質の違いがあること, 広範囲を一度に撮影できないこと等の課題がある.

光学衛星画像は比較的高分解能の画像を広範囲で撮影することができるが, 雲の影響を受けやすく, 定期的に都市的土地利用への都市利用転換を把握することは難しい.

そこで, 過去画像も含めて入手することができ, 天候の影響を受けず比較的均一な画質の画像を得られる SAR 衛星画像を用いることとする. 将来的には SAR 衛星画像に加えて, UAV, 航空機画像などを組み合わせて観測を行い, 都市的土地利用への都市利用転換の把握を行う利用法が考えられる.

光学衛星画像と SAR 衛星画像からの地理情報の識別に関する関連研究については, 近年深層学習を含む機械学習を用いた地理情報の識別を行う研究が行われてきているが, モデルやアルゴリズム等についての提案が多く, 時系列画像を用いた都市的土地利用への都市利用転換についての分析は行われていない.

第4章 提案手法

4.1. 概要

本章では, SAR 衛星画像からの深層学習による地理情報識別に基づき都市的土地利用への土地利用転換の把握を行う提案手法について述べる. 図 4.1 に提案手法の概要を示す.

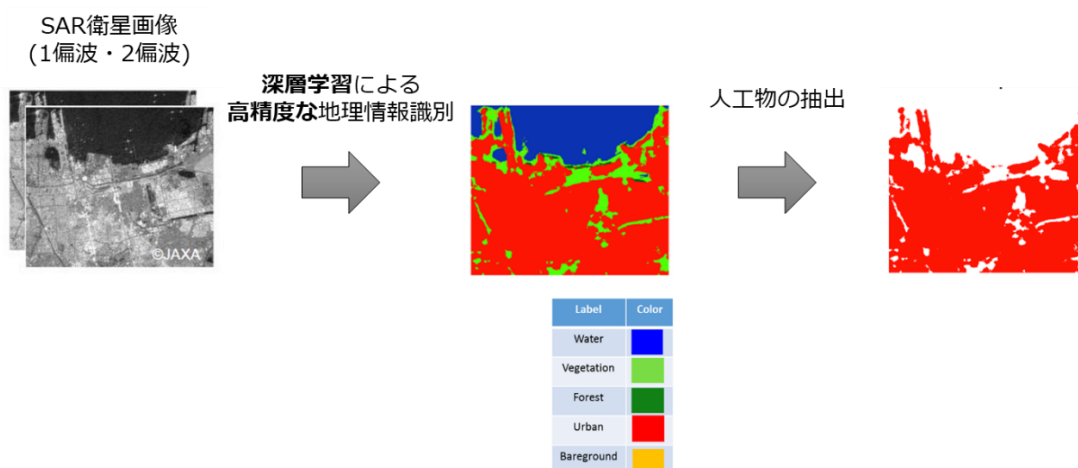


図 4.1 提案手法の概要

最初のステップでは, 1 偏波または 2 偏波の SAR 衛星画像から深層学習により高精度な地理情報識別を行う. 分類のクラス数を決める上では, 図 4.2 の国土交通省都市局が発表している都市計画調整調査実施要領 [2]を参考に 5 クラスに設定した. 自然的土地利用と都市的土地利用にまず分けることができ, 自然的土地利用はさらに 5 分類に分けられる. 季節により見え方の異なる田畑を合わせて草地とし, 残る森林・その他裸地・水域と合わせて 5 クラスの分類とした.

次のステップでは, Geographic Information System (GIS) ツールや作成したプログラム等を用いて, 都市的土地利用として識別されたピクセルを抽出する. 本研究では GIS ツールとして, Quantum GIS (QGIS) [44]を用いた. そして抽出された都市的土地利用のピクセルの情報を時系列で分析し, 都市的土地利用への土地利用転換の把握を行った.

用途区分		細分用途
土地 利用	田	水田
	畑	畑、樹園地、採草地、養鶏(牛、豚)場
	山林	樹林地
	水面	河川水面、湖沼、ため池、用水路、濠、運河水面
	その他自然地	原野・牧野、荒地 [※] 、低湿地、河川敷・河原、海浜、湖岸
都市的 土地利用	住宅用地	建物用途現況図の 5～9
	商業用地	同 1～4
	工業用地	同 13
	農林漁業施設用地	同 14
	公益施設用地	同 10、11、15
	道路用地	道路、駅前広場
	交通施設用地	同 12
	公共空地	公園・緑地、広場、運動場、墓園
	その他公的施設用地	防衛施設用地
	その他の空地①	ゴルフ場
	その他の空地②	太陽光発電のシステムを直接整備している土地
	その他の空地③	平面駐車場
	その他の空地④	その他の空地①～③以外の都市的土地利用 (建物跡地、資材置場、改変工事中の土地、法面〈道路、造成地 等の主利用に含まれない法面〉)
	不明	不明な土地

[2]

図 4.2 都市計画調整調査実施要領

都市的土地利用への土地利用転換の把握を高精度で行うため、主に以下の 5 点についての工夫を行った。

1. 超パラメータ探索により最適化したモデルの利用と再学習の活用
2. 光学/SAR 衛星画像に加えて NDVI を基に正解データを作り 5 分類
3. 都市的土地利用に適した観測地域画像のコンテキスト情報の活用
4. 高さ情報である DSM の活用
5. 細部特徴を強調する複数偏波の活用

4.2. 提案手法のフロー

提案手法のフローを図 4.3 に示す。フェーズは学習フェーズと推論フェーズに分けられる。学習フェーズでは、まず SAR 衛星画像に前処理を行い、正解データのクラスラベルを基に、データセットを作成する。SAR 衛星画像に加えて、地理情報の分類精度を上げるために高さ情報である全球数値地表モデル(DSM)や数値標高モデル(DEM)を重ね合わせてデータセットを作成することができる。作成した各クラスのラベル付きのデータセットを用いて、深層学習のモデルにより学習を行い、学習済みモデルを作成した。

推論フェーズでは、SAR 画像に学習フェーズと同じ前処理を行い、学習済みモデルを用いて推論を行い、5クラスの地理情報の識別を行った。

その後、都市的土地利用を GIS ツールで抽出し、人工物マップを作成し、時系列での都市的土地利用への土地利用転換の把握や非都市エリアの識別を行う。

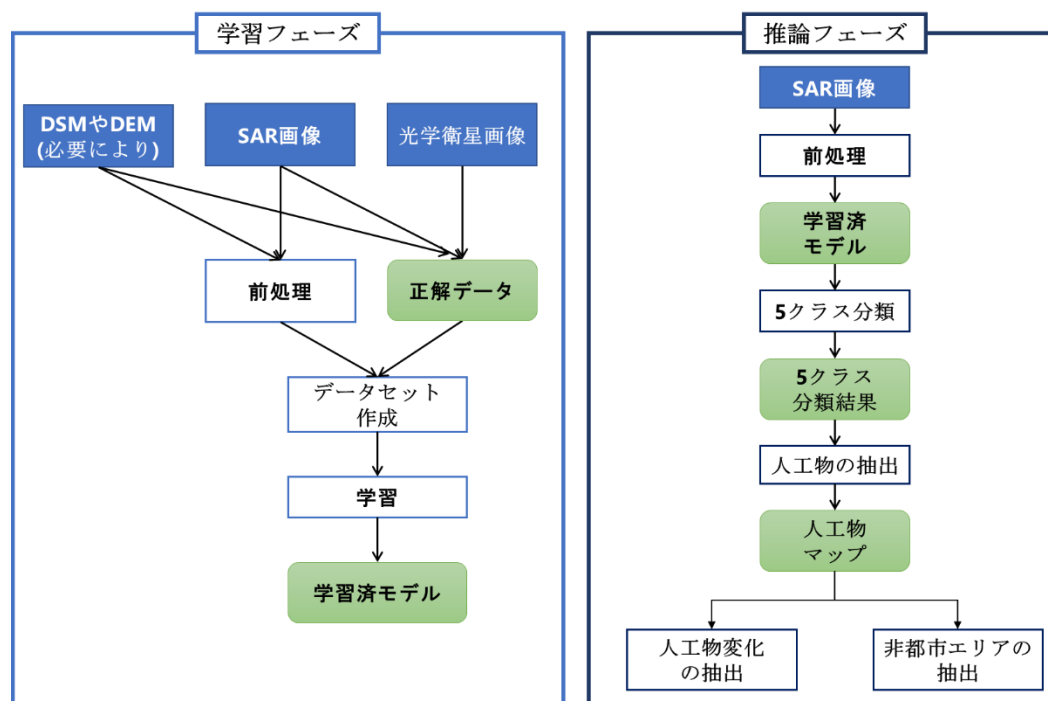


図 4.3 深層学習の学習と推論のフロー

4.3. データの作成

SAR 衛星画像は光学衛星画像に比べて、感覚的に分かりにくいいため、専門知識をもった者が識別を行う必要がある。そこで SAR 衛星画像からの地理情報の見分け方を熟知した上で、データの作成を行った。

正解データの作成方法を図 4.4 に示す。SAR 衛星画像だけでは、5 クラスの正確に識別しにくい場所もあるため、光学衛星画像と光学衛星画像から数式(1)で算出した正規化植生指標 (NDVI) [45]の画像を見比べることで、確実にそれぞれのクラスと識別される場所をそれぞれのクラスのラベル別の属性値を付加し GIS ツールで囲った。

$$NDVI = \frac{IR - R}{IR + R} \quad \dots \text{数式 (1)}$$

NDVI は植生の分布状況を表す数値であり、都市的土地利用と自然的土地利用を区別するための指標として活用することができる。IR は近赤外域の反射率の画像, R は可視域赤の反射率の画像を表す。本研究では, QGIS の演算機能を用いて各ピクセルの NDVI 算出を行い、画像化した。

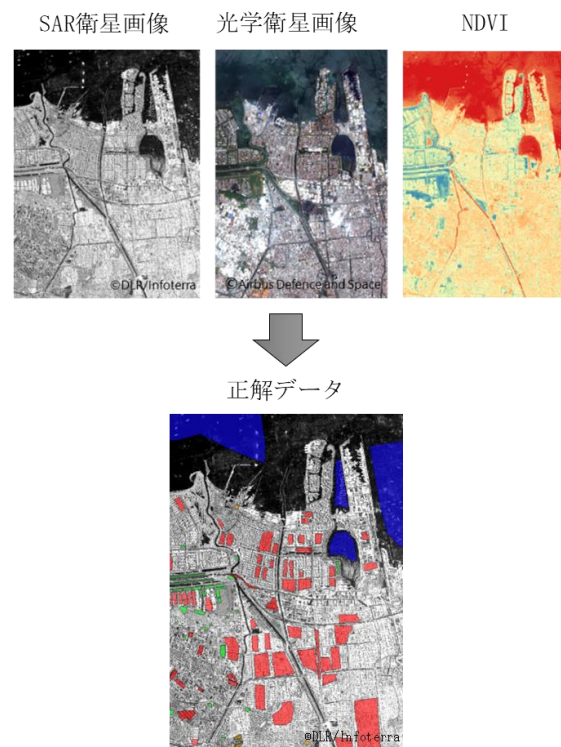


図 4.4 正解データの作成方法

4.4. 深層学習による地理情報識別

本論文の検証で用いる深層学習のモデルは、各クラスのラベル付けしたコンテキスト領域を考慮したパッチを CNN への入力とし、最終層の活性化関数は CNN で広く使われているソフトマックス関数 [46]とすることで、入力パッチが各クラスである予測確率を出力とした。学習率や正則化パラメータ等の学習によって自動的に決めることのできない超パラメータは、ベイズ的最適化を利用し [47], 検証用データセットの分類精度が高くなるような組み合わせを探索して決定した。層の構造についても、超パラメータを固定したうえで幾通りか試し、学習・テストに要する時間や、検証用パッチセットに対する精度を考慮して各値を設定した。深層学習モデルの構造を図 4.5 に示す。

なお、さらに深い層の深層学習モデルである GoogleNet [48]や ResNet [49]等を、パラメータチューニングを行った上で利用することは可能である。

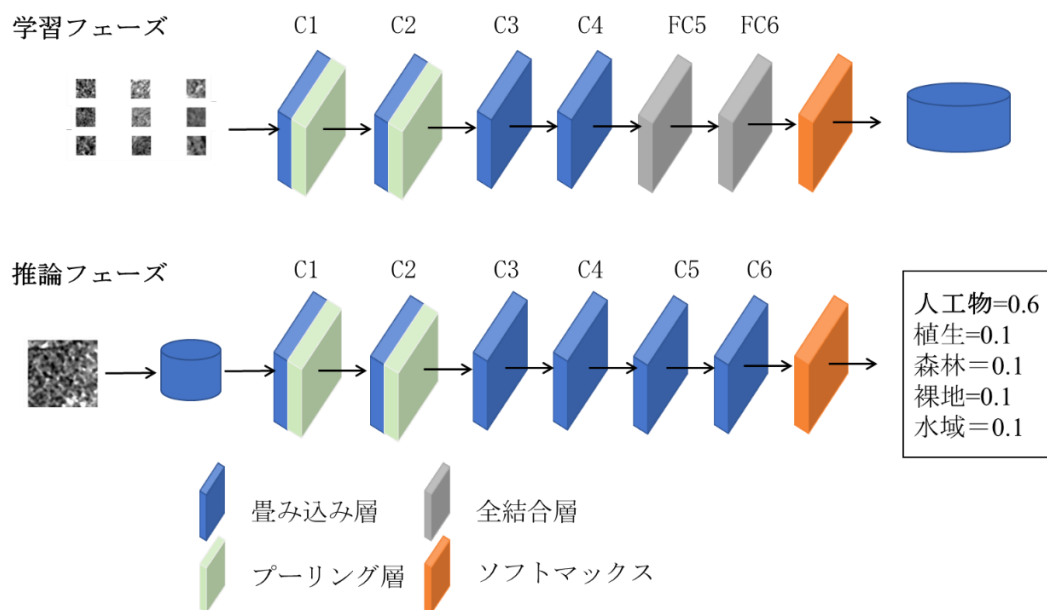


図 4.5 本研究で利用した深層学習のモデル

4.5. 深層学習モデルの再学習

深層学習は未知のデータに対しても、精度を大きく下げることなく推論することができるが、少ない新規データを作成し、再学習 (fine-tuning) することで [50] [51], より高い精度の推論を行うことができる。再学習とは、学習済みモデルを用いて少数の新しいデータセットで再度学習させることである。再学習と再学習済みモデルによる推論のフローを図 4.6 に示す。

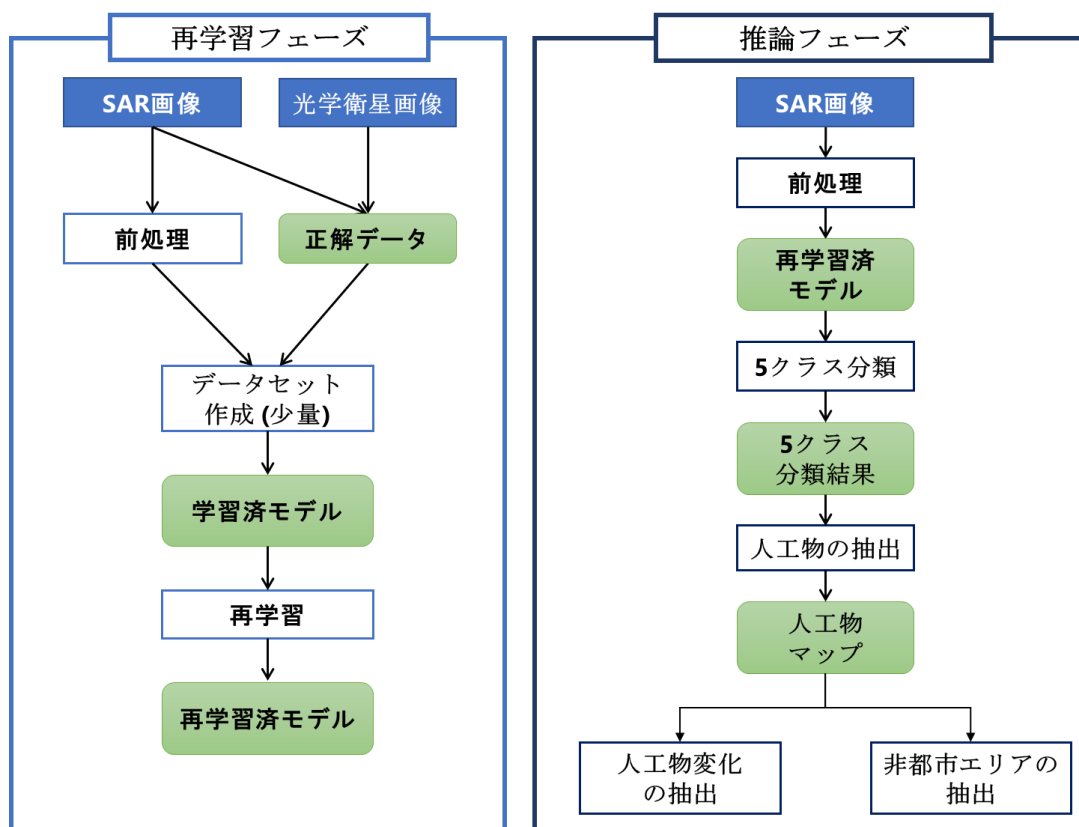


図 4.6 再学習モデルを用いた推論のフロー

4.6. パッチサイズの検討による識別精度の向上

4.6.1. パッチ画像の作成

GIS ツールで作成した正解データから学習と検証に用いるパッチ画像を作成する方法は、図 4.7 に示すように、25m x 25m の関心領域に単一のラベル（5 クラス）を含む領域において、100m～700m のコンテキスト領域を考慮したパッチ画像を切り出す。




図 4.7 パッチ画像の作成イメージ

4.6.2. パッチ画像サイズの検討

深層学習を用いる場合、コンテキストの情報が重要である。識別したい対象により、必要なコンテキストの領域は変わってくるため、本研究では観測したい地域の画像で精度の検証を行い、最適なパッチサイズを決定する。100m から 700m のパッチサイズを作成し、学習・推論を行い、識別精度を比較することで、パッチサイズを決定した。インドネシアジャカルタの衛星画像から 100m から 700m のパッチサイズで切り出したパッチ画像の例を図 4.8 に示す。

100m では建物の一部しかパッチに入らない一方で、700m では数十個の建物をコンテキストとして含むことができる。またクラス別のパッチ画像の例を図 4.9 に示す。




図 4.8 パッチサイズ別のパッチ画像の例


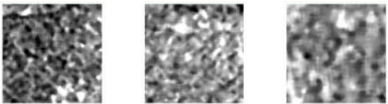

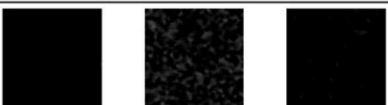

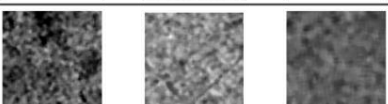

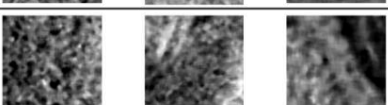

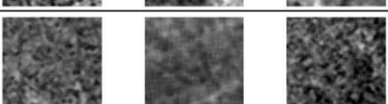
クラス	モデル1 (パッチサイズ = 100m)	モデル2 (パッチサイズ = 200m)
人工物		
水域		
草地		
森林		
その他裸地		

図 4.9 パッチサイズ別の各クラスの見え方の違い

4.7. DSM の追加による識別精度の向上

SAR 衛星画像は場所により異なる見え方をし、5 クラス分類が正しくできないことがある。例えば、海は水域に分類するのが正しいが、浅瀬・浮遊物・船舶等により、裸地や人工物として誤分類されることもある。そこで高さ情報である DSM 等を追加情報として与えることにより、分類精度を向上させることを考える。

方法としては、まず 1 偏波以上の SAR 衛星画像に DSM 画像をマージした画像データを作る。その後、図 4.3 のフローにしたがい、深層学習の学習と推論を行う。インプットとアウトプットのイメージを図 4.10 に示す。

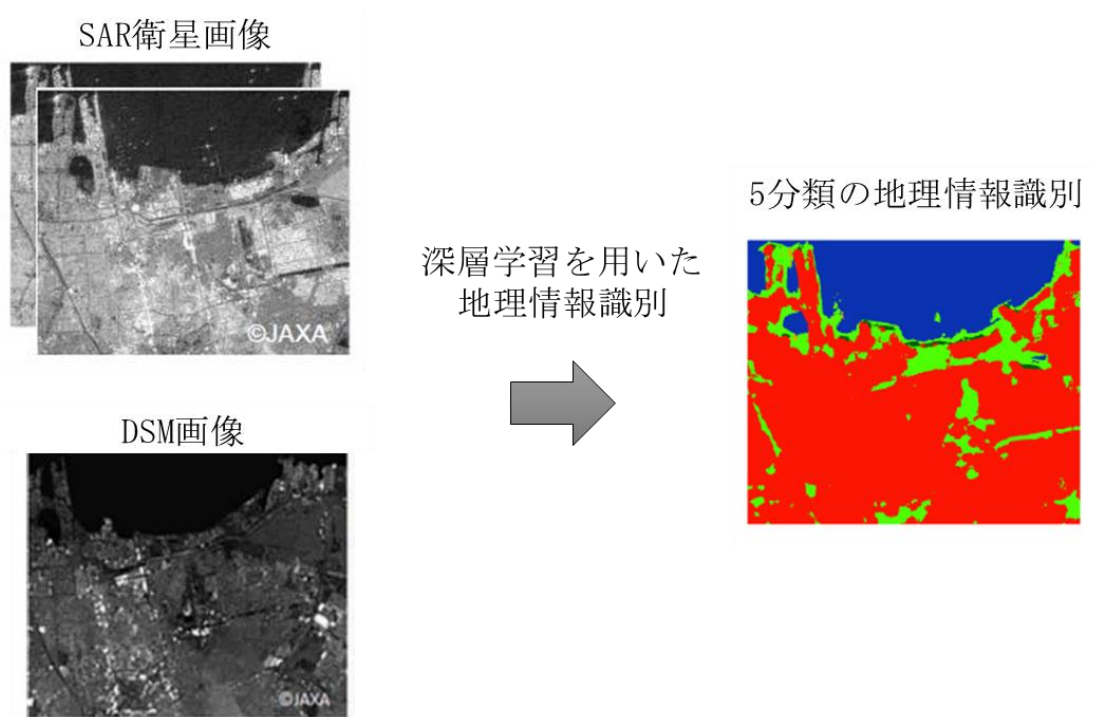


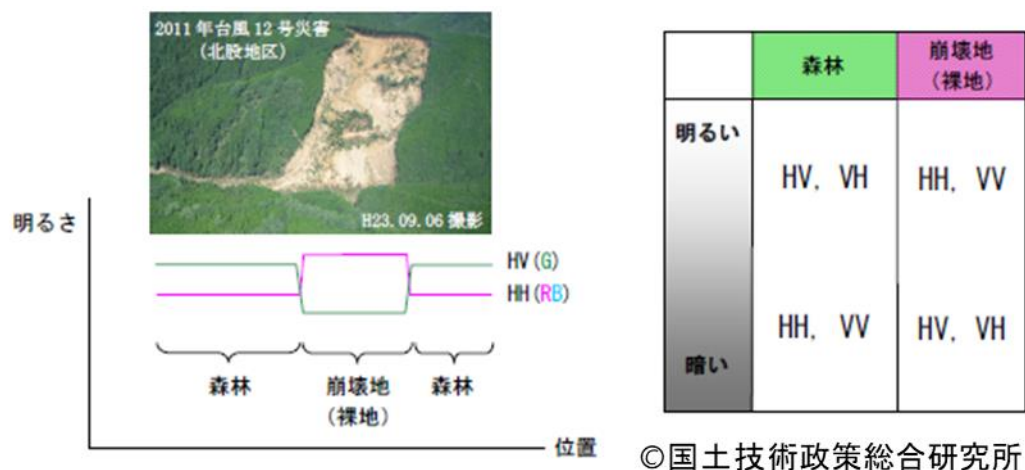
図 4.10 SAR 画像と DSM 画像を組み合わせた地理情報の識別

4.8. 複数の偏波情報を組み合わせた精度の向上

2 偏波 SAR 衛星画像を用いる場合、識別精度を向上させるための偏波の組み合わせ方について検討を行った。

4.8.1. SAR 衛星画像の偏波

偏波とは、時間的に変動する電場の振幅と振動方向の関係を記述するものであり、電界ベクトルの向きにより、振幅が進行方向に対して水平である水平偏波(H)と振幅が進行方向に対して垂直である垂直偏波(V)に分類される [27]。送受信の組み合わせで、HH, HV, VH, VV と表現される。SAR 衛星画像の偏波により異なる情報が得られるが、例えば HH, HV は崩壊地で後方散乱強度が大きく、森林では小さくなる。一方で HV, VH は森林で後方散乱強度が大きく、崩壊地では小さくなるという特性がある。図 4.11 のように偏波の違いにより明るさが異なり、見え方が異なる。



[27]

図 4.11 偏波の違いによる明るさのイメージ

例えば ALOS-2 の HH, HV 画像では図 4.12 のように、それぞれの地理情報の見え方が異なる。HH では草地と人工物の区別がしやすい一方で、HV では裸地と草地の区別がしやすいなどの異なる利点がある。




図 4.12 偏波の異なる SAR 衛星画像の見え方の違い

4.8.2. 偏波画像の組み合わせを利用した地理情報の識別

Abdikan らは、欧州の衛星である Sentinel-1 の 2 偏波 SAR 衛星画像を用いて、Support Vector Machine (SVM) による土地被覆分類の方法を提案した [52]。垂直方向で送信し垂直方向で受信する VV と垂直方向で送信し水平方向で受信する VH の組み合わせの分類精度の比較を行った結果、VV, VH, (VV-VH) の組み合わせが最も精度よく、全体の精度 (Overall accuracy) は 93.3% であった。

これらの偏波の組み合わせは、SAR 衛星画像の種類や機械学習の手法により異なることが考えられるため、本研究で用いる SAR 衛星画像と深層学習のモデルを用いて、複数の偏波組み合わせパターンで精度を検証し、最も分類精度がよくなる組み合わせを用いて、都市的土地利用への土地利用転換の把握を行うこととした。

4.9. 時系列の SAR 衛星画像を用いた都市的土地利用への土地利用転換の把握

本研究の目的である都市的土地利用への土地利用転換の把握を行うため、SAR 衛星画像から識別した 5 クラスの地理情報から都市的土地利用を抽出し、時系列の分析結果を比較する。地理情報の識別結果から都市的土地利用への土地利用転換の把握を行うイメージを図 4.13 に示す。

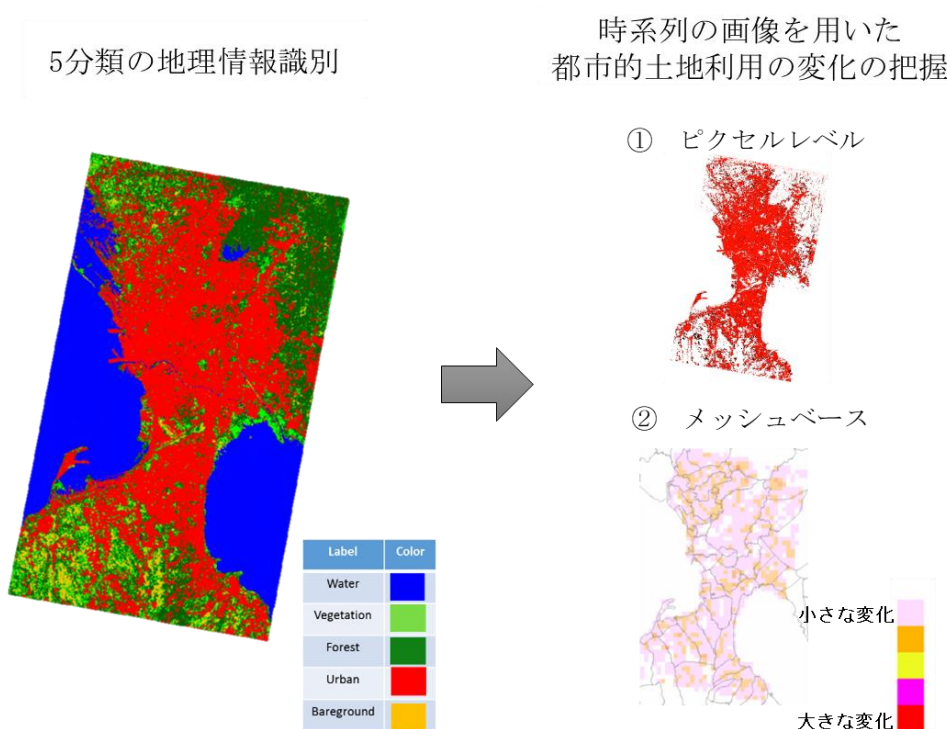


図 4.13 時系列の SAR 衛星画像を用いた都市的土地利用への土地利用転換の把握

まず 5 クラスの地理情報の識別結果から, GIS ツールを用いて都市的土地利用のエリアと識別されるピクセルの抽出を行う. その後, 時系列の SAR 衛星画像のピクセル値を比較することで, ピクセルベースでの都市的土地利用への土地利用転換の把握を行う. ピクセルベースの変化抽出は, 細かい箇所の変化まで捉えることができる一方で, 画像のノイズなどにも影響されやすく, 誤分類も起きやすい.

そこで図 4.14 に示すように GIS ツールで数百メートル単位のメッシュ (方形区) ポリゴンを作成し, ピクセルの統計処理を行うことで, メッシュベースでの変化分析を行うこととした.

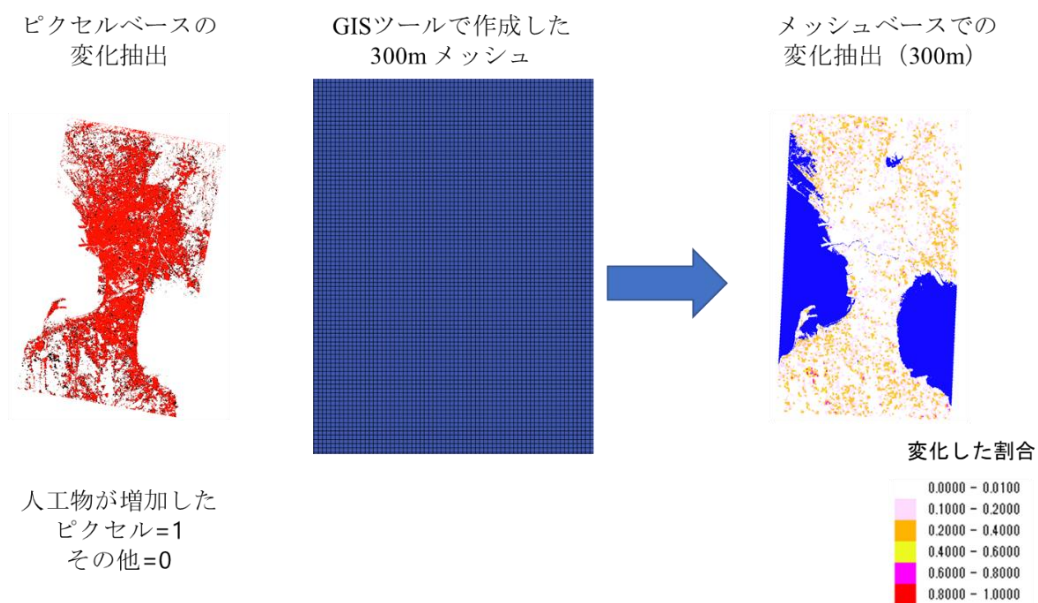


図 4.14 ピクセルベースの変化抽出からのメッシュベースでの変化抽出

4.10. 光学衛星画像と SAR 衛星画像を用いた世帯数の推計

深層学習の教師データのラベルとして 5 章と 6 章で利用するクラスの値の代わりに建物数を与えて学習・推測を行うことで、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の回帰推定を行うことができる。

提案手法と検証結果については 7 章において詳しく述べる。

4.11. 提案手法の利点

1.5 で挙げた 3 つの課題に対応した本提案手法の利点としては以下が挙げられる。

1. 都市的土地利用への土地利用転換の把握に必要な精度・頻度・観測範囲のデータが限られる
 - ・ 精度に関しては、画像分類で他の機械学習に比べて分類精度が高い深層学習を用いた地理情報の識別を行うことでより高い精度での推測を行うことができる。また学習時よりも少量の新規データを用いたモデルの再学習を行うことで、学習データと異なる画像に対しても高精度な地理情報の識別が可能になる。
 - ・ 頻度に関しては、SAR 衛星画像を用いることで雲や太陽光の影響を受けず、安定した画質の画像が取得可能であり、高頻度で地理情報の識別ができる。
 - ・ 観測範囲に関しては、SAR 衛星画像 1 枚で広範囲をカバーすることができ、均一な基準での分析を行うことができる。
2. 得られた画像情報から地理情報を識別できない
 - ・ SAR 衛星画像は光学画像と異なりモノクロであり感覚的に地理情報の識別を行うことが難しく、識別にかかる時間も長時間かかる。専門知識をもった者が一部の地域の画像のみに対して地理情報の識別を行うことで学習データを作成し、深層学習モデルに学習させることで、自動での地理情報の識別が可能になる。そのため、均一の基準での地理情報の識別を行うことが可能になる。また深層学習は学習済みモデルを用いた推測を迅速に行うことができるため、SAR 衛星画像を入手してから分析結果を得られるまで短時間である。
3. 地理情報から都市的土地利用への土地利用転換を把握することができない
 - ・ SAR 衛星画像から識別した 5 クラスの地理情報から都市的土地利用の場所を抽出し、時系列の分析結果の差分をとることで、2 章で定義した都市的土地利用への土地利用転換の把握に必要なレベルでの情報を得ることができる。

4.12. 検証方法

4 章で提案した手法について, 表 4.1 の各項目の検証マトリックスに従い, 5 章・6 章・7 章で検証を行っていく.

表 4.1 検証マトリックス

	5 章の検証 (1 偏波画像の利用)	6 章の検証 (2 偏波画像の利用)	7 章の検証 (世帯数の推計)
4.3. データの作成	○	○	○
4.4. 深層学習による 地理情報識別	○	○	○
4.5. 深層学習モデルの 再学習	-	○	-
4.6. パッチサイズの 検討による 識別精度の向上	○	○	-
4.7. DSM の追加による 識別精度の向上	-	○	-
4.8. 複数の偏波情報を 組み合わせた精度の 向上	-	○	-
4.9. 時系列の SAR 衛星画像を 用いた 都市的土地利用 への土地利用 転換の把握	○	○	-
4.10. 光学衛星画像と SAR 衛星画像を 用いた世帯数推計	-	-	○

4.13.4 章のまとめ

本章では, SAR 衛星画像を用いた深層学習による地理情報識別に基づく都市的土地利用への土地利用転換の把握を行うための手法について述べた.

最初に 1 偏波または 2 偏波の SAR 衛星画像から深層学習により高精度な 5 クラスの地理情報識別を行う. 次のステップでは, GIS ツールや作成したプログラム等を用いて, 都市的土地利用として識別されたピクセルを抽出する. そして抽出された都市的土地利用のピクセルの情報を時系列で分析し, 都市的土地利用への土地利用転換の把握を行う.

また地理情報識別の精度を上げるために, 深層学習の画像分類に重要であるコンテキスト領域を考量したパッチサイズの比較, 高さ情報である DSM を追加した精度の改善, 2 偏波 SAR 衛星画像を用いることができる場合の偏波画像を組み合わせ方法, 新しい画像に対する深層学習のモデルの再学習についての手法を示した.

本章で提案した手法の有効性を示すための検証結果を, 5 章・6 章・7 章で述べる.

第5章 1 偏波 SAR 衛星画像からの 都市的土地利用への土地利用転換の把握

5.1. 概要

本章では, 提案手法を用いて, 1 偏波 SAR 衛星画像 TerraSAR-X から, 都市的土地利用への土地利用転換の把握を行うことが出来るかの検証を行った. TerraSAR-X はドイツの衛星画像であり, SAR 衛星画像としては高分解能の画像を得ることができる [53]. Spotlight SL mode の HH の分解能 1.25m の画像を用いた. 1 偏波 SAR 衛星画像を用いた都市的土地利用への土地利用転換の把握のフローを図 5.1 に示す.

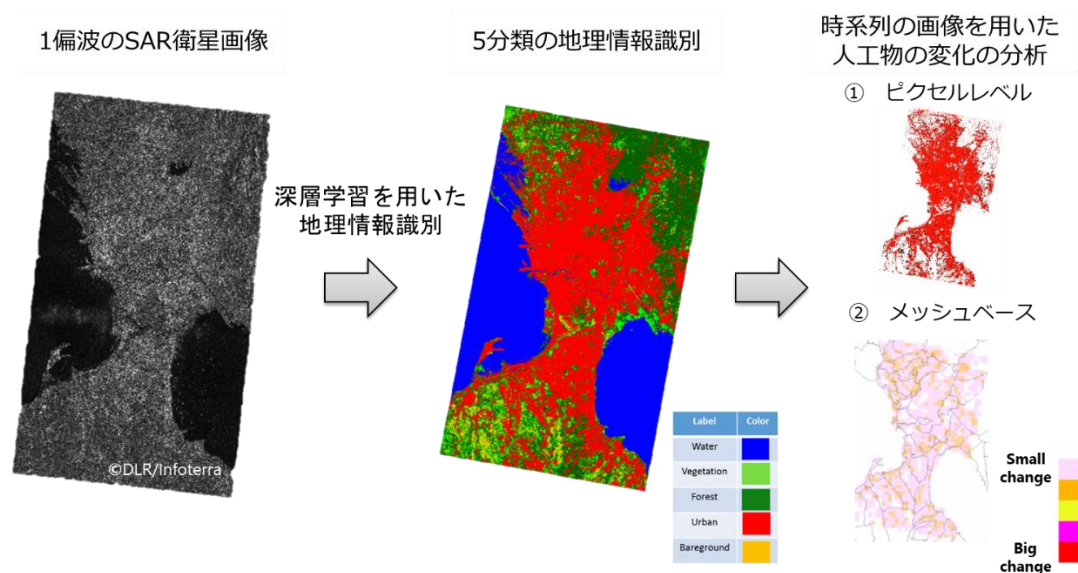


図 5.1 1 偏波 SAR 衛星画像を用いた都市変化の把握のフロー

5.2. 利用するデータ

学習データとしてインドネシアのジャカルタ、フィリピンのマニラ、ベトナムのハノイの画像データを用い、テストデータとして、別日時に撮影されたマニラとヤンゴンの画像を用いた。用いた衛星画像の場所・撮影日時を表 5.1 に示す。

表 5.1 利用した衛星画像のデータ

目的	衛星	場所	撮影日時
学習データ	TerraSAR-X	ジャカルタ	2015/12/23
		マニラ	2016/02/20
		ハノイ	2016/09/01
テストデータ	TerraSAR-X	マニラ	2010/03/27
			2013/03/20
			2016/08/25
			2017/01/15
		ヤンゴン	2010/05/26
			2016/08/30
			2016/12/07

5.3. 学習とテスト用のパッチ画像の作成

4.6.1 章で述べた方法を用いて、学習とテスト用のパッチ画像を作成した。光学衛星画像、植生指標(NDVI)の結果、SAR 衛星画像を比較し、確実に人工物・水域・植生・森林・裸地の 5 クラスの区域である地域を抽出し、パッチサイズ 100m と 200m のパッチ画像を作成した。正解データ・NDVI 画像の算出等に用いる光学衛星画像は Pleiades と Landsat を用いた。Pleiades はフランスの 50cm の高分解能光学衛星の画像である [54]。

学習に用いたパッチ画像のデータ数を表 5.2 に示す。

表 5.2 作成したパッチ画像の学習データ数

	ジャカルタ	マニラ	ハノイ	合計
人工物	2579	2578	2579	7736
水域	2579	2578	2579	7736
草地	2579	2578	2579	7736
森林	3239	3812	685	7736
裸地	971	2882	3883	7736
合計	11947	14428	12305	38680

5.4. 検証方法

マニラ・ヤンゴンの 600 個のパッチ画像を画像分類し定量的評価を行うとともに, SAR 衛星画像全体に対して識別を行い, 定性的評価を行った.

5.5. パッチ画像の分類結果に対する定量的評価

100m と 200m のパッチサイズで作成した人工物とラベル付けしたパッチ画像を分類した結果を適合率(Precision)・再現率(Recall)・F 値により比較することで定量的評価を行った.

適合率は正解と予測したうちの正解率, 再現率は正解の正のうち正しく予測できた率, F 値は適合率と再現率の調和平均をとった指標である [55]. 混同行列を図 5.2 に示す. 適合率・再現率・F 値を算出するための数式は(2)-(4)である.

		正解	
		正	負
予測	正	True Positive (TP)	False Positive (FP)
	負	False Negative (FN)	True Negative (TN)

図 5.2 混同行列

$$\text{適合率} = \frac{TP}{(TP+FP)} \quad \dots \text{数式 (2)}$$

$$\text{再現率} = \frac{TP}{(TP+FN)} \quad \dots \text{数式 (3)}$$

$$F\text{値} = \frac{2 \times \text{再現率} \times \text{適合率}}{\text{再現率} + \text{適合率}} \quad \dots \text{数式 (4)}$$

パッチ画像の分類結果を適合率・再現率・F 値で評価した結果を表 5.3 に示す. 100m と 200m のコンテキストのパッチサイズ別の適合率, 再現率, F 値を比較すると, いずれの値でも 200m のパッチ画像の方が高い. このことから, より大きなコンテキストを含めたパッチ画像を用いることにより, より高い精度の地理情報識別を行うことができると考えられる.

さらに大きなコンテキストを考慮したパッチサイズを用いることで精度がさらに高まるか 6.6 章の 2 偏波画像を用いた検証により示す.

表 5.3 パッチ画像の分類結果

	100m	200m
適合率	532 パッチ/560 パッチ (95%)	556 パッチ/572 パッチ (97.2%)
再現率	532 パッチ/600 パッチ (88.67%)	556 パッチ/600 パッチ (92.67%)
F 値	91.73%	94.88%

5.6. ヤンゴンのピクセルベースの都市的土地利用への土地利用転換の把握

ヤンゴンの衛星画像を用いて都市的土地利用への土地利用転換を把握できるかの定性的評価を行った。ピクセルベースでの変化分を図 5.3 に示す。




図 5.3 ヤンゴンの増加した人工物

5.7. ヤンゴンのメッシュベースの都市的土地利用への土地利用転換の把握

ピクセルベースの分析結果を見ると、変化しているピクセルの数が多く、都市的土地利用への土地利用転換が行われているエリアを識別するのは難しい。そのため、QGIS の演算機能を利用したメッシュベースで変化分の分析を行うこととした。メッシュサイズの大きさを 300m と 1 km の 2 通りで変化分の分析を行った結果を図 5.4 と図 5.5 に示す。取得した情報の粒度に合わせてメッシュサイズを選択し、分析を行うことが重要である。この結果を図 5.6 の JICA 調査団が作成した 2025 年のヤンゴン土地利用予測図の傾向と比較すると、整合性のある結果を得ることができる。

分析結果で変化があると推測された箇所と、Landsat 画像から目視で確認できた人工物の変化が確認された箇所の比較を行った結果を図 5.7 と図 5.8 に示す。赤枠で囲った箇所については、Landsat 画像でも目視で変化を確認することができた。

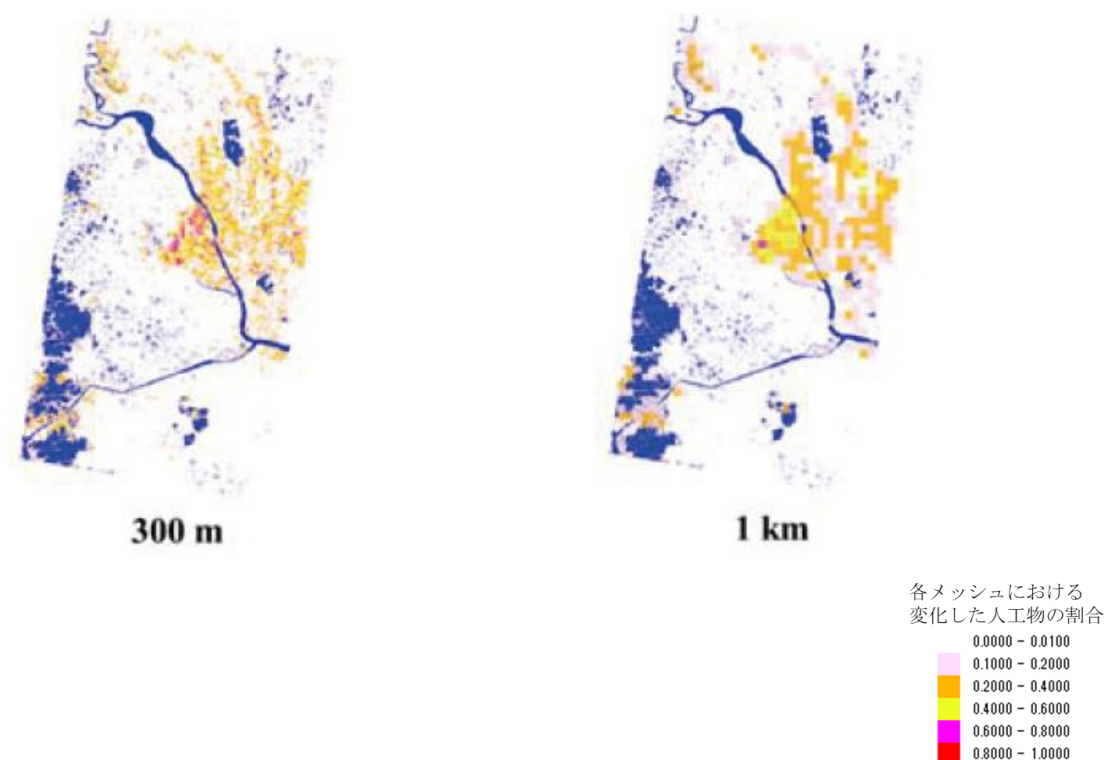


図 5.4 2010 年から 2016 年のヤンゴンのメッシュベースでの都市変化


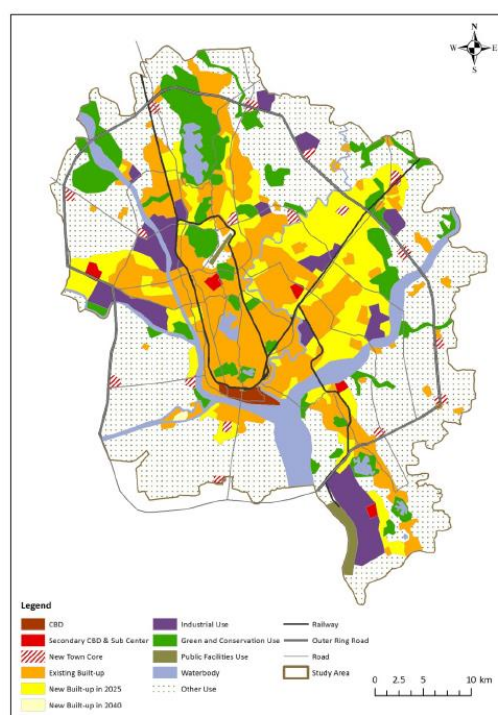


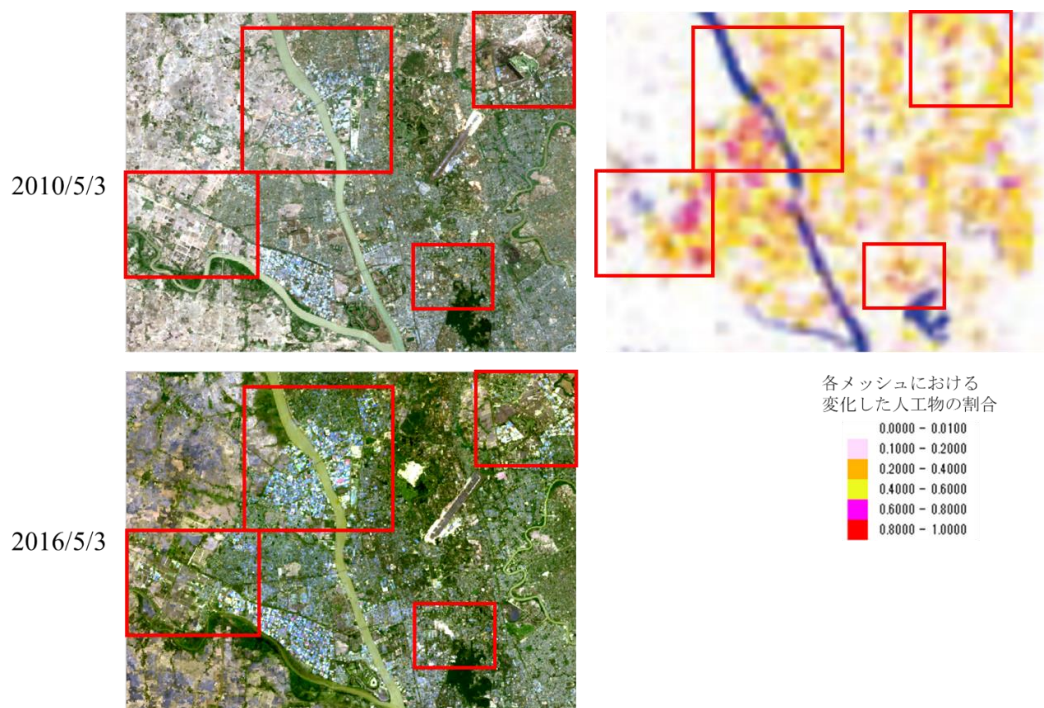
図 5.5 2016 年から 2017 年のヤンゴンのメッシュベースでの都市変化



出典：JICA 調査団

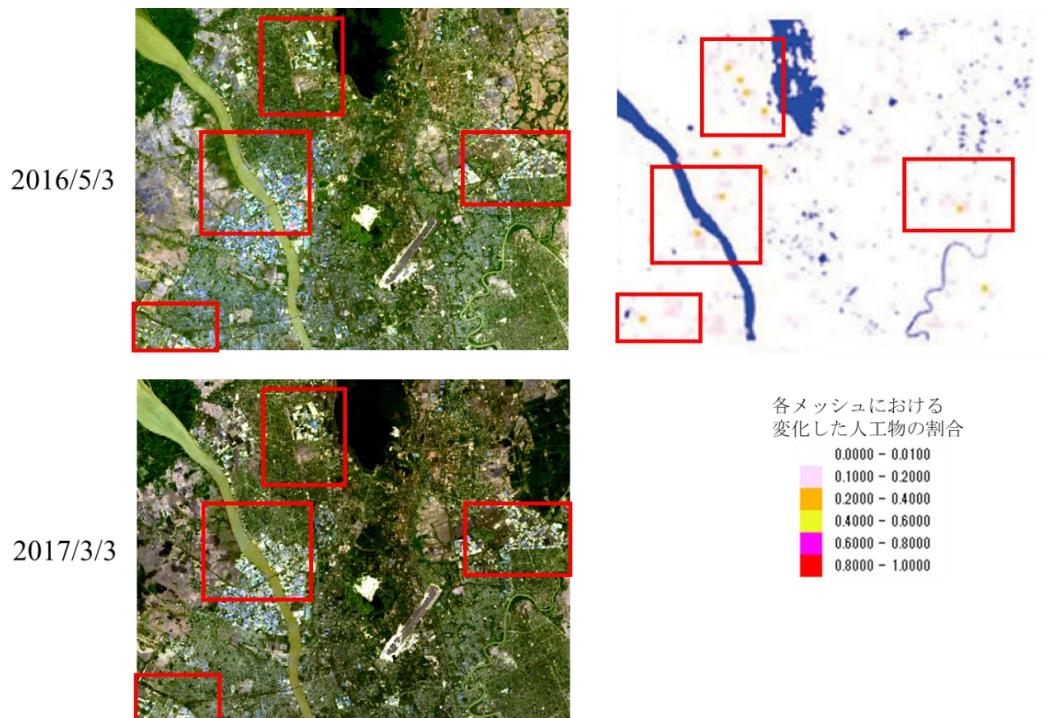
[16]

図 5.6 JICA 調査団が作成した 2025 年のヤンゴン土地利用予測図



©USGS

図 5.7 ヤンゴンにおける 2010 年から 2016 年の人工物変化と分析結果の比較



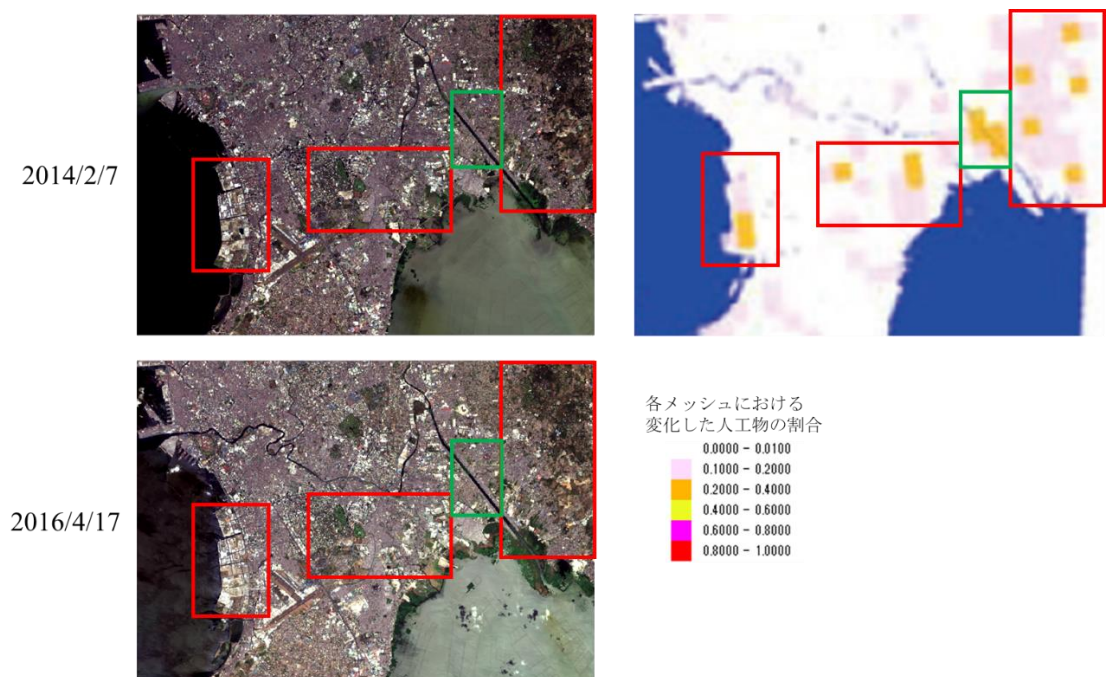
©USGS

図 5.8 ヤンゴンにおける 2016 年から 2017 年の人工物変化と分析結果の比較

5.8. マニラの都市的土地利用への土地利用転換の把握

マニラの画像を用いて都市的土地利用への土地利用転換の把握ができるかの定性的評価の結果を図 5.9 に示す。赤枠で囲った箇所については、Landsat 画像から目視で人工物の変化を確認することができた。緑枠で囲った箇所については、Landsat 画像では変化を確認できなかったが、分析結果ではメッシュ内の 20% から 40% の変化が確認されている。

これらの場所を光学衛星画像で確認を行った結果、図 5.10 に示すように、狭い川などの水域において誤分類が多いことが確認された。



©AIRBUS DS

図 5.9 マニラにおける 2014 年から 2016 年の人工物変化と分析結果の比較




図 5.10 水域の誤分類の例

5.9. 光学衛星画像からの水域抽出結果を用いた精度向上

5.9.1. 手法

水域の分類結果の誤分類を改善するため、光学衛星画像から深層学習を用いて水域を抽出しその結果を組み合わせることで、都市的土地利用への土地利用転換の把握の推論精度を上げる。水域の抽出精度を上げるため、NIR・gNDVI・NDWI・BAIの4つの指標を用いて、深層学習を用いた地理情報の識別を行った。深層学習のモデルは、衛星画像のピクセルサイズの違いを考慮し、4.4章のモデルにパディングを加えた。

5.9.2. 利用するデータ

光学衛星画像は欧州のESAが無料で提供しているSentinel-2 [56]を用いた。Sentinel-2は合計13バンドの観測波長帯を持つため、それらのバンドから算出できるNDVIをはじめとする様々な指標の活用を行った。様々な指標を検討した上で、今回の目的に合わせて選定した指標の名称と説明を表5.4に示す。

表 5.4 各指標の名称と説明

番号	指標の名称	指標の説明	数式
1	正規化植生指数 Normalized difference vegetation index (NDVI) [45]	植生指標	(1)
2	緑正規化植生指数 Green normalized difference vegetation index (gNDVI) [57]	植生指標	(5)
3	正規化水指数 Normalized Difference Water Index (NDWI) [58]	水指標	(6)
4	開発指標値 Built-up Area Index (BAI) [59]	市街化指標	(7)

$$gNDVI = \frac{(NIR - Green)}{(NIR + Green)} \cdot \cdot \cdot \text{数式 (5)}$$

$$NDWI = \frac{(Green - NIR)}{(Green + NIR)} \cdot \cdot \cdot \text{数式 (6)}$$

$$BAI = \frac{(Blue - NIR)}{(Blue + NIR)} \cdot \cdot \cdot \text{数式 (7)}$$

RGB と近赤外領域のバンドに加えて、数式(1), (5)-(7)で算出した指標が、水域を抽出するのに有効であるかの評価を行うため、水域の 픽셀値と人工物・草地・森林・裸地それぞれの 픽셀値との差を比較した結果を図 5.11 に示す. 4 つの指標の 픽셀値を GIS 表示したものを図 5.12 に示す.




図 5.11 水域と他クラスの 픽셀値の違い




図 5.12 各指標のピクセル値

5.9.3. 正解データとの比較による定量性評価

正しく水域が抽出できたか評価を行うため、高分解能の光学衛星画像の SPOT6 [60]のデータから目視で水域の正解データを作成し、その正解データとの比較評価を行った。作成した正解データを図 5.13 に示す。

深層学習により水域と識別されたピクセル値と作成した正解データに対して、適合率・再現率・F 値による比較を行った結果、表 5.5 に示すとおり、68.47%の F 値を得ることができた。深層学習による水域の識別結果と作成した正解データを比較した結果を図 5.14 に示す。画像の右側の比較的大きな川はほぼ全域で正しく抽出ができているが、左側の水域は誤分類があった。

水域の精度をさらに向上させるためには、無料で入手可能な Sentinel-2 の代わりに、有償で入手可能な高分解能の光学衛星画像を用いることが考えられる。




図 5.13 検証用の正解データ

表 5.5 正解データと比較した水域の抽出精度

	水域
適合率	56.18%
再現率	87.64%
F 値	68.47%




図 5.14 水域の識別結果と作成した正データの比較評価

5.10. 水域の誤分類の改善

SAR 衛星画像からの水域識別結果と光学衛星画像からの水域識別結果を比較した結果を図 5.15 に示す. この結果から, 光学衛星画像を用いた水域の識別結果をマージすることで, 水域と人工物の誤分類を減少できることが確認できた.

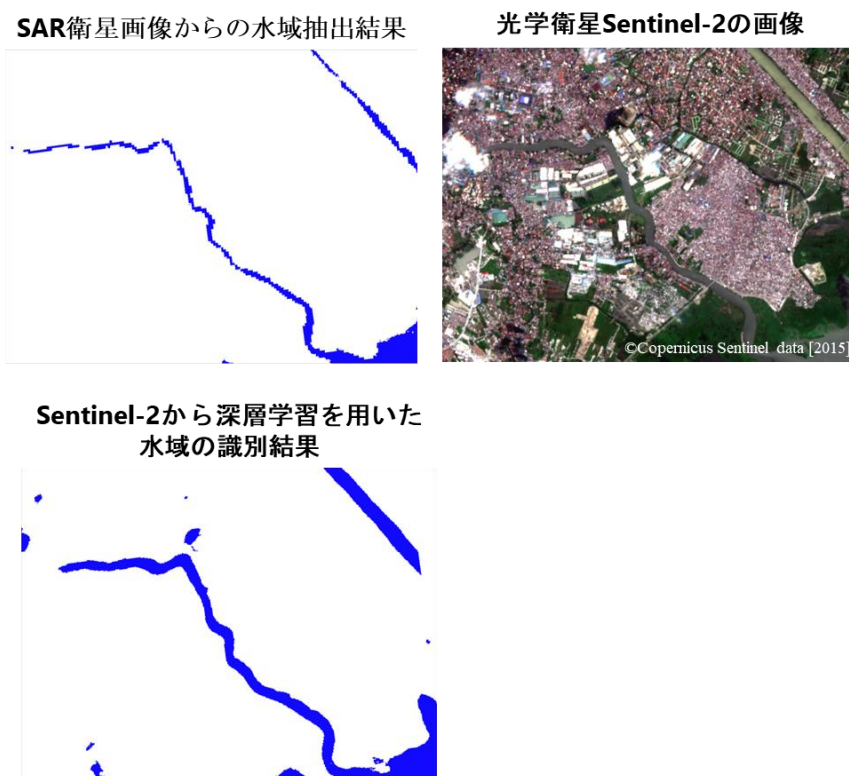


図 5.15 光学衛星画像と SAR 衛星画像からの水域識別結果の比較

5.11.5 章まとめ

提案手法を用いて 1 偏波の SAR 衛星画像から 5 分類の地理情報識別を行い, そこから都市的土地利用を抽出し, 時系列の分析結果を用いた変化抽出を行うことで都市的土地利用への土地利用転換の把握を行えることを, フィリピンのマニラ・ミャンマーのヤンゴン・インドネシアのジャカルタの衛星画像を用いた検証で示した.

SAR 衛星画像から深層学習による地理情報識別を行い, 数か月・数年単位での都市的土地利用への土地利用転換の把握を行うことができた. ピクセルベースとメッシュベースでの都市的土地利用への土地利用転換の分析結果の特徴を以下のように整理することができる.

① ピクセルレベルでの変化把握

- 1~6m ほどの高い分解能で, 変化の把握が可能になる
- 一方で誤分類も多い

② メッシュレベルでの変化把握

- 捉えたい変化の程度に合わせた粒度で変化の把握ができる
- 誤分類が比較的少なくなり, 土地利用の変化が起きている箇所を特定しやすくなる

狭い川などに対しては 1 偏波の SAR 衛星画像の限られた情報量により誤分類があったが, 光学衛星画像からの地理情報の識別結果を用いて精度の改善を行った結果, 半分以上のエリアで水域を正しく抽出することができた.

検証結果から, 2.10 章で整理した要求に対して, 都市的土地利用の転換の把握に必要な精度・頻度・観測範囲で分析を行えることを示した.

第6章 2 偏波 SAR 衛星画像からの 都市的土地利用への土地利用転換の把握

6.1. 概要

2 偏波の SAR 衛星画像を用いて都市的土地利用への土地利用転換の把握を行った. 2 偏波画像を用いることで, 1 偏波の衛星画像よりも得られる情報量が多くなり, 分類精度も上がることが期待される. また人工物の分類精度を上げるために, 高さ情報である数値表層モデル (DSM : Digital Surface Model) を活用した.

DSM の利用に関する先行事例として, Tian らは, 光学衛星画像と DSM を組み合わせることにより建物変化検知の精度を上げ [61], Långkvist らは, 光学衛星画像からの CNN による分類・セグメンテーションに DSM を組み合わせて精度を上げることができた [34].

6.2. 利用するデータ

ジャカルタ 2 時期, ハノイ 1 時期の ALOS-2 の 2 偏波 SAR 衛星画像に加えて, DSM としてオープンデータである ALOS World 3D - 30m [62]を用いた学習・テストを行った. SAR 衛星画像の分類結果の妥当性評価のため, 同時期に撮影された光学衛星画像を利用した.

6.3. 学習とテスト用のパッチ画像の作成

光学衛星画像, 算出した NDVI の結果, SAR 衛星画像を比較し, 確実に人工物・水域・植生・森林・裸地の 5 クラスの区域である地域を抽出した. パッチサイズ 100m, 300m, 500m, 700m のパッチ画像を作成し, 学習データと評価データに分けた. また高さ情報としての DSM を画像データの一つのバンドとしてマージした.

6.4. 深層学習の超パラメータ設定

本検証では 4.4 章に述べた深層学習のモデルを用いたが, 学習によって自動的に決めることのできない超パラメータは, ベイズ的最適化を利用して検証用データセットの分類精度が高くなるような組み合わせを探索して決定した [47]. 精度が高くなるような超パラメータをマニュアルでの試行で決めることは難しいため, ランダムにパラメータの組み合わせを作成し, 試行を行うプログラムを作成し, 最も精度が高くなるパラメータを探索した.

探索して決定したパラメータの例を表 6.1 に示す.

表 6.1 利用した超パラメータ

超パラメータ名称	選定したパラメータ
学習率	1e-3
モメンタム	0.877408447266
荷重減衰	0.000425028418183
イタレーションの数	20000

6.5. 偏波の組み合わせ別の地理情報の識別精度の評価

2 偏波の情報を有効に利用するため、偏波の組み合わせ（例：HH, HV, HH-HV など）別に 5 クラスの分類精度を比較し、最も平均値が高い組み合わせをその後の学習・テストに用い、深層学習を用いた地理情報の識別を行うこととした。偏波の組み合わせ（例：HH, HV, HH-HV など）別に 5 クラスの分類精度を比較した結果を図 6.1 に示す。5 クラスの分類精度の平均が 64.92%と最も高い組み合わせであった HH, HV, HH/HV を用いて、その後の学習・テストを行った。




図 6.1 偏波の組み合わせ別の分類精度

SAR 衛星画像の HH, HV, HH/HV, DSM, 比較するための光学衛星画像の見え方の違いについて図 6.2 に示す。それぞれ異なる見え方の画像情報を得ることができ、深層学習により分類精度を向上させることができる。

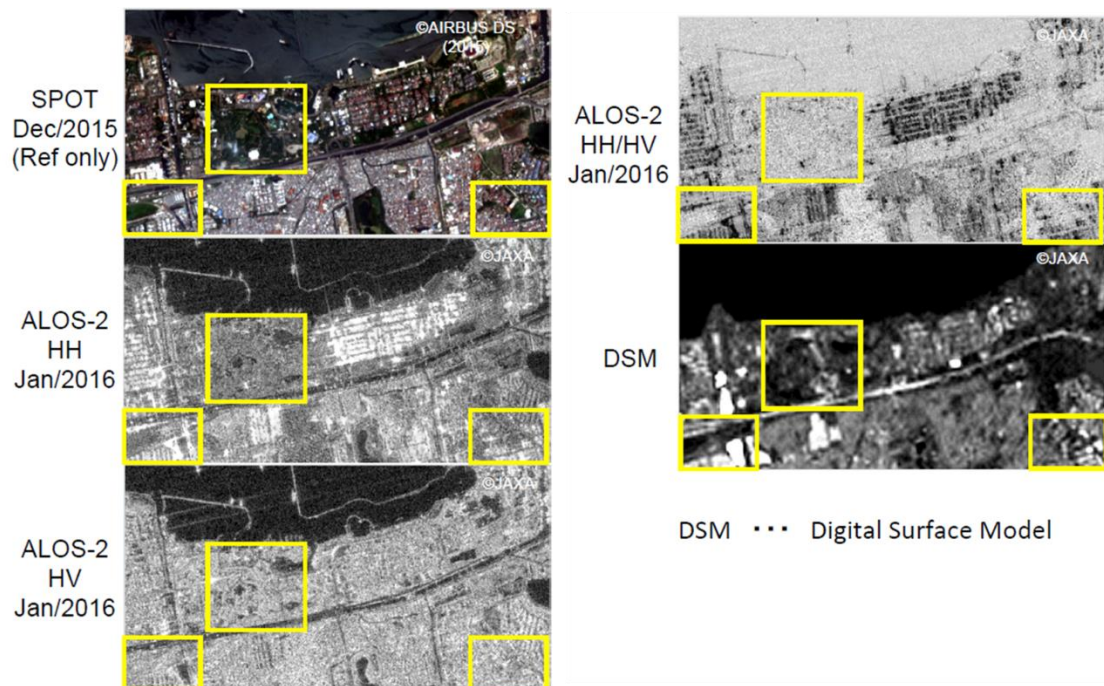


図 6.2 各偏波による見え方の違い

6.6. 地理情報の識別精度の定量的評価

5 クラスそれぞれ 400 個のパッチ画像を用いて検証を行った。DSM ありなしの 2 パターン、パッチ画像の大きさ 4 つのパターンで、それぞれパッチ画像の分類精度を評価した。

人工物のパッチサイズ別の結果をグラフ化したものを図 6.3, 5 クラスのパッチサイズ別の結果を表 6.2 に示す。その結果、人工物の識別精度については、300m のパッチサイズで、DSM を加えた画像データで学習したモデルが最も良い結果であった。




図 6.3 人工物のパッチサイズ別の精度の比較

表 6.2 各クラスのパッチサイズ別の精度

100m		
	DSM を加えていない時の分類精度	DSM を加えた時の分類精度
人工物	95.95	95.40
水域	88.97	95.34
草地	67.74	79.83
森林	90.27	97.24
裸地	77.94	88.55
300m		
	DSM を加えていない時の分類精度	DSM を加えた時の分類精度
人工物	97.18	97.96
水域	96.88	98.37
草地	92.31	94.99
森林	97.18	98.39
裸地	97.33	98.76
500m		
	DSM を加えていない時の分類精度	DSM を加えた時の分類精度
人工物	96.79	96.64
水域	98.24	98.74
草地	95.03	95.47
森林	98.52	99.25
裸地	98.64	99.13
700m		
	DSM を加えていない時の分類精度	DSM を加えた時の分類精度
人工物	90.96	97.32
水域	97.24	98.74
草地	81.53	95.31
森林	89.59	99.13
裸地	95.71	98.76

6.7. 時系列画像を用いたジャカルタの地理情報の識別

学習済みモデルを用いて SAR 衛星画像全体に対して地理情報の識別を行った。ジャカルタとハノイの画像に対して、パッチサイズ別の SAR 衛星画像のみの識別結果, SAR 衛星画像に DSM を加えた画像の識別結果, 同時期に撮影された光学衛星画像 SPOT 画像を並べた画像を図 6.4 と図 6.5 に示す。

パッチサイズにより, 異なる特徴の結果を得た。例えば 100m では人工物を過抽出している箇所が多いことが分かった。また DSM を含めることにより裸地や人工物の誤分類を減らすことが出来ることを確認した。

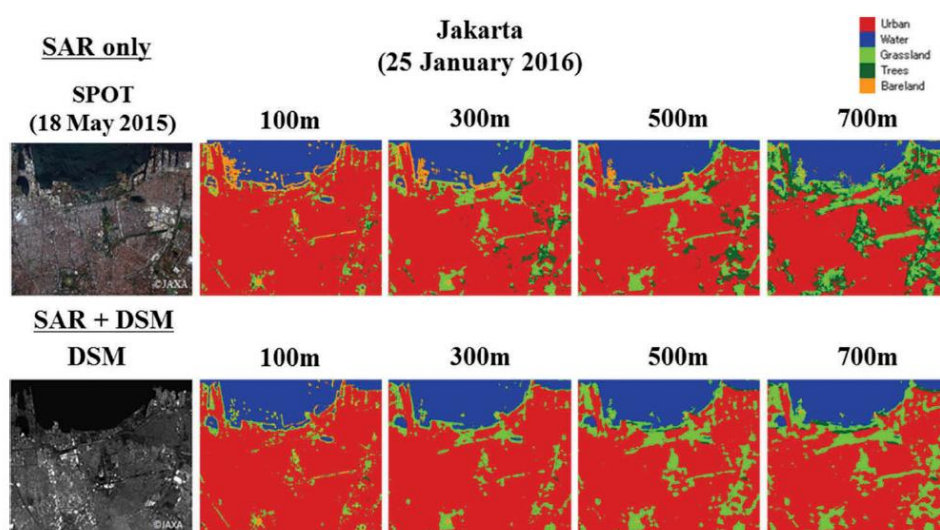


図 6.4 ジャカルタの地理情報の推測結果

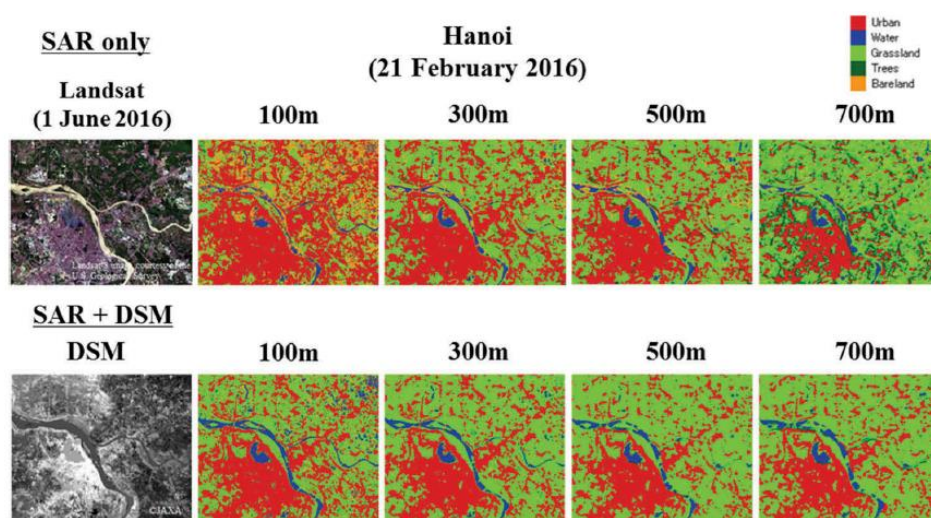


図 6.5 ハノイの地理情報の推測結果

6.8. DSM の利用についての考察

偏波の組み合わせ、高さ情報である DSM の追加、パッチ画像のサイズ別の分析結果を比較することにより、5 種類の地理情報の識別精度を上げることができた。DSM については 1 時期のデータを用いたが、精度をさらに向上させるためには、衛星画像の日時と DSM の日時をできるだけ合わせる必要がある。そのため複数の SAR 衛星画像からの DSM を作成する手法の利用 [63] [64], SAR 衛星画像と DSM をセットで学習させた深層学習モデルを作成し、SAR 衛星画像から DSM を推測すること等の方法が考えられる。

6.9. 深層学習と最尤推定の推測結果の比較

深層学習モデルと他の機械学習の手法を比較するため、代表的な機械学習の手法である最尤推定を使って推測を行った結果との比較を行った。光学衛星画像からの土地被覆分類に対する最尤推定の有効性を示した関連研究としては Akgun [65]や Subhash [66]らの研究がある。

光学衛星画像と 2 つの方法の識別結果を比較した結果を、図 6.6 と図 6.7 に示す。最尤推定は Arc GIS 10.3 [67]を用いて行った。最尤推定の利点としては、学習データに似ている特徴をもつ画像に対しては高い精度で識別を行うことができることである。

図 6.7 の結果を考察すると、住宅街などは精度よく識別が出来ている一方で、工場エリア等の地域は人工物でなく、草地として誤分類している。またコンテキスト情報を考慮した識別を行っていないため、識別結果が細かく分かれており、深層学習に比べて都市的土地利用の土地利用転換の把握に適していないと考察される。深層学習はモデルの再学習ができることから、他の機械学習に比べて優位である。

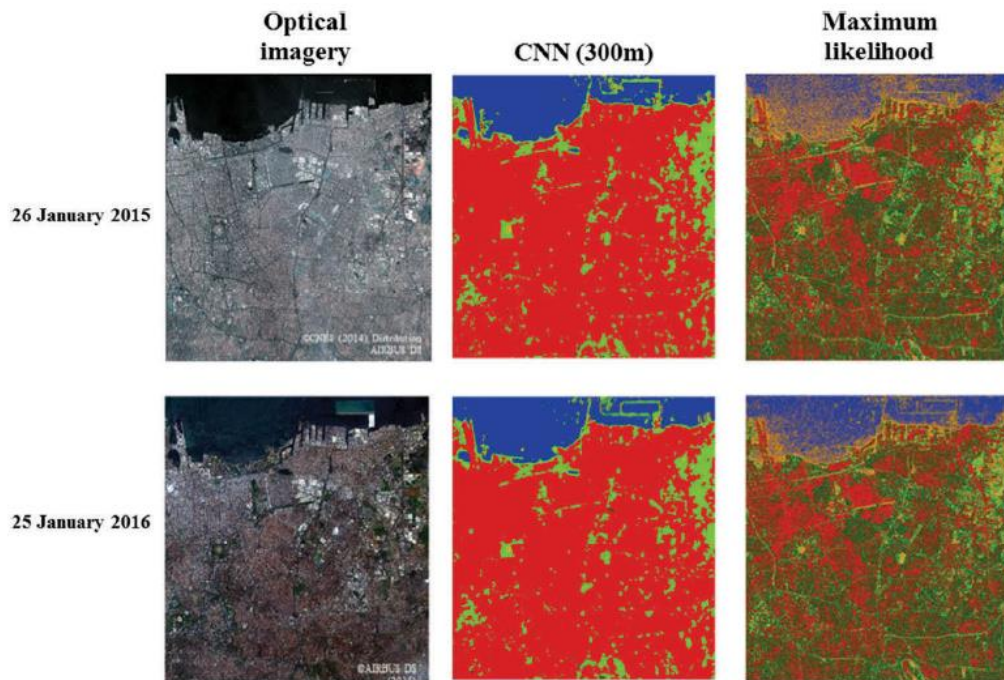


図 6.6 ジャカルタ全体の深層学習と最尤推定による推測結果の比較

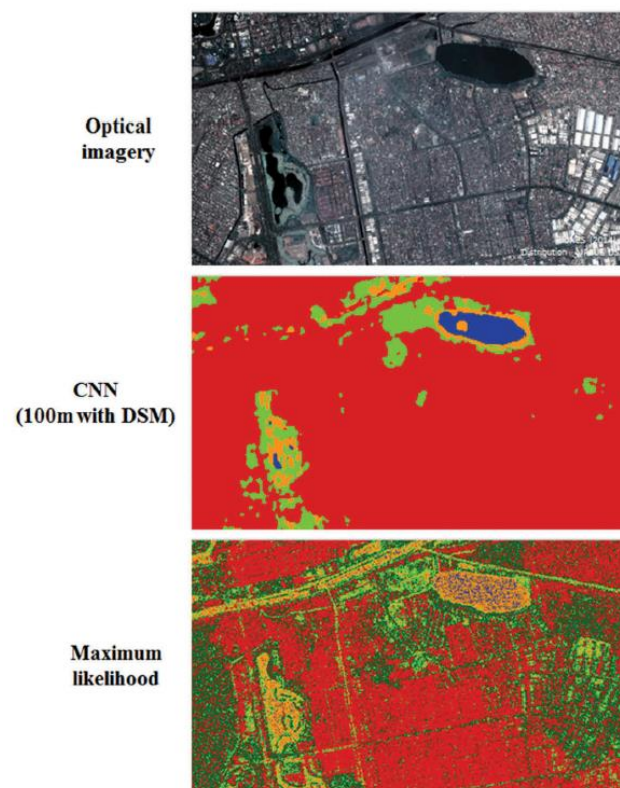


図 6.7 深層学習と最尤推定による推測結果の比較

6.10. メッシュベースでの都市的土地利用への 土地利用転換の把握

時系列の人工物の推測結果の変化分を捉えるため、QGIS を用いた 300m メッシュでの変化したピクセル値を集計した。集計結果を図 6.8 に示す。白は 0%-25%、オレンジ色は 25-50%、赤色は 50-100%の変化が推測されたメッシュである。最尤推定の結果により土地利用転換が起きていると推測されたメッシュは、深層学習の結果に比べて少ない結果となった。

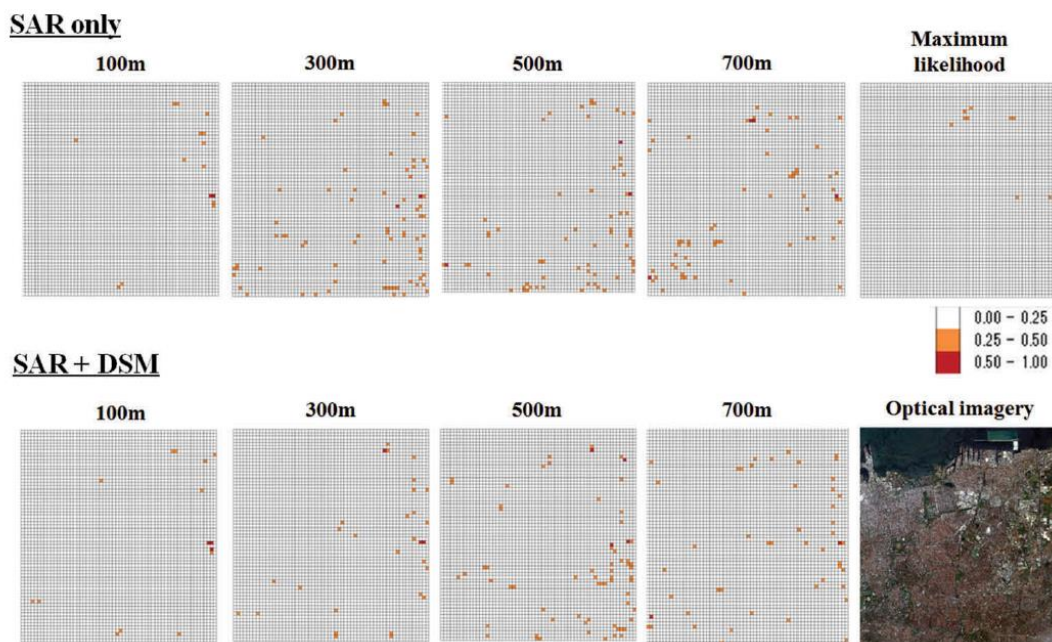


図 6.8 メッシュベースの都市の分析結果

DSM を加えた場合と加えていない場合の 100m から 700m の結果での合計 8 個のパターンでの結果において、50%以上の変化が確認されたメッシュの合計を集計した結果を図 6.9 に示す。1つのパターンのみ 50%以上の変化が確認されたメッシュは 7個、2つのパターンで確認されたメッシュは 2個、4つのパターンで確認されたメッシュは 1個、7つのパターンで確認されたメッシュは 1個という結果が得られた。これらのエリアに対して、実際に変化が起きているかを高分解の光学衛星画像で確認を行った。黒い四角で囲った箇所が都市的土地利用への土地利用転換が起きていると推測された箇所であるが、赤く囲った場所で、実際に都市的土地利用への土地利用転換が起こっていることを図 6.10, 図 6.11, 図 6.12 のように目視でも確認することができた。

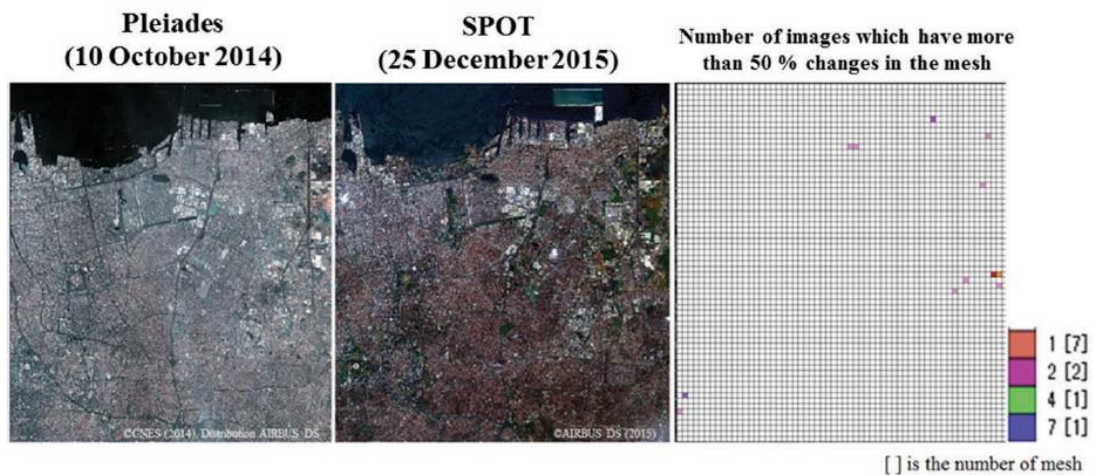


図 6.9 大きな都市的土地利用への土地利用転換が起きていると推測されるエリア

Area 1



図 6.10 実際に変化が確認できた場所 (1/3)

Area 2



Area 3



図 6.11 実際に変化が確認できた場所 (2/3)

Area 4



Area 5



Area 6



Area 7



図 6.12 実際に変化が確認できた場所 (3/3)

6.11. 深層学習モデルの再学習

4.5 章で述べた深層学習モデルの再学習の方法を用いた識別結果について、新規データ数を横軸、各クラスの F 値を縦軸に表したグラフを図 6.13 に示す。各クラス 25 枚, 50 枚, 100 枚, 200 枚で比較を行った結果, 100 枚以上のデータを用いた学習を行うことで、各クラスの平均値 95%以上を達成することができることが分かった。

この結果から、少ない新規データを使って再学習を行うことで深層学習モデルの精度を向上させることができることを確認できた。




図 6.13 再学習に必要なデータ数

6.12. 異なる周波数の衛星画像を用いた地理情報の識別

一つの衛星では撮影できるリソースも限られているため、短期間の間隔で定期的に撮影するために、異なる SAR 衛星画像を組み合わせることで地理情報を識別することが考えられる。X バンド（波長: 3.1cm）の TerraSAR-X, C バンド（波長: 5.6cm）の Sentinel-1, L バンド（波長: 24cm）の ALOS-2 [68] の 3 種類の SAR 衛星画像を用いて深層学習による地理情報の識別を行った。

一般に、短い波長の電波は物質の表面で反射しやすく、長い波長の電波は物質内部にある程度入り込む性質がある。例として森林に対して、L バンドの波長では葉を透過して幹や地表で反射、X バンドの波長では葉で反射、C バンドの波長では葉や枝で反射される [27]。イメージ図を図 6.14 に示す。それぞれの波長の SAR 衛星画像を用いて深層学習による地理情報識別の定性的評価を行った結果を図 6.15 に示す。各 SAR 衛星画像の分解能と各バンドの特徴により異なる特徴の地理情報の識別結果を得ることができた。

都市的土地利用への土地利用転換の把握にこれらの分析結果を利用するためには、識別結果の組み合わせ方等について工夫を行う必要がある。




図 6.14 バンド別の電波の反射イメージ

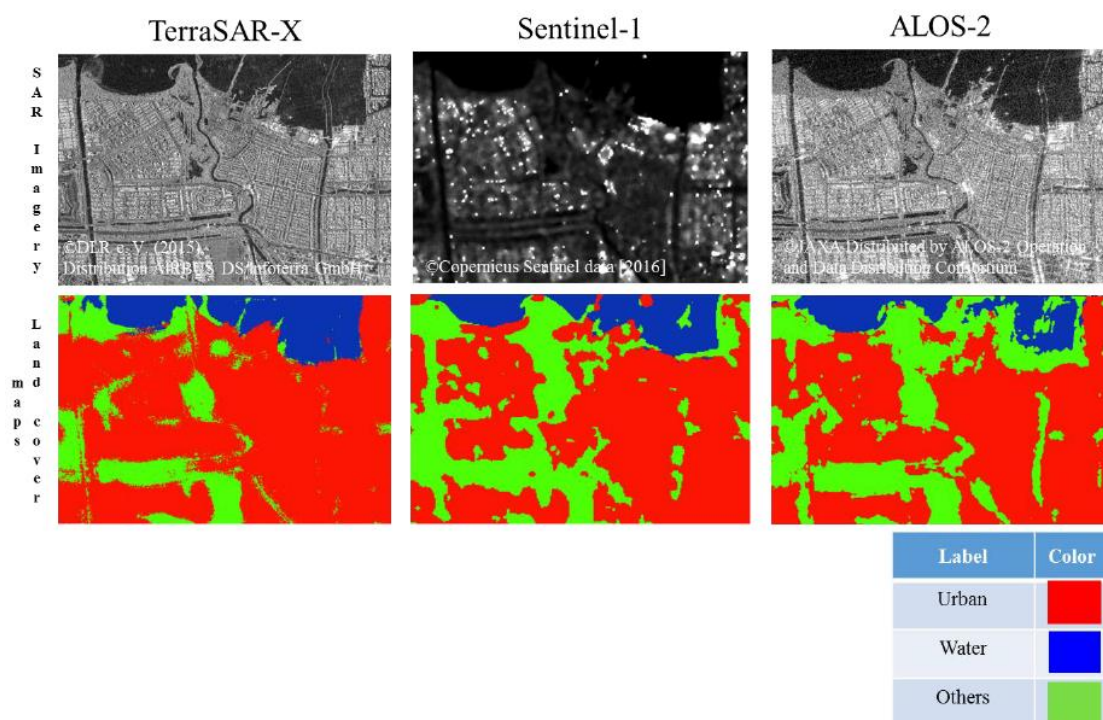


図 6.15 3 種類の SAR 衛星画像からの地理情報の識別結果の比較

6.13.6 章まとめ

本章では深層学習を用いて 2 偏波の SAR 衛星画像からの 5 種類の地理情報の識別を行い、都市的土地利用への土地利用転換の把握できるかの検証をインドネシアのジャカルタ・ベトナムのハノイの衛星画像を用いて行った。定期的な都市的土地利用への土地利用転換の把握に求められる高精度な地理情報の識別を行うため、偏波の組み合わせ、高さ情報である DSM の追加、パッチ画像のサイズの検討を行い、精度を向上させることが出来た。

今回の実験で用いた ALOS-2 の画像を用いた実験の結果では、HH, HV, HH/HV に加えて DSM を組み合わせた画像で、パッチサイズを 300m とした場合が最も高い精度で都市的土地利用を識別できることを示した。また 100 枚の新規データを用いた再学習を行うことで、各クラスの平均値 95%以上を達成することができることも示した。

最後に 3 種類の SAR 衛星画像を同一の深層学習モデルで分析できることを示し、複数の SAR 衛星画像を組み合わせたより間隔の短い都市的土地利用への土地利用転換の把握が出来る可能性を示した。

これらの結果から、2.10 章で整理した各要求を満たす形で都市的土地利用への土地利用転換の把握が行えることを示した。

第7章 光学衛星画像と SAR 衛星画像を用いた世帯数の推計

7.1. 概要

光学衛星画像から深層学習を用いた世帯数の推計を行い, SAR 衛星画像からの深層学習を用いた都市的土地利用識別結果等を用いて補正を行う手法を提案し, ジャカルタの画像データを用いた検証を行った.

7.2. インドネシアの統計データ

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都市計画等に必要最新の統計データを得ることが難しい. インドネシアのジャカルタ市の国勢調査は, 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 [69]. また図 7.1 に示すように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, 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ことが課題である.

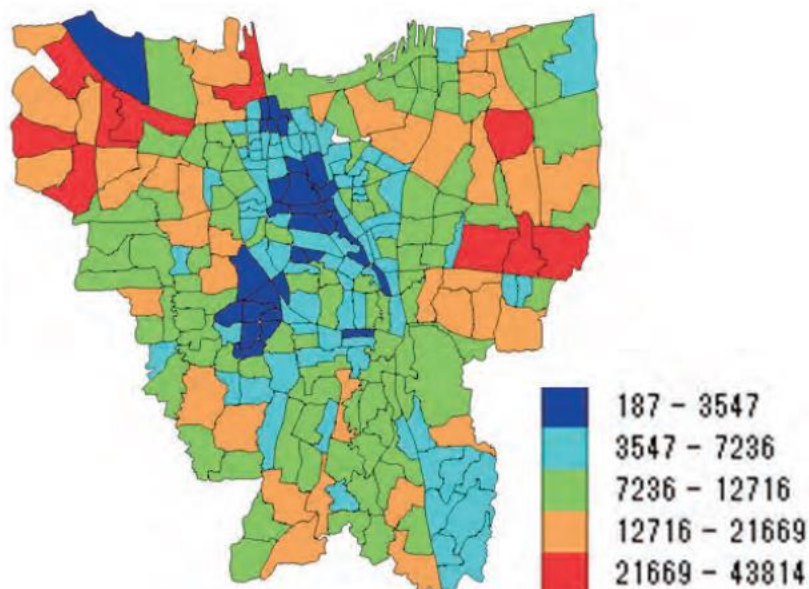


図 7.1 ジャカルタ市における 2010 年度国勢調査結果 (世帯数)

[69]のデータを基に作成

7.3. 使用したデータ

光学衛星画像は 2017 年に撮影されたジャカルタ市の SPOT 画像, SAR 衛星画像は TerraSAR-X を用いた. 衛星画像に対する建物数の教師データとしてはオープンストリートマップ (OSM) [70]の建物ポリゴン (2017 年度更新) を利用した. また居住地エリアを補正するためのデータとして土地利用状況を示したゾーンマップ・Google map の建物名称などを利用した.

7.4. 関連研究

Bast らは, OpenGeoDB のセンサス統計データと OSM の建物ポリゴン・Point of Interest (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の人口推定を行った [71].

Robinson らは, 光学衛星画像から CNN を用いて 74x74 の画像パッチ毎に人口と画像の関係性を 17 クラスで学習し, 異なる時期の光学衛星画像から画像パッチ毎に 17 クラスの分類を行い, 人口を推定する方法を提案したが [72], ノイズデータによりパッチ画像によりエラーが大きくなったり, 新しく出来た建物が学習したデータと異なる特徴を持っている場合に精度が低くなったりする等の課題があった.

7.5. 世帯数・人口推計の全体フロー

深層学習の教師データのラベルとして 5 章と 6 章で利用していたクラスの値の代わりに建物数を与えて学習・推測を行うことで, 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建物数の推計を行う.

推計を行った結果に対して, 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, 推計結果の高精度化を行った. 提案手法の全体フローを図 7.2 に示す.

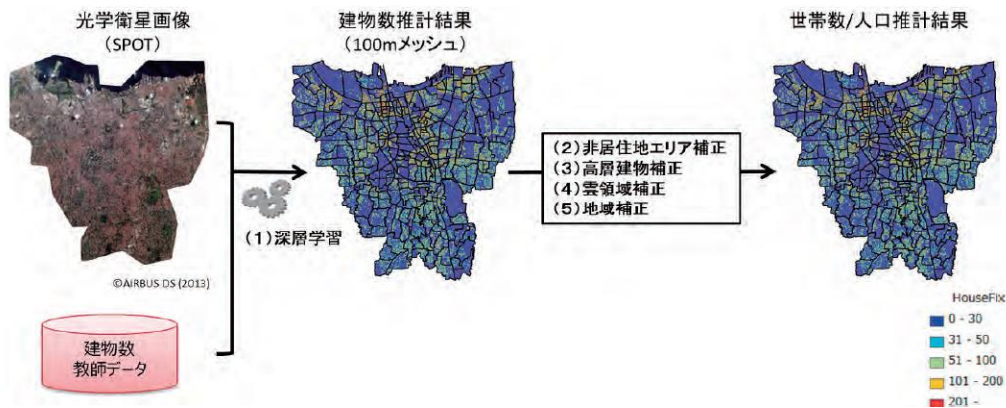


図 7.2 世帯数・人口推計の全体フロー

世帯数・人口推計の全体フローは、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

7.6. 建物数推定の教師データ作成

本研究では、建物の形状はある程度判別できる 1.5m 分解能のジャカルタ市全域を 2017 年度に撮影した SPOT 衛星画像を用いた。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。建物数のカウントは建物の大きさによらず、各建物の中心点のみを用いて行った。建物の面積や階数による世帯数の補正については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ない。例えば図 7.3 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 つのポリゴンにまとめられている、または抽出漏れがあるなど、建物ポリゴンが衛星画像にそくしていない地域が多く存在する。



図 7.3 SPOT 衛星画像および OSM の建物ポリゴンの例

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

7.7. 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 7.4 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 メッシュのパッチ画像、出力は入力されたパッチ画像内に含まれる建物数の推計値とした。

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。畳み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、回帰を行った。学習時における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二乗誤差関数を用いた。




図 7.4 世帯数推計のための深層学習のモデル

7.8. 建物数推定結果の補正

推定した建物数推計結果の改善を行うための方法として以下4つの補正を行った。

1. 非居住地エリアマップを作成し補正。詳細については、7.8.1 で述べる。
2. 高層マンションの POI と重なったメッシュの世帯数に対して、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）で算出した高層マンション世帯数補正マップを作成して補正
3. 雲がかかっている地域に対して、雲および雲の影がかかる地域は OSM の建物ポリゴン数を基に、時点の近い他の衛星画像もしくは航空写真と OSM のポリゴンを比較することで補正
4. 建物数が異常値を示すメッシュに対しては、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することで補正

7.8.1. 非居住地マップの作成

推定した建物数推計結果を補正するために用いる非居住地マップ作成のフローを図 7.5 に示す。また SAR 衛星画像からの人工物の抽出結果を図 7.6 に示す。

光学衛星画像と Google Map の建物名称とジャカルタの自治体が公開しているゾーンマップを参考に居住地でないエリアを識別し、非居住地マップを作成した。また、SAR 衛星画像から深層学習により識別した人工物結果を利用して非居住地エリアを作成し、非居住地マップにマージした。

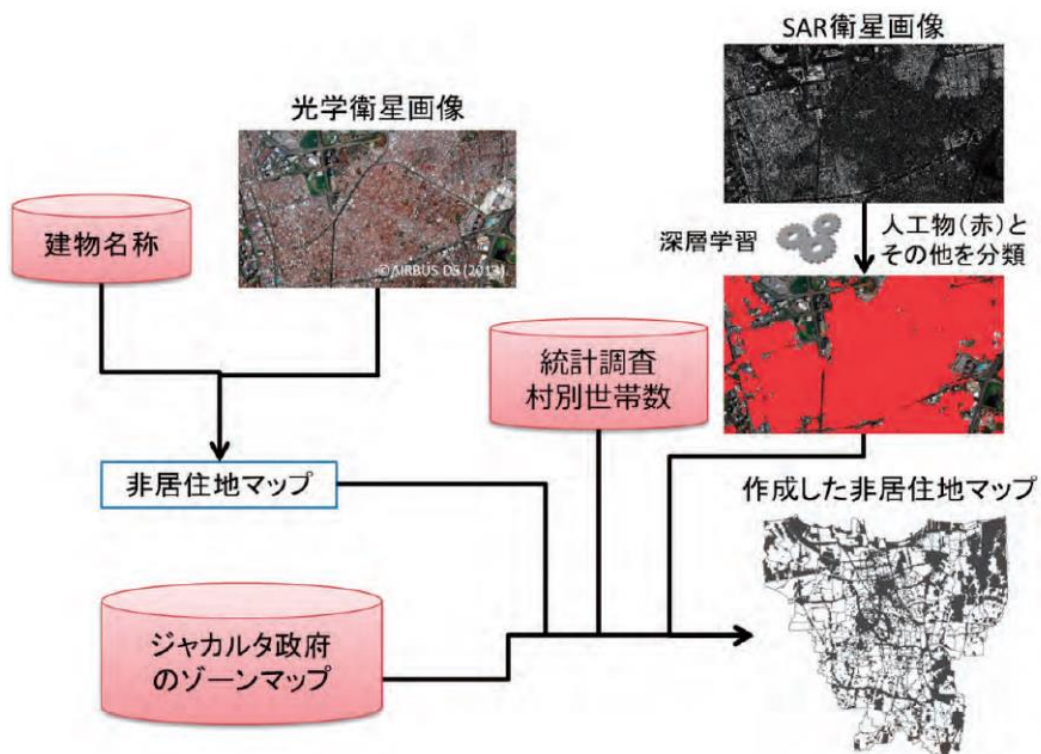


図 7.5 非居住地マップ作成のフロー

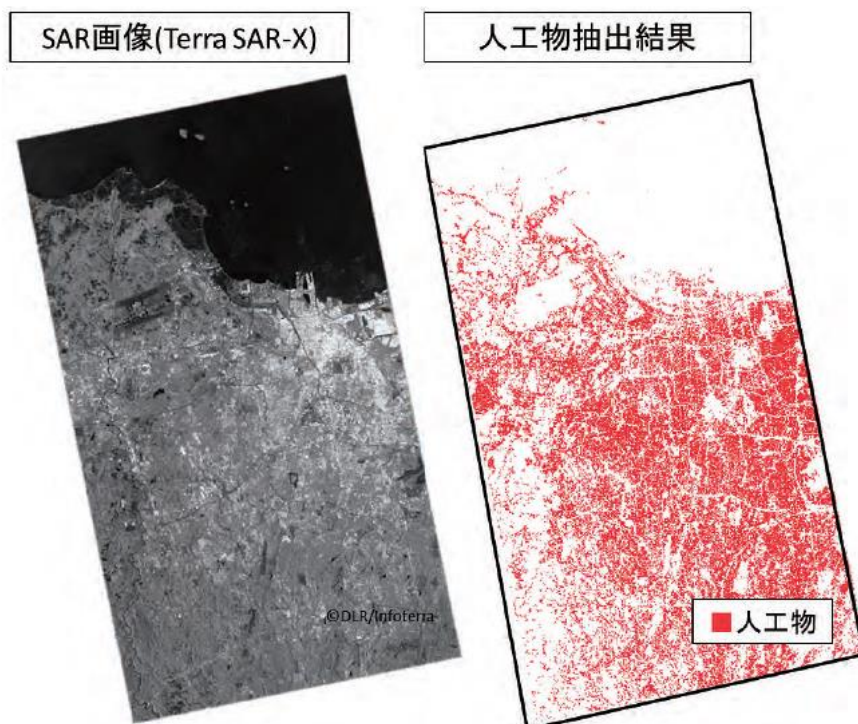


図 7.6 SAR 衛星画像からの人工物の抽出結果

各補正後の 100m メッシュごとの 2017 年の世帯数の推計結果を図 7.7 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.

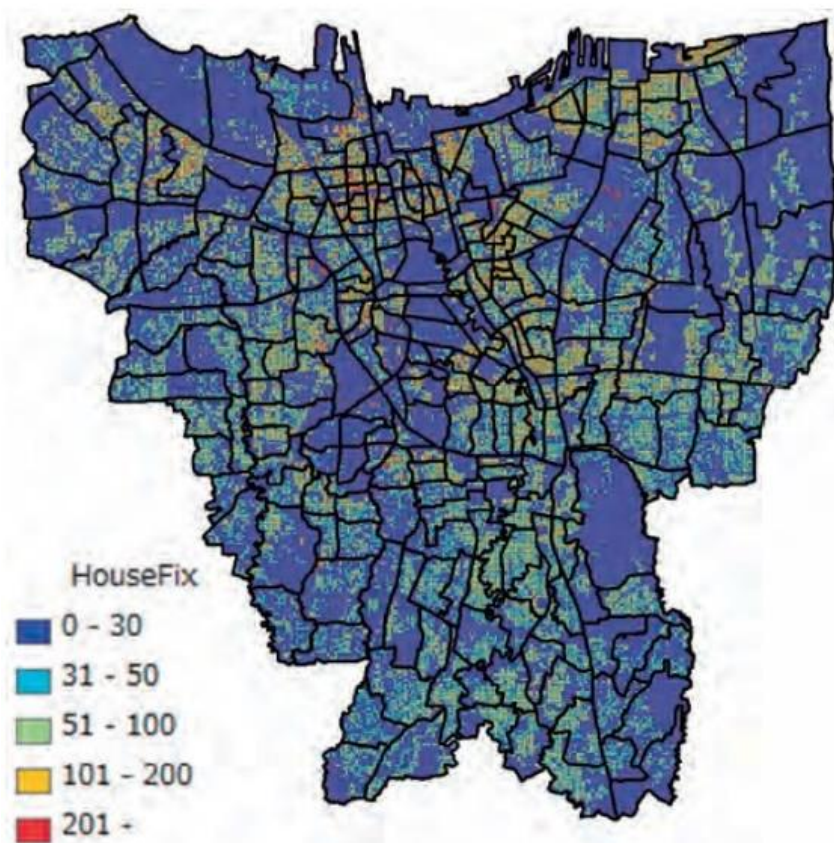


図 7.7 世帯数の推定結果

推計した世帯数の評価を行うため, 現地の 2010 年の国勢調査のデータを用いて乖離度を算出した評価結果を図 7.8 に示す.世帯数の推計結果と国勢調査のデータが極端に異なった村は 3 個のみであり, その他の村では, 高い精度で推計することができたと言える.

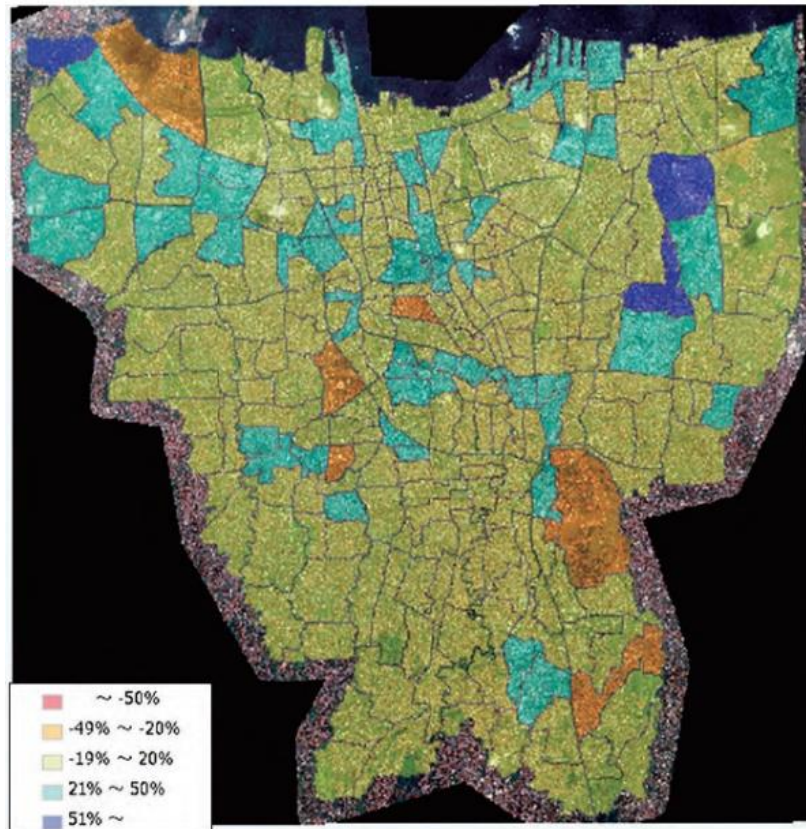


図 7.8 推計世帯数と 2010 年の統計データとの乖離

7.9. 考察

国勢調査データは 2010 年であり、本手法による推定結果は 2017 年を対象としているため、実際の乖離度は今回の評価結果よりも改善することが期待される。

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。インドネシアでは超高密集地から 1000m²以上のスペースの家まで居住地の特性に大きな開きがある。建物は、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建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と考えられる。推計した世帯数と国勢調査のデータが極端に異なった 3 個の村については、高層マンションなどは確認できなかったため、特殊な住居の状況であることが考えられる。

7.10. 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たものである。

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。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ことで精度を上げることができると考えられる。

7.11.7 章まとめ

本章では OSM の建物ポリゴンを修正・加工したデータを教師データとして、光学衛星画像からの深層学習による建物数・世帯数を推計し、様々な補正を行うことで世帯数推計の精度を上げる手法について提案を行い、ジャカルタのデータを用いた検証を行った。

実験の結果から、2.10 章で整理した要求に対して、一部の特殊な住居状況の地域を除き、タウンシップグループ毎(地区毎)の世帯数や人口を、都市全域で均一の質で推計できることを明らかにした。

第8章 結論

8.1. まとめ

本論文では、1 偏波と 2 偏波の SAR 衛星画像からの深層学習を用いた地理情報の識別を行うための手法、精度向上を行うための手法について提案し、高精度での都市的土地利用への土地利用転換の把握に寄与することを示した。また光学衛星画像と SAR 衛星画像を組み合わせて世帯数の推計にも応用できることを示した。本論文で提案した手法は都市的土地利用への土地利用転換の把握や世帯数の推計だけでなく、自然的土地利用把握や違法開発等の様々な用途に応用できると考えられる。

本研究の以下 3 つの課題に対応した要求に対する検証結果を表 8.1 に示す。

1. 都市把握に必要な精度・頻度・観測範囲のデータが限られる
2. 得られた画像情報から地理情報を識別できない
3. 地理情報から都市的土地利用への土地利用転換の把握を行うことができない

本研究のリサーチクエスチョンである「衛星画像により得られる画像情報と都市的土地利用への土地利用転換を把握するための情報の関係とは何か」に対しては以下が明らかになった。

- ・ SAR 衛星画像により得られる画像情報は、適切な領域に分割し、土地利用現況図での用途区分に準ずる 5 分類のクラスとして、都市的土地利用への土地利用転換の把握のための情報を得ることができる
- ・ さらに、高さ情報や細部特徴強調（複数偏波画像）を活用することで、その情報の質を向上させることができる

表 8.1 各要求に対する検証結果

No	ステークホルダー	ユースケース	解析・検証結果
1	自治体 (国内)	都市計画区域 外の土地利用 の把握	本論文では、日本の SAR 衛星画像を用いた検証は行っていないが、海外の SAR 衛星画像を用いて、大規模な都市的土地利用への土地利用転換が行われた場所を数百メートル程度の分解能で捉えられることを示した
2	JICA 調査団 等の開発 支援組織	土地利用の 地図の 定期的な更新	土地利用を抽出、市街地変化の把握ができるような数百メートル程度の分解能で、目視の結果と大きく変わらない精度で、数か月～1 年毎に都市全域に対して分析を行えることができた
3		市街地変化の 把握	
4		人口/世帯数の 推計	

8.2. 本研究の学術的意義

本研究の学術的意義としては、時系列の 1 偏波、2 偏波の SAR 衛星画像を用いて、深層学習を用いた都市的土地利用への土地利用転換の把握を行うという新しい使い方を示したことと SAR 衛星画像と DSM を組み合わせて、深層学習により地理情報を識別する方法を示し、検証により有効性を示したということである [73] [74] [75].

8.3. 本研究の貢献

SAR 衛星画像を利用した土地利用の把握については、天候の影響を受けないことから活用が期待されているが、光学画像に比べて視覚的に地理情報の識別が難しく、専門的な知識が必要であるためなかなか普及が進んでいない。

本研究で提案する手法を用いることで、一部のエリアのみに対して専門家が地理情報の識別を行うだけで、画像全体に対して地理情報の自動識別が可能になる。新しい地域の衛星画像に対しても、少量のデータを用いた深層学習の再学習を行うことで、精度良く地理情報の識別を行うことが可能となる。この手法を用いて全世界の主要都市の衛星画像に対して分析を行う事で、世界レベルでの都市的土地利用への土地利用転換の把握を定期的に行うことが出来るようになる。

また都市的土地利用への土地利用転換の把握のみでなく、深層学習を用いて人口や世帯数の推定を行う事ができるので、世界中の人口・世帯数を統一した基準で、定期的に（最短で2週間毎）把握することができるようになる。

6.12 章で試行した複数の種類の SAR 衛星画像を用いた分析が出来るようになると、さらに短い間隔で変化を把握することができるようになり、数日毎の変化を把握することが出来るようになる。

謝辞

本論文は、筆者が株式会社パスコ衛星事業部在籍時に行った研究を基に、筑波大学大学院システム情報工学研究系知能機能システム学位プログラム専攻博士後期課程における研究成果をまとめたものです。

最初に本論文をまとめるにあたり多大なご指導を賜りました筑波大学システム情報系鈴木健嗣教授に心から感謝申し上げます。

副査として、貴重なご助言をいただきました筑波大学計算科学研究センター北原格教授、システム情報系黒田嘉宏教授、谷口守教授、延原肇准教授に感謝いたします。

株式会社パスコにおいて、共同で研究を行っていただいた皆さまに感謝いたします。

また私の社会人博士進学を認めていただいた現職場である有人宇宙システム株式会社の皆様に感謝いたします。

そして研究遂行に際して数々の刺激を頂きました筑波大学システム情報工学研究科人工知能研究室の皆さまに感謝いたします。

最後に、私の博士課程進学をご支援いただいた家族に感謝いたします。

参考文献

- [1] 国土交通省, “都市計画法,” 4 2006. [オンライン]. Available: <https://www.mlit.go.jp/common/000029198.pdf>. [アクセス日: 13 2 2021].
- [2] 国土交通省都市局, “都市計画基礎調査実施要領,” 3 2019. [オンライン]. Available: 都市計画基礎調査実施要領. [アクセス日: 30 12 2020].
- [3] 国土交通省, “市街化区域と市街化調整区域〔区域区分〕,” [オンライン]. Available: <https://www.mlit.go.jp/common/000234475.pdf>. [アクセス日: 13 2 2021].
- [4] 櫻井 祐次., et al, “都市計画マスタープランにおける白地及び都市計画区域外の土地利用方針に関する基礎的研究,” *都市計画論文集*, 第 35, pp. 205-210, 2000.
- [5] 改訂農村計画学編集委員会, 改訂農村計画学, 農業土木学会, 2003.
- [6] 国土交通省, “都市白書,” 6 2020. [オンライン]. Available: <https://www.mlit.go.jp/statistics/file000006.html>. [アクセス日: 13 2 2021].
- [7] 独立行政法人 国際協力機構 経済基盤開発部, “都市開発分野の協力,” 独立行政法人 国際協力機構, 2013.
- [8] ESCH, Thomas, et al., “Breaking new ground in mapping human settlements from space, The Global Urban Footprint,” *ISPRS Journal of Photogrammetry and Remote Sensing*, 第 巻 134, pp. 30-42, 2017.
- [9] 和多治, “白地地域・都市計画区域外における小規模開発のコントロールに関する研究 1992 年都市計画法・建築基準法改正に伴う形態制限の適用事例を中心に,” *都市計画論文集*, 第 33, pp. 517-522, 1998.
- [10] 八木洋憲, 土地利用計画論, 養賢堂, 2005.
- [11] United Nations, Department of Economic and Social Affairs, Population Division, "World Population Prospects 2019: Data Booket," no. ST/ESA/SER.A/424., 2019.
- [12] GRI, United Nations, wbcasd, “SDG Compass,” 2015. [オンライン]. Available: <https://sdgcompass.org/>. [アクセス日: 30 12 2020].
- [13] 荒 仁, “インフラ（都市開発・経済回廊）,” 27 2 2019. [オンライン]. Available: https://www.jica.go.jp/aboutoda/sdgs/news/ku57pq00002jdrb9-att/20190313_08.pdf. [アクセス日: 30 12 2020].
- [14] 鈴木 和哉, “JICA 事業における人工衛星利用と今後への期待,” 27 2 2012. [オンライン]. Available: https://www.satnavi.jaxa.jp/news/event/pdf/121018_doc_03.pdf. [アクセス

日: 30 12 2020].

- [15] 一般財団法人宇宙システム開発利用推進機構, “平成 29 年度新興国市場開拓事業 (【アジア】 リモートセンシング衛星の利用可能性調査及びリモートセンシング衛星利用による課題解決のための政策対話) 報告書,” 2 2018. [オンライン]. Available: https://www.meti.go.jp/meti_lib/report/H29FY/000709.pdf. [アクセス日: 30 12 2020].
- [16] 独立行政法人 国際協力機構 (JICA), “ミャンマー国ヤンゴン都市圏開発プログラム形成準備調査ファイナルレポート,” 4 2013. [オンライン]. Available: https://openjicareport.jica.go.jp/618/618/618_104_12122503.html. [アクセス日: 30 12 2020].
- [17] D. Engelke, D. Biehl, “Land Use Management as Key Part of Metropolitan Governance for Sustainable Urbanisation,” 46th ISOCARP Congress, 2010.
- [18] U.S. Geological Survey, “Earth observation satellites (ver. 1.2, April 2020): U.S. Geological Survey Fact Sheet 2015-3081,” 2016. [オンライン]. Available: https://pubs.usgs.gov/fs/2015/3081/fs20153081_ver1.2.pdf. [アクセス日: 30 12 2020].
- [19] Norzailawati Mohd Noor, et al, "Remote sensing UAV/drones and its applications for urban areas: a review," *IOP Conference Series: Earth and Environmental Science*, no. 169, 2018.
- [20] The World Bank, “JAKARTA Urban Challenges in a Changing Climate,” 2010. [オンライン]. Available: <http://documents1.worldbank.org/curated/en/132781468039870805/pdf/650180WP0Box360ange0Jakarta0English.pdf>. [アクセス日: 30 12 2020].
- [21] Alessandro Matese, et al, “Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture,” *MDPI*, 2015.
- [22] 林野庁, “令和元年度山地保全調査 (新たな治山・地すべり対策計画手法検討調査) 委託事業報告書(概要版),” 3 2020. [オンライン]. Available: https://www.maff.go.jp/j/budget/yosan_kansi/sikkou/tokutei_keihi/R1itaku/R1ippan/attach/pdf/index-248.pdf. [アクセス日: 30 12 2020].
- [23] ESA, “Satellite Missions Database,” 2021. [オンライン]. Available: <https://directory.eoportal.org/web/eoportal/satellite-missions>. [アクセス日: 30 12 2020].
- [24] Candiago Sebastian, et al, "Evaluating multispectral images and vegetation indices for precision farming applications from UAV images," *Remote sensing*, vol. 7.4, pp. 4026-4047, 2015.
- [25] B. Bansod, "A comparison between satellite based and drone based remote sensing technology to achieve sustainable development: a review," *Journal of Agriculture and Environment for International Development (JAEID)*, vol. 111, no. 2, pp. 383-407, 2017.
- [26] 秋山侃, “農業生態系研究におけるリモートセンシング利用の概論,” 6 11 2006. [オ

- ンライン]. Available:
http://www.naro.affrc.go.jp/archive/niaes/techdoc/inovlec2006/1_akiyama.pdf. [アクセス日:
 30 12 2020].
- [27] 水野正樹., et al, “単偏波の高分解能 SAR 画像による河道閉塞箇所判読調査手法
 (案),” 11 2013. [オンライン]. Available:
<http://www.nilim.go.jp/lab/bcg/siryounn/tnn/tnn0760.htm>. [アクセス日: 31 12 2020].
- [28] LeCun, Yann., et al, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, 1998.
- [29] Alex Krizhevsky., et al, “Imagenet classification with deep convolutional neural networks,” *Advances in neural information processing systems*, 2012.
- [30] Russakovsky Olga, et al, "Imagenet large scale visual recognition challenge," *International journal of computer vision*, vol. 115, no. 3, pp. 211-252, 2015.
- [31] Krylov Vladimir A., et al, “Large urban zone classification on SPOT-5 imagery with convolutional neural networks,” 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). IEEE, 2016.
- [32] Huang Xin., et al, "Classification and extraction of spatial features in urban areas using high-resolution multispectral imagery," *IEEE Geoscience and Remote Sensing Letters*, vol. 4, no. 2, pp. 260-264, 2007.
- [33] Pacifici F., et al, "A Neural Network Approach Using Multi-scale Textural Metrics from Very High-resolution Panchromatic Imagery for Urban Land-use classification," *Remote Sensing of Environment*, vol. 113, no. 6, pp. 1276-1292, 2009.
- [34] Lagkvist, M., et al, "Classification and segmentation of Satellite Orthoimagery Using Convolutional Neural Networks," *Remote Sensing*, vol. 8, no. 4, pp. 329-, 2016.
- [35] Riho Ito, et al.,, “Assessing the Land Cover Classification Technique of the Satellite Imagery Using Deep Learning,” The 30th Annual Conference of the Japanese Society for Artificial Intelligence 4L1-1, 2016.
- [36] Lv, Q., et al, “Urban land use and land cover classification using remotely sensed SAR data through deep belief networks,” *Journal of Sensors*, 2015.
- [37] Gao, F., et al, "Dual-branch deep convolution neural network for polarimetric SAR image classification," *Applied Sciences*, vol. 7, no. 5, p. 447, 2017.
- [38] Zhang, Z., et al, “Complex-valued convolutional neural network and its application in polarimetric SAR image classification,” *IEEE Transactions on Geoscience and Remote Sensing*, 第 卷 55, 第 12, p. 7177-7188, 2017.
- [39] Chen, W., et al, "Classification of PolSAR images using multilayer autoencoders and a

- selfpaced learning approach," *Remote Sensing*, vol. 10, no. 1, p. 110, 2018.
- [40] Wang, L., et al, "Multi-pixel simultaneous classification of PolSAR image using convolutional neural networks," *Sensors*, vol. 18, no. 3, p. 769, 2018.
- [41] Li, J., et al, "Multiscale convolutional neural network for The detection of built-up areas in high-resolution sar images," *IEEE International Geoscience and remote sensing symposium (IGARSS)*, 2016.
- [42] Xu, Z., et al, "Building extraction from high-resolution SAR imagery based on deep neural networks," *Remote Sensing Letters*, vol. 8, no. 9, p. 888–896, 2017.
- [43] Gong, M., et al, "Feature learning and change feature classification based on deep learning for ternary change detection in SAR images," *ISPRS Journal of Photogrammetry and Remote Sensing*, no. 129, p. 212–225, 2017.
- [44] Quantum GIS Development Team, "Quantum GIS geographic information system," *Open Source Geospatial Foundation Project*, 2012.
- [45] Tucker, Compton J., et al, "Red and Photographic Infrared Linear Combinations for Monitoring Vegetation," *Remote Sensing of Environment*, vol. 8, no. 2, pp. 127-150, 1979.
- [46] Morin, F., et al, "Hierarchical probabilistic neural network language model," *Aistats*, 2005.
- [47] Snoek, Jasper., et al, "Practical bayesian optimization of machine learning algorithms," *Advances in neural information processing systems*, 2012.
- [48] Szegedy, Christian., et al, "Going deeper with convolutions," *Proc. of CVPR*, 2015.
- [49] He, Kaiming, et al, "Deep residual learning for image recognition," *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016.
- [50] Mohamed, Abdel-rahman., et al, "Deep belief networks for phone recognition," *Nips workshop on deep learning for speech recognition and related applications*, 2009.
- [51] Mohamed, Abdel-rahman., et al, "Investigation of full-sequence training of deep belief networks for speech recognition," *Eleventh Annual Conference of the International Speech Communication Association*, 2010.
- [52] Abdikan, Saygin, et al, "Land cover mapping using SENTINEL-1 SAR data. The International Archives of the Photogrammetry," *Remote Sensing and Spatial Information Sciences, Volume XLI-B7, 2016 AQ3 XXIII ISPRS Congress*, 2016.
- [53] Suess, M, et al, "TerraSAR-X-design and performance," *Proc. EUSAR*, no. 2, pp. 49-52, 2002.
- [54] Gleyzes, M. Alain, "Pleiades system architecture and main performances," *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 39, no. 1, pp. 537-542, 2012.

- [55] POWERS, D.M.W, "Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation," arXiv preprint, 2020.
- [56] Drusch, Matthias, et al, "Sentinel-2: ESA's optical high-resolution mission for GMES operational services," *Remote sensing of Environment*, no. 120, pp. 25-36, 2012.
- [57] C. BUSCHMANN, et al, "In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation," *International Journal of Remote Sensing*, vol. 14, no. 4, pp. 711-722, 1993.
- [58] S. K. e. a. McFeeters, "The Use of the Normalized Difference Water Index (NDWI) in the Delineation of Open Water Features," *International Journal of Remote Sensing*, vol. 17, no. 7, pp. 1425-1432, 1996.
- [59] Mhangara, Paidamwoyo, et al, "Road extraction using object oriented classification," Visualisation Technical, 2011.
- [60] P. Campenon, "Pleiades and SPOT-6: Earth observation in high and very high resolution," Proceedings of the 60th IAC (International Astronautical Congress), 2009.
- [61] Tian, Jiaojiao, et al, "Building change detection based on satellite stereo imagery and digital surface models," *IEEE Transactions on Geoscience and Remote Sensing*, 第 卷 52, 第 1, pp. 406-417, 2013.
- [62] T. Tadono, et al, "Precise Global DEM Generation By ALOS PRISM," *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 2, no. 4, pp. 71-76, 2014.
- [63] Toutin, Thierry, et al, "State-of-the-art of elevation extraction from satellite SAR data," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 55, no. 1, pp. 13-33, 2000.
- [64] P. e. a. Capaldo, "High-resolution SAR radargrammetry: A first application with COSMO-SkyMed spotlight imagery," *IEEE Geoscience and Remote Sensing Letters*, 第 卷 8, 第 6, pp. 1100-1104, 2011.
- [65] Akgün, Aykut, et al, "Comparing different satellite image classification methods: An application in Ayvalik District, Western Turkey," The 4th International Congress for Photogrammetry and Remote Sensing, 2004.
- [66] Subhash, T, et al, "Comparison of Different Image Classification Techniques for Land Use Land Cover Classification: An Application in Jabalpur District of Central India," *International Journal of Remote Sensing and GIS*, vol. 1, no. 1, pp. 26-31, 2012.
- [67] Environmental Systems Research Institute (ESRI), "ArcGIS Release 10.3," 2015.
- [68] 宇宙航空研究開発機構, "陸域観測技術衛星 2 号「だいち 2 号」," 宇宙航空研究開発機構, <https://www.jaxa.jp/projects/pr/brochure/pdf/04/sat29.pdf>.

-
- [69] Badan Pusat Statistik, “Sensus Penduduk 2010,” 2010. [オンライン]. Available: <https://sp2010.bps.go.id/>. [アクセス日: 21 2021].
- [70] Jokar Arsanjani, J, et al, “An introduction to OpenStreetMap in Geographic Information Science: Experiences, research, and applications,” *OpenStreetMap in GIScience*. Springer, Cham, 2015.
- [71] Bast, H, et al, “Fine-grained population estimation,” *Proceedings of the 23rd SIGSPATIAL International Conference on Advances in Geographic Information Systems*, 2015.
- [72] Robinson, Caleb, et al, “A deep learning approach for population estimation from satellite imagery,” *Proceedings of the 1st ACM SIGSPATIAL Workshop on Geospatial Humanities*, 2017.
- [73] Agrawal, S, et al, “A Comparative Assessment of Remote Sensing Imaging Techniques: Optical, SAR and LIDAR,” *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2019.
- [74] Shi, W, et al, "Change Detection Based on Artificial Intelligence: State-of-the-Art and Challenges," *Remote Sensing*, vol. 12, no. 10, p. 1688, 2020.
- [75] You, Y, et al, "A Survey of Change Detection Methods Based on Remote Sensing Images for Multi-Source and Multi-Objective Scenarios," *Remote Sensing*, vol. 12, no. 15, p. 2460, 2020.

研究実績

【本論文に関連する実績】

査読付き学術雑誌論文

1. Iino, Shota, et al. “CNN-based generation of high-accuracy urban distribution maps utilising SAR satellite imagery for short-term change monitoring” International Journal of Image and Data Fusion 9.4 (2018): 302-318.
2. Iino, Shota, et al. “Urban Change Monitoring in Developing Countries Based on Deep Learning Technique by Utilizing Time Series Imageries of the SAR and Optical Satellites” Transactions of the Japan society for Aeronautical and space sciences, Aerospace Technology Japan, 16.1 (2018): 40-46.

査読付き国際会議論文

1. Iino, Shota, et al. “Generating high-accuracy urban distribution map for short-term change monitoring based on convolutional neural network by utilizing SAR imagery” SPIE Remote Sensing (2017)
2. Iino, Shota, et al. “Urban Change Monitoring in Developing Countries Based on Deep Learning Technique by Utilizing Time Series Imageries of the SAR and Optical Satellites” 31st International Symposium on Space Technology and Science (ISTS) (2017)

国内学会

1. 飯野翔太 et al. “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)” 第 40 回測量調査技術発表会 (2018)
2. 伊東里保 , 飯野翔太 , et al. “ディープラーニングを適用した衛星画像からの土地被覆分類手法の評価” 人工知能学会全国大会論文集 第 30 回全国大会 (2016) (pp. 4L11-4L11). 一般社団法人 人工知能学会. (共著)

刊行物

1. 伊東里保 , 原香代 , 飯野翔太 et al. 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) , 先端測量技術 No.111 2018 年 11 月, 111-02

出願特許

1. 土地被覆学習データ生成装置, 土地被覆学習データ, 土地被覆分類予測装置及び土地被覆学習データ生成プログラム
2. 人口統計データ作成装置及び人口統計データ作成プログラム

受賞等

2019 年第 41 回測量調査技術発表会 優秀技術論文奨励賞 (共著)

【本論文に関連するもの以外の主な実績】

査読付き学術雑誌論文

1. D.Iwaizumi, S.Iino, et al. "Improvement of Reception and Transmission Performance on Early Warning System for Multi country with QZSS Augmentation Signal" Journal of Disaster Research 10(2) (2015): 373-385.
2. 岩泉大介, 石田剛郎, 飯野翔太, et al. "準天頂衛星補強信号を利用した防災情報配信システムの受信性・行動誘発性・エリア配信性のユーザー評価" 地域安全学会論文集 No.24, (2014)
3. 岩泉大介, 石田剛郎, 平田大輔, 飯野翔太, et al. "準天頂衛星補強信号を利用した広域防災情報配信手法の設計と情報情報伝達性の評価" 電子情報通信学会論文誌 B vol.J97-B No.11,(2014)

査読付き国際会議論文

1. S.Iino, et al. "Design of GNSS-Based Multi-Hazard Early Warning System for Multiple Countries: Case of Tsunamis and Bushfires in Asia and Oceania Regions" 31st International Symposium on Space Technology and Science (ISTS) (2017)
2. S.Iino, et al. "EU-Japan Collaborative Research for Designing Emergency Message Services utilizing EGNOS and QZSS" European Navigation Conference (2014)
3. R.Ito, S.Iino, S.Hikosaka "Change detection of land use from pairs of satellite images via Convolutional neural network" Asian Conference on Remote Sensing (2019)
4. D.Iwaizumi, S.Iino, N.Kohtake, Improvement of Reachability and Promptness of an Augmentation-Signal-Based Early Warning System Using Multiple Satellites of the QZSS Constellation" International Conference on Future Computational Technologies (2015)
5. K.Tanaka, D.Nakajima, S.Iino et al. "Trade Study of Spacecraft Design for Manned Mars Flyby" 30th International Symposium on Space Technology and Science (2015)
6. E.Moriyama, R.Moroshima, S.Ohura, T.Hirosaki, T.Yamashita, S.Iino et al. "New ECLSS Simulation Software and Its emonstration by Manned Mars Missions, 45th International Conference on Environmental Systems" ICES-2015-157, pp. 1-20 (2015)
7. D.Iwaizumi, T.Ishida, S.Iino et al. "GNSS-based Emergency Message Service : Lessons learned and Future Prospects" 7th Advanced Satellite Multimedia Systems Conference 13th Signal Processing for Space Communications Workshop (2014)

国内学会

1. 飯野翔太 et al.“機械学習を用いた国際宇宙ステーションシステム機器の異常予兆検知,
第 64 回宇宙科学技術連合講演会 (2020)
2. 野本秀樹, 道浦康貴, 飯野翔太, FRAM/SpecTRM によるブラックボックス型人工知能
システムの安全性検証, 第 10 回横幹連合コンファレンス (2019)
3. 飯野翔太 et al. “インスピレーションマーズ学生国際ミッション設計コンテストでの有
人火星ミッション設計” 第 58 回宇宙科学技術連合講演会講演集, JSASS-2014-4405,
pp.1-2 (2014)

受賞等

1. 2015 年 慶應義塾大学 塾長奨励賞 (受領代表)
2. 2015 年 G-SPASE Outstanding Contribution
3. 2014 年 International Inspiration Mars Student Design Competition 最優秀賞
(チームリーダー)
4. 2014 G-SPASE Award Best Performance
5. 2013 慶應義塾大学システムデザインマネジメント研究科 デザインプロジェクト
最優秀チーム
6. 2005 University of Western Sydney, College of Science Dean's Merit List