

AI と衛星画像を用いた土砂災害警戒区域における土地利用変化の抽出

株式会社ティコク ○菱川 拓海、はぜ 峰生、若園 陽司、山口 善臣

岐阜大学 工学部 加藤 邦人

1. はじめに

平成 13 年 4 月より土砂災害防止法が施行され、全国で基礎調査として土砂災害のおそれがある土地の調査や、土砂災害警戒区域の指定・周知が実施されてきた。同法第四条より、概ね 5 年ごとに基礎調査を行うこととされている。

しかし、法律の施行から 20 年以上経過している現在も土砂災害危険箇所以外の箇所に対して基礎調査が行われており、多くの自治体で、指定から既に 5 年以上経過している土砂災害警戒区域の再調査の実施が課題となっている。

今後は指定済区域の再調査が実施されていくことが予想されるが、それら箇所すべてを 5 年ごとに再調査することは、費用・時間面から困難である。

そこで、AI 分野で活用される深層学習を用いて机上調査を効率化し、現地調査箇所を最小限にすることで、作業員への負担を軽減し費用や時間が大きく削減されることが期待される。

本稿では、深層学習を用いた土地利用変化の抽出するツールを開発した。その手法および結果を報告する。

2. 土地利用変化の抽出方法の検討

2.1. 土地利用変化の抽出方法について

深層学習を用いて、衛星画像の土地利用分布を予測するツールを開発した。同地域で 2 時期の衛星画像を用いてそれぞれの土地利用を比較することで、指定済区域内で地形変化のおそれがある箇所を抽出する。

深層学習では、画像とラベル（画像が示す答え）が一組となる多数のサンプルから、法則性を学習させる。本稿では、衛星画像の一部から中央にある土地利用をラベルとして表 1 に示す土地利用に予測分類する。

表 1 判定する土地利用とサンプル数

土地利用	事例	サンプル数
森 林	山林、竹林等	25,000
建 物	人家、駐車場、砂防施設等	25,000
田 畑	田畑、運動場、植生地等	25,000
道 路	一般道、農道、高速道路等	25,000
水 域	河川、溜め池等	25,000

衛星画像全体から一部を切り取り、その中央にある土地利用を予測させる。具体的には、各土地利用で予測確率が出力される。これが最も大きいものが、その地点での土地利用であると予測される。

（例：予測結果が[森林：建物：田畑：道路：水域]=[0.9：0.01：0.05：0.01：0.03]のとき、森林と予測される）

これを極小区間（4 ピクセルとした）で隙間なく繰り返すことで、図 1 に示す通り衛星画像全体の土地利用分布図を作成することができる。



図 1 土地利用分布図の作成イメージ

2.2. 使用画像について

深層学習の画像解析には、衛星画像を使用した。衛星画像は日本全域を定期的かつ包括的に撮影し、データを蓄積している為、撮影に掛かる費用や時間を抑えつつ、あらゆる地域で同質の画像を用意することができる。また、一般的な航空写真（RGB 画像）の情報に加えて、近赤外線の情報も持っている。これは、植生の有無に反応を示す特徴があり、森林調査等に用いられる指標である。これらから、定期的の実施される調査に適しているとして衛星画像を使用するものとした。

本稿では、運用期間が長く分解能（≒解像度、1 ピクセルあたりの情報量）も比較的に良好な、表 2 に示す観測衛星の撮影した画像を用いる。

表 2 観測衛星の仕様

名称	運用開始	分解能	回帰日数
SPOT 6	2012/9	1.5m	26 日
SPOT 7	2014/6		



3. 開発ツールの評価

3.1. 精度の検証結果

開発ツールによる土地利用分布の再現精度を検証する為に、サンプルに使用されていない地域をテスト地域として選定した。目視と開発ツールのそれぞれから土地利用分布図を作成し比較することで精度評価した。目視による土地利用分布図を「目視マップ」、対して開発ツールによるものを「深層学習マップ」と呼称する。テスト地域には、近年、東海環状自動車道の開発により地形変化が著しくテスト地域に適しているとして、岐阜県山形市市役所周辺を設定した。

精度評価の結果を次ページの図 2 に示す。全体として 85% 程度、とくに土砂災害が発生しうる森林では 95% 以上の精度で再現することができた。一方、土地利用が混在する市街地周辺において、精度が劣っている。主な原因は、土地利用の境界部において連続して判定が異なる為と考えられる。また、航空写真により土地利用を確認した際、目視マップの方が間違っていた箇所も散見され、特に土地利用が複雑な箇所でも多く確認さ

2013 年 6 月撮影



2021 年 6 月撮影




図 2 精度の検証結果

れた。目視マップと深層学習マップを見比べてもわかる通り、深層学習マップで明らかな誤判定がされた箇所はほとんど確認されなかった。

3. 2. 地形改変箇所の抽出結果

同テスト地域で、2013 年版と 2021 年版の深層学習マップを比較し、土地利用に変化があった箇所を地形改変のおそれがある箇所として抽出した。

同じ地点における 2013 年版と 2021 年版それぞれの森林（傾斜部）の予測確率同士の差分を算出する。土地利用に変化があるとき、この差分が大きくなる。このときの差分が 80%以上の地点を赤く着色した。赤く着色された地域と既に指定されている土砂災害警戒区域を重ね、重複する区域を深層学習解析による地形改変のおそれがある箇所として抽出した。目視でも地形改変のおそれがある箇所を抽出し、それぞれの抽出結果を比較検証した。

比較検証の結果を図 3、表 3 に示す。テスト地域内で全 89 箇所の指定済区域（図 3 の黄色矩形）が存在していたが、そのうち 30 箇所（全体の約 33%）が開発ツールにより変化ありとされた。そのうち、目視でも変化ありとした箇所が 13 箇所であった。また、開発ツールによって変化なしとされた全 59 箇所のうち、目視で変化ありとした箇所は 0 箇所であり、抽出漏れはなかった。

4. まとめと今後の展望

開発ツールにより変化ありとして抽出された全 30 箇所のうち、17 箇所（約 66%）が本来抽出する必要のな

図 3 地形改変箇所の抽出結果
（左：抽出前、右：抽出後）

表 3 抽出結果の混同行列

		目視		合計
		変化あり	変化なし	
深層学習	変化あり	13	17	30
	変化なし	0	59	59
合計		13	76	89

い箇所（過剰抽出）であった為、まだ机上抽出すべてを自動化することはできない。しかし、目視確認が必要な箇所がおおよそ 1/3 にまで絞り込むことができたため、スクリーニングツールとして十分実用的なものになったと考えている。そのため、本稿で開発したツールを用いることで、基礎調査作業の効率化が期待できる。

今後の課題として、過剰抽出箇所の削減が挙げられる。そのために、より正確で汎用性の高いモデルに更新する必要がある。より様々な地域・季節で誤判定が起りやすい地点の学習サンプルを強化して追加学習を行い、異なるテスト地域にて同様に検証する必要がある。