

AI による光学衛星画像のみを用いた林相区分図の作成

株式会社オリエンタルコンサルタンツ ○高橋大地・秋山怜子
株式会社 Geotrans 黒澤裕也・中谷吾吾

1. はじめに

近年、土砂災害に伴って発生する流木被害が増加し、流域治水において流木対策が今後必要な対策として位置付けられている。国土交通省からも土砂・洪水氾濫時に流出する流木の対策計画の基本的な考え方（試行版）¹⁾ が公表され、流域全体での流木対策への取り組みが強化されている。

国土交通省が管理する流域では、航空写真及び航空レーザ計測成果を用いて流木発生ポテンシャルを分析した結果に基づく流木対策計画が策定済みもしくは検討中であるが、都道府県が管理する流域では調査に必要なデータが十分に蓄積されておらず、計画策定まで時間を要することが課題である。

上記の課題に対し、広範囲を短時間で撮影できる衛星画像のみを用いて精度良い林相区分が可能となれば、短期間での流木発生ポテンシャルの把握が期待できる。したがって、本稿では光学衛星画像のみを用いて AI による林相区分図の自動作成技術の開発を試みた内容を報告する。対象流域は相模川水系沢井川（A=19km²）とした。



図1 検討対象流域（背景：地理院タイル）

2. AI モデルの開発方針

本稿で開発するモデルは、光学衛星画像と林相目視判読結果の組合せを学習させ、解析対象エリアの林相を推論することを目的とする。本稿はその第一段階となる検討内容である。

まず、対象流域内に存在する樹種や土地利用を把握した上で区分する林相は「スギ・ヒノキ・広葉樹・タケ・田畑・道路建物」とした。AI モデルに使用する画像は林相判読に十分な空間分解能を保有し、全国的に整備されていることを重視し、Pleiades Neo (Airbus 社) を利用した。衛星画像は複数時期で撮影されているが、本稿では林相区分に適した衛星画像を選定するため、春季と秋季の衛星画像（春季：2024/4/20 撮影・分解能 30cm、秋季：2024/11/24 撮影・分解能 30cm）の2種類で比較した。

3. 使用する衛星画像の選定

ここでは、林相区分を実施するにあたり、色調による各林相の分離性を定量的に把握する。なお、今回用意した衛星画像には、R(赤)・G(緑)・B(青)・NIR(近赤外)・Red Edge(赤緑域)・Deep Blue(深青色域)の6種類が含まれており、それぞれの波長帯の画素値を利用し分離性を評価する。

林相の分離性の評価は、SNR (Signal-to-Noise Ratio) を指標とした。SNR は各林相間の平均画素値の差を比較する林相の画素値の標準偏差の和で正規化した指標であり、値が大きいほど指定した波長帯における林相が区分しやすいことを示す。

まず、本稿で用意した2種類の衛星画像に対し、目視判読により林相区分図を作成した。その後、異なる2つの林相の組合せ（以下、クラスペア）ごとに、特定の波長帯の画素値を用いて、式(1)により SNR を計算した。なお、SNR の計算に使用する波長帯は植生指数の解析に使われる機会の多い NIR とした。

$$SNR = |\mu_x - \mu_y| / \sqrt{(\sigma_x^2 + \sigma_y^2) / 2} \dots \dots \dots (1)$$

ここに、 μ_x と μ_y は各林相に属する NIR の平均値、 σ_x と σ_y は NIR の標準偏差を示す。

比較した結果を表1に示しており、いずれのクラスペアでも春季の衛星画像で分離性が大きいことを確認した。したがって、以降の検討は春季画像で実施することとした。

表1 SNR 比較結果

クラスペア	SNR(クラス分離性)	
	春季	秋季
スギ-ヒノキ	0.93	0.83
スギ-タケ	1.75	0.83
スギ-広葉樹	1.31	0.66
タケ-広葉樹	0.43	0.22

4. 林相判読に使用する波長帯の解析

上記の結果により、春季画像に対して、林相区分に用いる波長帯を定量的に分析し選定する。分離性の比較は、複数の波長帯を組み合わせたときの分離性も評価できる JM 距離 (Jeffries-Matusita 距離) を指標とした。JM 距離が大

きいほど林相の分離性が高いことを示し、最小値は0.0, 最大値は2.0である²⁾。

$$J_{xy} = 2 \times (1 - e^{-B}) \dots \dots \dots (2)$$

$$B = \frac{1}{8} (m_x - m_y)^t \left\{ \frac{\sum_x + \sum_y}{2} \right\}^{-1} (m_x - m_y) + \frac{1}{2} \ln \left(\frac{(\sum_x + \sum_y)/2}{(\sum_x \sum_y)^{1/2}} \right) \dots \dots \dots (3)$$

ここに、 m_x と m_y は各林相に属する画素値を成分とする多次元ベクトル、 \sum_x と \sum_y はそれらの画素値の共分散を示す。

表2にクラスペアごとに波長帯の組合せに応じたJM距離を示す。これらを比較した結果、単体の波長帯で解析するよりも、「R+NIR+RE」の波長帯を組み合わせた方が林相の分離性が高いことを確認した。

表2 JM距離の比較結果

クラスペア	JM距離				
	R	NIR	RedEdge	R+NIR+RE	RGB
スギ-ヒノキ	0.03	0.23	0.20	0.35	0.24
スギ-タケ	0.32	0.69	0.58	0.93	0.63
スギ-広葉樹	0.45	0.45	0.57	0.90	0.92
タケ-広葉樹	0.03	0.04	0.01	0.84	0.14
タケ-田畑草地	0.01	0.15	0.05	1.14	1.19

5. モデルの設計

本モデルは森林のまとまりを考慮した深層学習モデルにより林相の自動区分を試みた。少数クラスにも配慮した学習設計により、安定した判読を目的とした。

訓練用データは春季に撮影された衛星画像をベースに、「学習データ：検証データ=8：2」の内訳とし、林相の分布がなるべく均等になるよう分割した。学習データについては、表3に示すように衛星画像と正解データの組合せをモデルに学習させた。なお、モデルによる推論は上記で選定した「R+NIR+RE」の波長帯の組合せで実施した。

表3 学習データ

衛星画像	目視判読結果
スギ	
広葉樹	

6. 解析結果

学習モデルを用いて、評価データに対し林相区分した結果について、目視判読結果と推論結果を比較した事例を表4に示す。主要なクラスであるスギ・ヒノキ・広葉樹のみ表示しているが、概ね適切に区分できている。

表4 推論結果の事例

精度を定量的に評価するための指標としてIoUを整理した結果を表5に示す。IoU (Intersection over Union) とは、正解と推論結果が、どの程度一致しているかを示す指標である (0.0 ≤ IoU ≤ 1.0)。目視判読と推論の領域の重複割合を数値化しており、林相区分の精度を評価している。

目視判読結果	推論結果

IoUを確認すると、広葉樹>スギ>ヒノキの順に精度が高い。既往研究において、実務上十分な精度とされる目安は概ねIoU=0.7であるため、スギや広葉樹は良い傾向を確認できた。一方で、その他の区分は更なる精度向上が必要と考えられる。

7. 今後の開発方針

本稿で報告したモデルは小規模流域に対し、全て目視判読を実施した上で、「学習データ：検証データ=8：2」で検討した。本モデルは砂防計画の対象となる流域に対して、判読作業の省力化を図ることが目的であるため、学習データは可能な限り少ないことが望まれる。したがって、本稿の対象流域に対し、学習データを少なくした場合にIoUがどのように推移するか今後分析する。また、より広範囲への展開、さらに他地方でのモデル適用性についても取り組む必要がある。

表5 IoUの比較

クラスペア	IoU
	R+NIR+RE
スギ	0.70
ヒノキ	0.57
広葉樹	0.74
田畑	0.35
タケ	0.57
道路建物	0.64

【引用文献】 1) 国土交通省水管理・国土保全局砂防部(2024)：土砂・洪水氾濫時に流出する流木の対策計画の基本的な考え方(試行版)、2) Richards, J. A., Jia, X (2013) : Remote Sensing Digital Image Analysis, 3) 小林裕之(2014) : 衛星データを使用したオブジェクトベース分類による林相区分