

Landsat画像を用いたディープラーニングによる植生分類

水落 啓太*・根本 達也*・升本 眞二*

Vegetation Classification based on Deep Learning using Landsat Images

Keita MIZUOCHI*, Tatsuya NEMOTO* and Shinji MASUMOTO*

*大阪市立大学大学院理学研究科 Graduate School of Science, Osaka City University, 3-3-138 Sugimoto, Sumiyoshi-ku, Osaka 558-8585, Japan. E-mail: m19sc026@fa.osaka-cu.ac.jp

キーワード: Landsat, リモートセンシング, 植生分類, ディープラーニング

Key words: Landsat, Remote sensing, Vegetation classification, Deep learning

1. はじめに

現在、植生分布を示した情報として、生物多様性センターが行っている調査の結果により作成された現存植生図がある。しかし、この現存植生図の作成には空中写真の判読や現地調査などの作業が必要であるため、植生図の更新には多大な時間と労力を要する(鎌形ほか, 2006)。効率的に植生図を整備する手法の開発は重要な課題である。

植生図作成・更新の効率化にリモートセンシングの技術の適応が期待されており、近年ではリモートセンシングと機械学習を用いて植生図を作成する研究が進められている。また、近年は機械学習の一種である深層学習の技術が発展してきている。深層学習はニューラルネットワークを用いることにより、従来の機械学習より高度な学習ができる。本研究では、リモートセンシングデータと深層学習を用いて植生図を作成し、その精度を検証した。

2. 分類方法


分類は8個のクラス(落葉広葉樹林, 常緑広葉樹林, 針葉樹林, 低草地, 竹林, 耕作地, 市街地, 水域)で行った。分類結果の検証対象と学習データ作成に使用する植生データは、環境省生物多様性センター1/25,000 植生図のデータを用いて8クラスに再分類して作成した。リモートセンシングデータは多数のデータを容易に取得できることからLandsatのデータを用いた。解析地域は、大阪・奈良・京都を含む、東西55.68km, 南北72.96kmで行った。分類は画像認識に適したCNN(Convolutional Neural Network)を用いた分類とピクセルベースでの2つの手法で行った。LandsatのデータはCNNでの分類は植生図が作成された年代に最も近い2000年8月のデータを、ピクセルベースの分類では2000年の3月・8月・12月のデータを使用した。

2.1 CNNを用いた分類手法

CNNでの学習は3チャンネルの画像データで行うため、バンド1~5と7の反射率のデータとNDVI(正規化植生指数)をから3つ選びRGBに対応させて画像データを作成した。作成した画像と植生データを使用し16×16pixelの画像を約4000枚切り出し、学習データを作成した。学習データを用いてCNN分類器を作成して、3チャンネルの画像を入力し分類結果を反映させた植生図を出力した。

2.2 ピクセルベースでの分類手法

ピクセルベースでは、各ピクセルの3月・8月・12月のバンド1~5とバンド7の反射率のデータ、合計18個のデータを使用した。学習は、18個のユニットを持つ入力層、150個のユニットを持つ層が4層ある中間層、8つのユニットを持つ出力層で構成したディープニューラルネットワーク(第1図)と、100,000個の学習データを用いて行った。学習したネットワークに、全ピクセルの反射率のデータを入力してクラスの分類を行った。




第1図 作成したディープニューラルネットワーク

3. 結果

精度の検証には κ 係数(kappa statistic)を用いた。 κ 係数は判定結果などの一致率を示す統計量で1に近いほど高い一致を示す。 κ 係数の判定基準にはLandis and Koch(1977)によって示されたものを使用した, 0.41~0.60で中程度の一致, 0.61~0.80で高い一致を示すとされる。

CNNを用いた分類は各バンドとNDVIの数種類の組み合わせで行った結果、バンド2, 5とNDVIを組み合わせた画像での分類が最も κ 係数が高くなった。第2図(a)に再区分した植生図, 第2図(b)に分類結果, および第1表に精度の検証結果を示す。 κ 係数は0.66となり高い一致となった。

第2図(c)に再区分した植生図, 第2図(d)にピクセルベースでの分類結果, および第2表に精度の検証結果を示す。 κ 係数は0.70となり高い一致を示し、CNNでの分類よりも高い精度での分類結果を得られた。



第 2 図 植生区分と分類結果

(a) CNN 用に再区分した植生図, (b) CNN による分類結果, (c) ピクセルベース用に再分類した植生図, (d) ピクセルベースでの分類結果.

第 1 表 CNN による分類の精度検証結果

	分類結果								
	落葉広葉樹林	常緑広葉樹林	針葉樹林	低草地	竹林	耕作地	市街地	水域	合計
植生区分	落葉広葉樹林	122,381	9	227,588	315	4,224	75,569	1,462	431,557
	常緑広葉樹林	548	0	7,172	0	16	2,830	61	10,627
	針葉樹林	59,152	27	1,182,961	667	1,234	107,671	3,314	1,355,061
	低草地	3,614	0	8,439	9,660	395	49,680	5,043	77,123
	竹林	7,141	0	9,836	7	1,514	31,809	377	50,684
	耕作地	20,007	0	39,915	688	3,630	521,746	39,881	626,063
	市街地	469	0	6,860	24	65	354,150	1,403,016	1,776,775
	水域	0	0	3,465	0	0	5,597	5,567	120,120
	合計	213,312	36	1,486,236	11,361	11,078	1,149,052	1,458,721	4,448,010

一致率 75.24% κ 係数 0.66

第 2 表 ピクセルベースでの分類の精度検証結果

	分類結果								
	落葉広葉樹林	常緑広葉樹林	針葉樹林	低草地	竹林	耕作地	市街地	水域	合計
植生区分	落葉広葉樹林	289,001	115	186,625	1,019	11,755	39,809	13,860	543,915
	常緑広葉樹林	5,743	852	13,646	131	1,417	1,118	2,492	25,654
	針葉樹林	133,011	324	993,717	2,423	11,812	34,265	16,763	1,193,464
	低草地	3,676	4	4,530	33,466	332	36,890	15,023	95,910
	竹林	18,217	27	21,689	60	43,029	12,354	8,606	104,358
	耕作地	36,453	6	28,726	1,380	7,562	503,081	106,742	687,186
	市街地	13,294	146	15,442	1,272	4,514	123,155	1,490,420	1,660,740
	水域	1,879	69	2,314	149	379	10,848	24,532	192,083
	合計	501,274	1,543	1,266,689	39,900	80,800	761,520	1,678,438	4,503,310

一致率 77.84% κ 係数 0.70

4. おわりに

ピクセルベースでの分類は κ 係数が 0.70 と高い精度で分類することができた。しかし、落葉広葉樹林、常緑広葉樹林、針葉樹林ではそれぞれ間違っ

文献

鎌形哲稔・原慶太郎・森 大・赤松幸生・李 雲慶・星野義延 (2006) 高分解能衛星データのオブジェクト指向分類による植生図作成手法の提案. 写真測量とリモートセンシング, vol.45, no.1, pp.48-93.
Landis, J. R. and Koch, G. G. (1977) The Measurement of Observer Agreement for Categorical Data. *Biometrics*,

vol.33, no.1, pp.159-174.
松林健一・根本 淳・百瀬 浩・藤原宣夫・日置佳之 (2002) 高解像度衛星データを用いた植生図化手法の開発と図化精度評価. 日本緑化工学会誌, vol.28, no.1, pp.127-131.
望月 翔太・村上拓彦 (2016) 機械学習法を用いた SPOT5/HRG データの土地被覆分類とその精度比較. 統計数理, vol.64, no.1, pp.93-103.
中川恭平・村上拓彦 (2012) オブジェクトベース画像分類による森林タイプ分類における分類手法ならびに特徴量選択に関する検討. 新潟大学農学部研究報告, vol.65, no.1, pp.57-65.
岡谷貴之 (2015) 機械学習. 講談社, 165p.
杉田幹夫 (2018) Landsat 地表面反射率データを用いた富士山周辺域の土地被覆分類における地形補正の影響. 富士山研究, vol.12, pp.17-24.