



衛星画像における分類精度の向上を目的としたCNNの導入および非学習領域への応用検証

吉原, 篤
滝口, 哲也
有木, 康雄

(Citation)

神戸大学都市安全研究センター研究報告, 21:151-156

(Issue Date)

2017-03

(Resource Type)

departmental bulletin paper

(Version)

Version of Record

(JaLCD0I)

<https://doi.org/10.24546/81011543>

(URL)

<https://hdl.handle.net/20.500.14094/81011543>



衛星画像における分類精度の向上を目的とした CNN の導入および非学習領域への応用検証

Introduction of convolutional neural networks for improving classification accuracy in satellite images and its application to unknown areas

吉原 篤¹⁾

Atsushi Yoshihara

滝口 哲也²⁾

Tetsuya Takiguchi

有木 康雄³⁾

Yasuo Ariki

概要：地震や津波といった大規模な災害が発生した場合、安全な避難・救援ルートを迅速に把握することが必要不可欠なタスクとなる。近年、このタスクを実現するための研究が注目されており、このため、リモートセンシング技術を用いた衛星画像に対する被覆分類処理が行われている。しかし、大規模災害をタスクとして実用するには、この被覆分類の精度が十分でないという問題がある。そこで今回、被災前後の衛星画像に対する被覆分類結果と被災前の地図情報と重ね合わせることで、被災直後の詳細な状況地図の作成することを最終目標とし、そのための第一段階として、分類精度の向上手法の検討を行った。本論文では、近年あらゆる分野で注目されている畳み込みニューラルネットワーク (CNN: Convolutional Neural Networks) を導入し、精度向上を図った。また、2つの分類器による精度の比較検証を行った。closed テストではわずかな向上が見られたが、非学習領域を用いた open テストではうまく分類することができなかった。主な原因として、学習データ数が少ないという問題が挙げられるため、これは今後の課題である。

キーワード：リモートセンシング, 衛星画像, 地図情報, 被覆分類, CNN

1. はじめに

毎年、世界中で大規模な災害が発生し、大きな被害を受けている。なかでも日本列島は、複数のプレートの上に位置しているため、世界的にも地震が多い地域である。特に、2011年に発生した東日本大震災では、東北地方の太平洋沿岸地域が甚大な被害を受けた。6年が経過した今でも復興活動が続けられている。

このような大規模災害が発生した場合、安全な避難・救援ルートの確保や復興対策の検討などが極めて重要なタスクとなる。これには、広域の情報を一括して取得する必要があるため、近年では、このタスクを実現するためにリモートセンシング技術が注目されている。リモートセンシングとは、人口衛星や航空機などのプラットフォームなどに搭載されたセンサーから放射された電磁波の反射を観測し、対象物を遠隔から測定する技術のことである。この技術には、遠隔性、広域性、周期性といった利点があり、土地利用調査などさまざまな分野に活用されている。

本研究では、この技術を災害で被害を受けた地域の状況把握に応用する。このタスクでは、土地被覆分類処理が施され、これに関する研究が多くなされている[1~5]。これらの研究では、分類精度の向上を目的として様々な分類手法が提案されている。しかし、大規模災害への実用を考えた場合、分類精度が不十分であるという問題がある。

そこで我々は、音声認識や画像分類、自然言語処理などのあらゆる分野で素晴らしいパフォーマンスを示している畳み込みニューラルネットワーク（CNN）を用いた分類精度を改善するための手法を提案する。一般的に、分類をタスクとする多くの深層学習モデルでは分類器として softmax 関数が用いられる。しかし、文献[1]のなかで、あるデータセットにおいては分類器として SVM (Support Vector Machine) を用いた場合の分類精度が高いという結果が示されていた。そこで、本研究で想定している災害に関する分類タスクにおいても SVM による分類が有効であるかどうか検証を行う。

2. 使用データと研究対象領域について

本研究では、Geoeye-1 という人工衛星に搭載されたマルチスペクトルセンサから得られる高解像度衛星画像を用いた。表 1 に、Geoeye-1 の各スペクトルバンド情報を示す。また、図 1 に宮城県石巻市上空の衛星画像を示す。この都市は、2011 年に発生した東日本大震災で津波によって最も大きな被害を受けた地域の一つである。画像全体のサイズは 10314×10312 [pixels] で、空間解像度は 0.5 [m/pixel] である。今回、事前実験として、5 つの分類クラスすべてを含むサンプル領域 A (256×256 [pixels]) を抽出し、分類精度の検証を行う。図 2 に抽出したサンプル領域 A を示す。

表 1. Gepeye-1 の各スペクトルバンド

Bnad	Bandwidth [nm]
Red	655 - 690
Green	510 - 580
Blue	450 - 510
Near-infrared	780 - 920
Panchromatic	450 - 800



図 1. 宮城県石巻市上空の衛星画像



図 2. サンプル領域 A

3. 提案手法

ここでは、衛星画像に対する被覆分類を目的とした CNN モデルの学習および概要について記述する。まず、図 2 に示したサンプル領域 A に対し、手作業でラベル付けを行う。分類するクラスは、Buildings, Water, Vegetation, Asphalt, Ground の 5 種類とした。その後、5 つの各クラスからランダムに 1000 ピクセルずつ選択し、これらの 8 割を学習用データ、2 割をテスト用データに分割する。すなわち、学習用データ数 4000 ピクセル、テスト用データ数 1000 ピクセルとした。CNN モデルへの入力、各学習用データ 1 ピクセルを中心とする周囲 $m \times m$ 、すなわち 4000 枚の $m \times m$ サイズの画像とした。CNN モデルは畳み込み層、プーリング

層、全結合層および分類器から構成されている。図 3 にモデルの構造図を示す。




図 3. CNN モデル構成図

畳み込みステップの後、非線形活性化関数として ReLU (Rectified Linear Unit) を用いている。また、ReLU 活性化関数によって生じる非飽和出力を正規化するため、局所コントラスト正規化 (LCN : Local Contrast Normalization) が実行される。全結合層および分類器のパラメータは、確率的勾配降下法 (SGD : Stochastic Gradient Descent) を用いたバックプロパゲーションによって学習される。SVM モデルでは、パラメータ調整のためにスケーリングおよびグリッド探索の処理が施されている。今回は他クラス分類をタスクとしているため、SVM カーネルは RBF (Radial Basis Function) を採用した。表 2 に CNN モデルの各種パラメータを示す。これらは、文献[6]において評価された値を用いた。

表 2. CNN モデルパラメータ

Contextural size m : 25
Convolutional filter size n : 10
Pooling filter size p : 4
Filter number k : 50

4. 評価実験

(1) 実験条件と評価方法

I. Closed test

前章 3 において、5 つのクラスからランダムに 1000 ピクセルずつ選択したものの内、テストデータとして分割した 1000 枚をここでのテストデータとして用いる。このテストデータを学習した CNN モデルに入力し、2 種類の分類器 (softmax 関数および SVM) で分類したときの精度結果を比較する。

II. Open test

ここでは、CNN モデルの学習に用いた領域とは別の 2 つのサンプル領域をテストデータとする。これらのサンプル領域についても 5 つのクラス (Buildings, Water, Vegetation, Asphalt, Ground) を含む領域を選択した。図 4 および図 5 にテストデータとしたサンプル領域 B, C を示す。




図 4. サンプル領域 B



図 5. サンプル領域 C

分類精度は、再現率(Recall)、正解率(Precision)、およびこれらの調和平均である F 値(F-measure)を算出することで評価する。算出式を以下に示す。

	Relevant	Non-Relevant
Retrieved	TP	FP
Not Retrieved	FN	TN

$$F - \text{measure} = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}}$$

$$\text{Recall} = \frac{TP}{TP+FN}, \quad \text{Precision} = \frac{TP}{TP+FP}$$

(2) 結果と考察

I. Closed test

表 3 に softmax 関数により分類したときの精度結果を示す。また、表 4 に SVM を分類器としたときの精度結果を示す。

この実験から、SVM を用いた分類の方がわずかではあるが精度が良いという結果が得られた。一般的に、データ数が少ない場合は SVM が、データ数が多い場合は CNN などの深層学習が良い精度を示すとされているため、将来的にデータ数を増加していくと結果が逆転する可能性があると考えられる。

表 3. softmax 関数による分類精度結果

	Buildings	Water	Vegetation	Asphalt	Ground	F-measure
Recall [%]	96.71	99.38	94.61	89.11	96.75	95.23
Precision [%]	95.83	97.57	94.67	94.43	93.44	

表 4. SVM 分類器による分類精度結果

	Buildings	Water	Vegetation	Asphalt	Ground	F-measure
Recall [%]	96.94	99.52	95.81	94.43	97.94	96.92
Precision [%]	98.09	98.16	96.33	95.90	96.16	

II. Open test

表 5 および表 6 にサンプル領域 B, C を用いてテストを行ったときの Confusion Matrix (混同行列)を示す。表中の黄色で示したセル部分が正しく分類できたピクセル数を示している。

この結果から、特に場所によって色や形が大きく異なる建物をうまく分類できていないことが分かる。学習に用いたデータ数が少なかったことや、テストに用いたデータ他領域への汎用性が低かったということが原因として考えられる。

表 5. サンプル領域 B をテストデータとしたときの Confusion Matrix

		Ground truth						
		Buildings	Water	Vegetation	Asphalt	Ground	Sum	Precision [%]
Predicted	Buildings	282	0	395	1801	1059	3537	7.97
	Water	1331	9961	165	346	132	11935	83.46
	Vegetation	270	3	17738	2421	2021	22453	79
	Asphalt	2171	480	1041	3720	2423	9835	37.82
	Ground	98	0	1835	1351	2317	5601	41.38
Sum		4152	10444	21174	9639	7952	53361	49.926
Recall [%]		6.79	95.38	83.77	38.59	29.14	50.734	50.33

表 6. サンプル領域 C をテストデータとしたときの Confusion Matrix

		Ground truth						
		Buildings	Water	Vegetation	Asphalt	Ground	Sum	Precision [%]
Predicted	Buildings	2425	214	234	917	68	3858	62.86
	Water	285	5772	191	3304	151	9703	59.49
	Vegetation	167	11	9942	2347	396	12863	77.29
	Asphalt	3846	1667	2671	15325	390	23899	64.12
	Ground	440	0	935	1661	2	3038	0.07
Sum		7163	7664	13973	23554	1007	53361	52.77
Recall [%]		33.85	75.31	71.15	65.06	0.2	49.11	50.87

5. おわりに

本稿では、災害が生じた際の対策処置のために、被災直後の状況をすばやく把握する支援を行うことを目的としている。これに関連した被覆分類を目的とした研究が多くなされているが、大規模災害をタスクとした場合、分類精度が不十分であるという問題があった。そこで近年注目されている CNN を導入し、また、CNN とその他の分類器を組み合わせることで分類精度が向上したという文献報告から、本稿では分類器として SVM を用いた際の分類精度を検証した。実験結果から、今回用いたデータ数では、SVM を用いた分類の方が良い精度が得られた。データ数が増えた際にどうなるかという検証が今後の課題である。また、非学習領域を用いたテスト結果では、建物の分類がほとんどできなかった。そのため、学習データ数をさらに増やし、CNN モデルのパラメータも再調整して汎用性の高いモデルを作成し、検証する必要がある。

参考文献

- [1]: Yichuan Tang. “Deep Learning using Linear Support Vector Machines.”
Contribution to the ICML 2013 Challenges in Representation Learning Workshop.
- [2]: Giorgos Mountrakis, et al. “Support vector machines in remote sensing.”
ISPRS Journal of Photogrammetry and Remote Sensing 66 (2011): 247-259.
- [3]: L. Albert, et al. “LAND USE CLASSIFICATION USING CONDITIONAL RANDOM FIELDS FOR THE VERIFICATION OF GEOSPATIAL DATABASES.”
International Society for Photogrammetry and Remote Sensing (2014): Volume 11-4, 14-16.
- [4]: Ozlem Akar, et al. “Classification of multispectral images using Random Forest algorithm.”
Journal of Geodesy and Geoinformation (2012): 105-112.
- [5]: Wei Hu, et al. “Deep Convolutional Neural Networks for Hyperspectral Image Classification.”
Journal of Sensors (2015): Article ID: 258619, 12 pages.
- [6]: Martin Langkvist et al. “Classification and Segmentation of Satellite Orthorectified Images Using Convolutional Neural Networks.” Remote Sensing (2016): vol. 8, issue 4, p.329.

筆者： 1) 吉原篤，システム情報学研究科，学生；2) 滝口哲也，都市安全研究センター，准教授；3) 有木康雄，都市安全研究センター，教授

Introduction of convolutional neural networks for improving classification accuracy in satellite images and its application to unknown areas

Atsushi Yoshihara
Tetsuya Takiguchi
Yasuo Ariki

Abstract

Once large-scale disasters occur like earthquake and tsunami, it becomes very important task to secure safe evacuation and rescue routes. In this task, land cover classification can be performed on satellite images using remote sensing technology. But, there is a problem that the accuracy of these classification is still low in order to be practical in large-scale disasters. Therefore, we decided to create a detailed situation map right after the disaster by overlaying the cover classification result on the map information before the disaster. As a first step for this purpose, we propose a method to improve the classification accuracy. In this paper, we employ a convolutional neural networks (CNN) for feature extraction. Generally, in classification tasks, most of deep learning models employ the softmax activation. But, [1] shows that by simply replacing softmax with linear SVMs, it gives significant gain. So, we employ the RBF (Radial Basis Function) SVM for classification. From our closed test, we demonstrated that the classification method using SVM is slightly higher than softmax used in a general classification method using CNN. But, from open test result, it seems that Buildings were not classified well because the training data was small and the versatility was low. So, it is necessary to increase the number of training data and study of a new CNN model.

©2017 Research Center for Urban Safety and Security, Kobe University, All rights reserved.