

# 地球観測衛星画像上で自動検知した熱源の深層学習による自動種別判定

## Automatic Classification of Hot spots on Satellite Imagery by Deep Learning

宮本寛気\*<sup>1</sup>  
Hiroki MIYAMOTO

加藤創史\*<sup>1</sup>  
Soushi KATO

織田篤嗣\*<sup>1</sup>  
Atsushi ODA

中村良介\*<sup>1</sup>  
Ryosuke NAKAMURA

\*<sup>1</sup> 産業技術総合研究所  
National Institute of Advanced Industrial Science and Technology

Earth observation satellites are producing tremendous amount of digital imagery in recent years. Automatic object recognition is an indispensable tool for the efficient analysis. We designed a convolutional neural network and create automatic classification system which classifies hotspots on the multi-band images obtained by middle-resolution satellite Landsat-8. Our experiments demonstrated that cause of hotspots can be accurately identified through the spatial and spectral features.

### 1. はじめに

近年、宇宙空間に打ち上げられる地球観測衛星の数が増加している。例えば、Planet 社による2014年から2016年に打ち上げられたDove衛星の総数は133機に上る[Planet16]。こうした地球観測衛星が配信するデータは、近い将来一日当たり数十テラバイトにも達すると予想される。このような状況下で日々更新される膨大なデータを人手で解析していくことは困難であり、効率的な解析を行うためのアルゴリズムが不可欠である。例えば火山の噴火、製鉄工場の溶鉱炉や油田施設のフレアスタック、自然発生した森林火災や農耕地における人為的な野焼きなど、高温を発生するイベントが世界中の様々な場所で日々発生している。近赤外線バンドを活用することで、こうした熱源を検知することができる[Kato15]。また画像解析手法の一つとして、一般物体認識の分野では、Convolutional Neural Network (CNN) が従来手法に比べ高い性能を示しており、地球観測衛星にて撮影された衛星画像においても、CNNを用いることにより、既存の機械学習手法と同等以上の性能を示すことが知られている[Ishii16]。本研究では、中程度の分解能(30m)を持つ衛星画像にて検知した熱源に対して、その発生原因をCNNにより自動で種別判定するシステムを構築した。高精度な高温検知・種別判定により、火山活動状況や森林火災の発生状況の自動モニタリングを目指す。

### 2. 対象データと熱源識別手法

本研究ではLandsat8号衛星が撮影した衛星画像を使用する。Landsat8号衛星は2013年2月に打ち上げられ、地球上の任意の地点を15m~100mの空間分解能でおおよそ16日周期で同地点を観測し続けている[Landsat13]。Landsatシリーズは長期にわたり地球上の陸上領域および一部海上を観測し続けており、継続的また長期的なモニタリングに適している。また毎日500GByteに及ぶデータが、誰もが自由に使えるオープンデータとして公開されている。Landsat8画像上で有用性が認められれば、将来的な実利用や拡張に向けた第一歩となるLandsat8の観測データを用いて、熱源検知を行う手法として加藤らが提案した手法がある[Kato15]。これは複数の近赤外線バンドの解析から、高温の熱が発生しているであろう画素を同定する。この手法を用いれば、日々観測されるデータから熱源の

連絡先: 宮本寛気, 産業技術総合研究所人工知能研究センター, 東京都江東区青海2-4-7 産業技術総合研究所 臨海副都心センター別館, miyamoto-hrk-tomeken@aist.go.jp

発生地点が取得できる。しかし熱源の発生地点を取得できたとしても、発生原因まではわからず、また日々発見される熱源は数百か所にも上るため、人手で確認することは困難である。本研究では、検知した熱源の周辺環境も含めてCNNで学習することにより、熱源の発生原因を自動で判別する。従来のCNNを用いた地物認識の研究においては、画素単位で地物のカテゴリ分けを行い、それに基づいた教師データの作成を行って学習、識別を行っていた[Mnih10][Yue15]。しかし熱源検知では、検出された地点の画素は高熱の状態であるため、元の地物の状況と大きく異なっていることがほとんどである。そこで熱源の検知地点を中心に任意の範囲を切り出し、熱源及び周囲の状況を学習することによってカテゴリ識別させる手法を用いる。学習および評価用のデータは、人手にて熱源の周囲状況や発生前の状況を確認し、熱源発生地点の地物を元に発生原因を推定することで作成した(表1)。平坦な屋根などの鏡面反射による誤検知および分類不可能な対象を含む6つのカテゴリに分類した。対象衛星画像は、2015年10月から2016年8月までに観測されたものを使用した。Fire(火災)は比較的世界中様々な場所で発生しているが、Factory(工場)などの人工物、Volcano(火山)などの特定条件のみにある自然物は相対的に数が少ない(表2)。今回用いたデータは次節で述べるように一般的なCNNに使用される画像サイズよりも小さく、またカテゴリ数も6カテゴリと少数であるため、CNNにおける層構造は比較的小さい構造を構築した(図1)。

### 3. 実験結果

本節では、CNNを用いて熱源の種別判定を行った結果を示す。一般画像認識では、識別対象となる画像は人が見て確認

表1: 熱源のカテゴリ

Category	
Fire	草原、森などで発生した火災の熱
Factory	工場などの人工物で発生した熱
Volcano	火山によるマグマ等で発生した熱
OilPlatform	海上に建設された油田施設の熱。なお地上の油田施設はFactoryに分類する。
Roof	屋根などの建造物の反射により熱源と誤検知したもの。
Nontypeable	上記のカテゴリに当てはまらない、また発生原因が不明なもの。




図1: CNNの層構造

表 2 : 学習データ数

	Training	Validation	Testing
Fire	1165	83	420
Factory	170	12	62
Volcano	154	11	56
OilPlatform	136	9	51
Roof	73	5	27
Nontypeable	56	2	19

できる程度の大きさとなるため、例えば ImageNet[Image16]では 256px 四方の大きさになっている。しかし Landsat8 の画像において同サイズの画像を用いると、その範囲は実スケールで一辺 7680m という非常に広範囲となり、対象となる熱源以外の多様な地物を含んでしまう。そこで熱源検知地点を中心に周囲  $N \times N$  ピクセルをとり、 $N$  のサイズを変えたときの正答率を図 2 に示す。最も成績が良い  $N=16$  においてはどのクラスについても 7~9 割の正答率を持つことがわかる。Factory および Roof については画像サイズが大きくなるにつれ正答率が下がっている。Factory や Roof のような建造物では、熱源の近辺では他の建造物等があるものの、広範囲では植生や水域といった地物が画像の大半を占める。そのため、画像サイズが大きいと画像内の他の地物と誤検知しやすくなってしまふと考えられる。また Landsat8 の OLI センサは、一般画像の RGB に相当する可視域のバンドに加え、紫外域・近赤外域をカバーする 4 つのバンドを持っている。そこでどのバンドが最も精度よく識別できるかどうかを比較・評価する。図 3 に使用するバンドの組み合わせと正答率の関係を示す。Roof と OilPlatform についてはバンド 456 の場合が最もよいが、それ以外のほとんど場合については 7 バンドすべてを使用した場合が最も正答率が高い。これらの結果に基づいて、 $N=16$  で 7 バンド全てを利用する自動種別判定システムを構築した(図 4)。このシステムは Amazon Web Service 上で日々更新される Landsat8 の画像から熱源を検知し、検知地点について提案手法でカテゴリ分類を行い、各カテゴリに対応したアイコンを自動で表示する。このシステムにより一目で検知した熱源の発生原因がわかるようになった。

#### 4. まとめ

Landsat8 画像上の熱源を検知した地点において CNN を使い、発生原因を自動で判別するシステムを構築した。正答率は分類不可能なカテゴリ以外では 7 割 9 割であることを確認した。一般的な深層学習には、学習に膨大なデータ量が必要となるが、今回行った識別では表 2 に示されるような比較的少数のデータであってもカテゴリ分類が可能であった。今回のターゲットは熱源の種別判定であったが、将来的にはより一般的な地物変化に対しても自動識別を行うようなシステムを拡張することを目指す

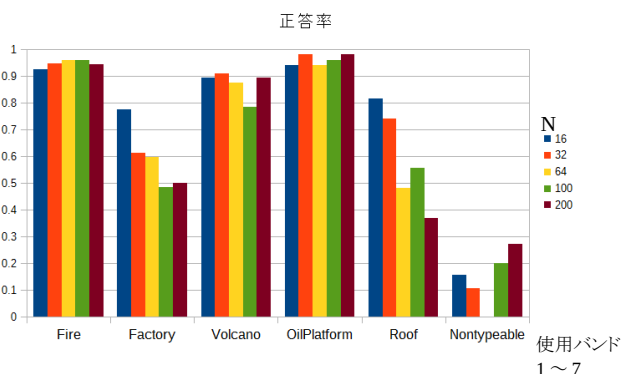


図 2 : 使用画像サイズ変更時結果

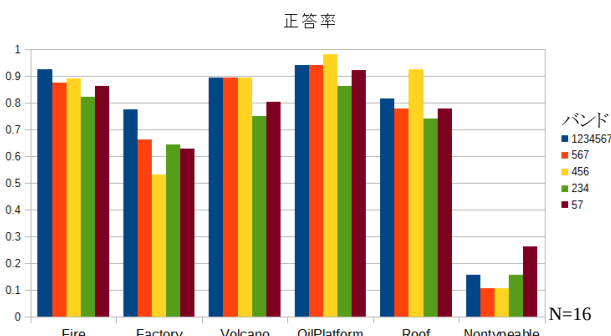


図 3 : 使用バンド変更時結果

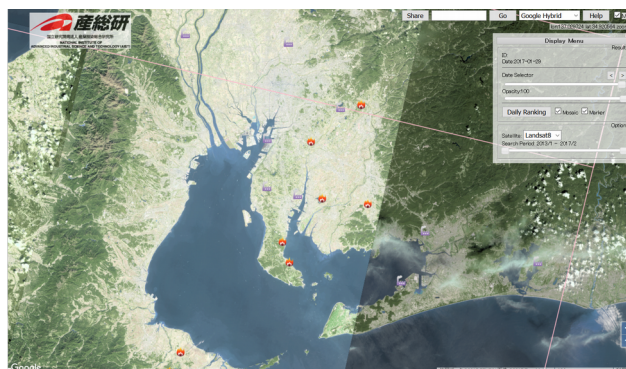


図 4 : 熱源自動検知システム

す。また Landsat8 という中程度の分解能をもつ衛星画像を利用したが、高分解能の衛星画像や航空写真等を用いれば、さらに細かい分類が可能になってくると期待できる。

#### 謝辞

この成果は、国立研究開発法人新エネルギー・産業技術総合開発機構(NEDO)の委託業務の結果得られたものです。

#### 参考文献

- [Planet16] <https://www.planet.com/>
- [Kato15] S.Kato, R.Nakamura, A.Oda, A.Iijima, T.Kouyama, T.Iwata, "Hot Spot Detection System Using Landsat 8/OLI Data", in AGU fall meeting, 2015
- [Ishii16] T.Ishii, E.Simo-Serra, S.Iizuka, Y.Mochizuki, A.Sugimono, R.Nakamura, and H.Ishikawa, "Detection by Classification of Building s in Multispectral atellite Imagery" in ICPR 2016.
- [Landsat13] <https://landsat.gsfc.nasa.gov/landsat-8/>
- [Mnih10] V. Mnih and G. E. Hinton, "Learning to detect roads in highresolution aerial images," in Computer Vision-ECCV 2010. Springer, 2010, pp. 210-223.
- [Yue15] J.Yue, W.Zhao, S.Mao, and H.Liu, "Spectral-spatial classification of hyperspectral images using deep convolutional neural networks" in Remote Sensing Letters, 2015, Vol6, No6, pp68-477
- [Image16] <http://www.image-net.org/>