

CNNを用いた高空間解像度衛星画像からの地物抽出

Object Extraction from High Spatial Resolution Satellite Imagery Utilizing CNN

藤田 藍斗
Aito Fujita

今泉 友之
Tomoyuki Imaizumi

彦坂 修平
Shuhei Hikosaka

株式会社パスコ 衛星事業部
PASCO CORPORATION Satellite Business Division

With the advent of satellite imagery with higher resolution than ever before (the spatial resolution of < 0.5 m) and constellation technologies, the amount of information that lurks in the images is now growing in terms of space and time. This then poses the following question: “How to deal with the intimidating volume of the images and to extract object information such as its identity, location and extent more effectively?” In practice, much of the information extraction is performed manually, e.g. via manual boundary delineation. We address this question by applying deep convolutional neural networks (CNNs) as a tool for automatically extracting objects from satellite imagery and by verifying its efficacy on our independently-derived dataset. Based on the experimental results, we affirmatively answer the question as follows: “Don’t be intimidated. CNNs will be a good surrogate for your object extraction process!”

1. はじめに

衛星画像を解析することで、「何がどこにあるのか」——つまり、画像にどんな地物が、どの位置に、どのような広がりをもって存在しているのか——といった情報を抽出することができる。本稿ではこれを、衛星画像からの地物抽出と呼ぶ。衛星画像からの地物抽出を実現する具体的な方法は、衛星画像の各画素を、どのような地物かを示すラベルに分類することである。このようにして衛星画像の各画素を分類した結果は、土地被覆分類図と呼ばれ、農林業、都市計画、防災、水文・気象モデリング等、多くの応用分野において有用な基盤情報として活用されている。1970年代初期に地球観測衛星が打ち上げられて以来、衛星リモートセンシング分野における研究の関心のひとつは、衛星画像からこの土地被覆分類図をいかに効率よく、精度よく作成するかということであり、多くの研究努力が費やされてきた。

最近では、画素当たりの空間解像度が数十 cm スケールの高解像度画像を取得できるようになり、衛星画像から「見えるもの」の種類が格段に増え、あるいは細分化し、これまで以上の幅広い用途に衛星画像を活用できるとの期待が高まっている。また、衛星コンステレーション技術(多数の独立した衛星で同一地点を撮像することで、時間解像度を向上させる仕組み; またその技術)の発展により、衛星画像から得られる情報量は、時間的にも増加している。つまり、今この時点においても時々刻々と、そして世界の至るところで詳細な衛星画像が撮像され蓄積されているのである。

しかしながら、このように衛星画像の情報量が増え続けていることは対照的に、実際の現場では画像からの情報抽出は大半が人手で行われており、大量のデータに眠る有用な情報を迅速に抽出できていないのが現状である。具体的には、人が画像を直接見て一つひとつ地物の輪郭を描いている、といった実情である。地物抽出を人手でやらざるを得ない理由として、低空間解像度の衛星画像において成功していた伝統的な地物抽出法が、高空間解像度の衛星画像ではそれほどの性能を発揮できず、それゆえ実用に足る地物抽出法が現時点で存在しないから——ということが挙げられる。

低空間解像度画像から地物を抽出する伝統的手法が、高空間解像度画像に対して適さない理由は、低解像度と高解像度

の二つの画像において対象となる地物が異なる、という点による。空間解像度が数十 m スケールの低解像度の画像において対象となる地物は、「都市域」や「農地」といった広義の分類クラスであり、これらを画像から識別する上では、それほど複雑な特徴は必要としない。一方で、高解像度画像の場合、対象となる分類クラスは、たとえば「建物」や「道路」である。これらを識別するためには、対象クラスの形状や周辺状況との関係性(コンテキスト)をも組み込んだ、より複雑で高次の特徴が必要となる。とはいえ、高解像度画像において対象クラスの「見え方」は大きく変動するため、この変動にロバストで識別に有用な特徴を模索し設計することは容易ではない。

このような背景を踏まえ、筆者らは、高空間解像度衛星画像からの地物抽出のツールとして、Convolutional Neural Network (CNN) の適用可能性を検討した。CNN は、近年、自然画像の分類や物体検出、領域分割などのタスクにおいて、既存手法を大きく上回る性能を記録している手法である [Krizhevsky 12]。CNN が効果的に働く理由として、認識対象の物体の形状や位置、大きさ等の変動が大きい状況下においても、それら変動にロバストで認識に有用な特徴を、データから「自動で」学習できるということが考えられている。

高解像度の衛星画像において抽出対象となる地物が示す「見え方」に関する変動は、低解像度画像における対象地物とは異なり、むしろ自然画像の物体に似た変動を呈すと考えられる。そのため、自然画像の物体認識において確認されている上記のような CNN の優位性を、今回のような問題設定においても享受できると考えられる: つまり、地物間の識別に有用な特徴を人手で設計する手間を省き、特徴の獲得と分類とを一体的な枠組みで実現できる CNN が有効であると期待できる。

本稿の貢献をまとめると以下の通りである:

- 高空間解像度衛星画像からの地物抽出ツールとして、CNN の有効性を確認した。
- 画素単位でラベル付けした教師データセットを構築し、これと CNN とを用いるだけの、明示的な特徴設計を必要としない、end-to-end な地物抽出フレームワークを確立した。
- CNN による地物抽出法に対し、さらなる高精度化の技法を検討し、それらの有効性を示した。

連絡先: 藤田藍斗, 株式会社パスコ, aaiti6875@pasco.co.jp

以降の流れは次の通りである。まず、2章において衛星画像からの地物抽出に関するレビューを行う。この章は、1章の内容を肉付けし、衛星リモートセンシング分野における地物抽出法の変遷とそれぞれの時代での抽出法の適否に関して論じたものである。3章では、CNNを用いた地物抽出のフレームワークを概説し、精度向上のために行ったいくつかの工夫についても述べる。4章では、CNNの地物抽出ツールとしての有効性を評価するために、自社で独自に準備したデータセットについて説明する。5章において地物抽出の実験結果を提示し、最後に、6章において結論と今後の展望について述べ、本稿を結ぶ。

2. 地物抽出法の変遷(空間解像度の視座から)

1970年代初期に地球観測衛星Landsatが打ち上げられて以来、衛星リモートセンシング分野の研究トピックのひとつは土地被覆分類図の作成に関するものであり、その研究例は枚挙に暇がない。Landsat衛星画像の空間解像度はたかだか数十mのスケールであり、そういった画像から地物抽出を行う場合、対象の地物は、「都市域」や「森林」、「農地」といった広義の分類クラスであった。これら分類クラスを画像から抽出する方法として一般的に用いられるものは、画像から局所的な特徴を得て、それと単純な分類器とを組み合わせる、というものである。局所的な特徴としてはたとえば、(i)最も単純な場合は抽出対象の画素(あるいはその周辺画素を含むこともある)から得られるスペクトルシグネチャそのもの——各画素が7つの波長帯をもつLandsat衛星画像であれば、これは7次元の実ベクトルとなる——や、(ii)抽出対象の画素とその周辺画素の画素値をもとに、テクスチャの情報を、専門家が設計した変換式により定量化したもの[Haralick 76]などが挙げられる。また、単純な分類器としてはたとえば、クラス条件付き分布が多変量正規分布に従うとしたベイズ分類器が挙げられる。とくにベイズ分類器においてクラス事前分布の影響を無視したものは、衛星リモートセンシング分野において最尤分類法と呼ばれており、衛星画像解析ソフトウェアに標準的に実装されている、いわば伝統的な手法である。

低解像度の画像において対象となる分類クラスを識別する上では、上記のような単純な特徴と分類器とを組み合わせるだけで十分な場合が多く、実際に、さまざまな種類の衛星画像について、また、さまざまな景観において、良好な結果を示した例が報告されている。しかし、画像の解像度が向上し、画像から抽出できる地物の種類や詳細が増したことで、これらの伝統的な地物抽出手法では十分な精度が達成できなくなっている。

1999年に、空間解像度が1m以下のIKONOS衛星が打ち上げられ、それまで以上に衛星画像の応用の裾野が広がることとなった。最近では、WorldView-3衛星のように、50cmよりも細かい解像度の画像が入手できるまでに至っている。さらには、衛星コンステレーション技術の普及により、空間解像度の高い画像が高頻度で取得できるようになり、空間的な観点のみならず時間的な観点からも、衛星画像が内包する情報量は増加の一途をたどっている。このように、衛星画像の時空間の高解像度化が進み、地表面の情報をこれまででない細かさで記録した衛星画像が、刻々と蓄積されている。この蓄積から有益な情報を抽出し応用へとつなげるためには、より効率的で正確な情報抽出技術を確立することが望まれ、筆者らは、このことが、いまの衛星リモートセンシング分野が解決すべき新たな課題と考える。

空間解像度が数十cmの高解像度衛星画像において対象となる地物は、「都市域」といった広義のクラスではなく、「建物」や「道路」といった狭義のクラスである。こういったクラスを画像から分類する上では、低解像度画像からの地物抽出においてはさ

ほど影響しなかった問題が顕在化する:つまり、地物の形状や色などの「見え方」に関する変動の悪影響が顕著に現れる。こうした理由から、これら地物を画像から抽出するためには、入力として、単画素のみに着目した局所的な特徴よりも、その地物の形状や周辺状況をも組み込んだ特徴が必要であろう。また、こういった高次の特徴空間において複雑な分類境界を引くためには、低解像度画像において「都市域」と「農地」とを識別するために使われていた分類器よりも、表現力の高い分類器が必要になると考えられる。

この問題に取り組んだ研究例として、たとえば[Dollar 06]がある。[Dollar 06]は、道路抽出を対象とし、それに有用な特徴を画像から得るため、(i)まず、何万種ものHaar-likeフィルタからなるフィルタバンクを予め定義し、それらを、さまざまなコンテキストを含むよう画像のいろいろな場所に適用し、数多くの特徴を抽出した;(ii)そしてその膨大な特徴に対し、非線形な分類器としてブースティングを適用した。このフレームワークは、高解像度画像からの道路抽出に対してある程度汎用的に使えるものではあるが、あらかじめ定義しておくフィルタの数や種類が恣意的かつ(何万種とは言っても)限定的であるという問題がある。この問題に対処するためには、データから自動で特徴を設計できる枠組みが必要となる。

CNNは、衛星リモートセンシング分野においても、この枠組みを実現する新技術として期待できる。実際に、高空間解像度衛星画像に対してCNNを適用し、その優位性を実証した文献が最近いくつか報告されている[Fan 15, Castelluccio 15]。これらの研究では、地物を囲んだバッチに対してひとつのラベルを振る分類問題の設定のもと、ImageNetの画像ですでに学習したCNN(CaffeNetやGoogLeNet)を用いてその効用を調査した。とくに[Castelluccio 15]は、(i)CNNを単なる特徴抽出器として用いただけでも、明示的な特徴設計を要するstate-of-the-artに比肩する性能を記録し、(ii)ファインチューニングした場合はそれを大きく上回った、としている。これら研究例からも、高空間解像度衛星画像からの複雑な特徴の抽出法として、CNNが適しているということが裏打ちされている。なお、本研究で扱う問題は、バッチに対してラベルをひとつ振る分類ではなく、バッチの各画素に対してラベルを振る領域分割に近い問題である。

3. 手法

3.1 地物抽出フレームワークの概要

本研究では、CNNを用いた衛星画像からの地物抽出の問題を、画素単位の分類問題として扱い、フレームワークの設計は[Dollar 06]や[Mnih 12]を参考にした。画素単位の分類を効果的に行うために、CNNの入力は、任意の大きさを持ったバッチ画像(たとえば64x64)を受け取るようにした;そして、その入力バッチのうち、中心の任意の領域(たとえば16x16)のそれぞれの画素に対して、分類の信頼度(クラス事後確率)を出力するようにした。入力バッチと出力バッチのそれぞれについて、領域の大きさには自由度があり、入力バッチのサイズを大きくするほどコンテキストをそれだけ取り込めることになり、出力バッチのサイズを大きくするほど地物抽出がより効率的に行えることになる。

本研究における地物抽出フレームワークの概要は図1の通りであり、大きく(i)学習フェーズと(ii)運用フェーズとに分かれる。(i)ではCNNの学習を行う。用いたCNNの構造は、他の文献でもよく用いられているものに倣った:畳み込み層を複数重ね、その後全結合層を配置した;ただし、畳み込み層のうちいくつかは、その直後にプーリング層を配置した。局所コントラスト正規化層やドロップアウトは、適用したが効果が得られなかった。

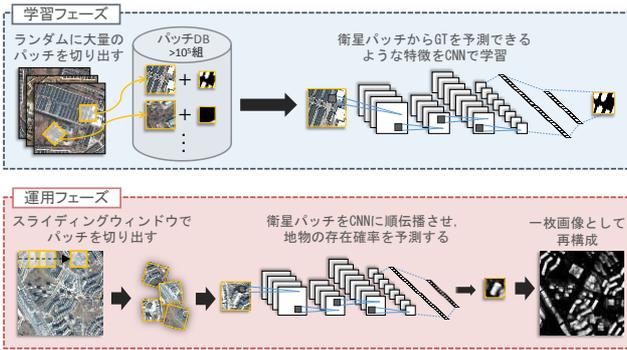


図 1: 地物抽出フレームワークの概要

一般的な K クラス分類の CNN [たとえば Alex 12] は、入力画像に対し、相互に排他的な K クラスのうちのいずれかを予測するように設計されている。つまり、最終層は K 個の出力ユニットを持ち、そこからの値が K -way softmax 関数を通り、クラス事後確率を予測する構造となっている。本地物抽出 CNN においては、最終層の K 個の出力ユニットを、出力パッチの K 個の画素(たとえば $K=16 \times 16=256$)のそれぞれと対応させて、 K 個の独立した二値分類を行うような設計とした。つまり、最終層の活性化関数は、 K 個の異なるロジスティックシグモイド関数とした。

CNN の重みパラメータの学習は、学習データに対して式(1)の交差エントロピー誤差 E を最小にするように行い、また、多量のデータから効率的に学習できるように、データをミニバッチに分割し確率的勾配降下法によって学習を行った。

$$E = - \sum_{n \in \text{MB}} \sum_{i \in R^{(n)}} (y_i^{(n)} \ln p_i^{(n)} + (1 - y_i^{(n)}) \ln(1 - p_i^{(n)})) \quad (1)$$

ここで、 n は単位ミニバッチ (MB) に含まれるパッチの添え字; $R^{(n)}$ は衛星パッチ n に対する出力パッチの画素集合; $y_i^{(n)} \in \{0, 1\}$ は、画素集合 $R^{(n)}$ のうち、画素 i の地物の在・不在を示したラベル; $p_i^{(n)}$ は、その画素 i に対して CNN が予測したクラス事後確率であり、シグモイド関数の出力である。学習の打ち切りは、検証データに対する式(1)が最小になる時点とした。

(ii) の運用フェーズは、(i) で学習した CNN を用いて、未知の衛星画像から実際に地物抽出を行うフェーズである。ここでは、もとの衛星画像を、(i) で学習した入力パッチと同サイズのパッチに分割し、一つひとつのパッチを学習済み CNN に入力する。そして CNN から出力された出力パッチを再配列し、もとの画像に対する予測結果として復元する(図 1 の下段参照)。

3.2 高精度化のための検討

3.1 の地物抽出フレームワークを基本モデルとし、さらなる高精度化を目的に 3 項目の周辺技術を検証した。これらの周辺技術は、基本モデルと組み合わせて適用するものである。

3.2.1. 超パラメータの自動決定

CNN には、学習により自動で決定できない多くの超パラメータが存在し、これらの設定によって性能が大きく左右するため、適切にチューニングする必要がある。たとえば、学習率、正則化係数、各畳み込み層におけるフィルタの数やサイズ、全結合層の出力ユニットの数、などである。ただし、これらのすべての超パラメータを網羅的にチューニングすることは、計算コストの観点から現実的でない。そこで、[Snoek 12] のベイズ的最適化理論に基づいた超パラメータの自動決定法を利用し、検証データに対する式(1)が最小となる組み合わせを得るよう試みた。

この方法では、まず、検証データに対する式(1)を、超パラメータを引数とした目的関数とする。この関数は閉じた形で表せ

ないため、その関数の事前分布にガウス過程を仮定し、逐次得られる評価点(ある超パラメータ設定とそのときの検証データに対する式(1)の値)の情報をもとに目的関数の事後分布を更新していく、といったアプローチを採る。次の評価点の探索は、その時点で得られている事後分布の情報をもとに、「活用(事後分布の平均)」と「探索(事後分布の分散)」のトレードオフを定式化した獲得関数(acquisition function)を最大にするものを選ぶ。

3.2.2. CNN のアンサンブル

3.2.1 の方法を用い、たとえば H 回の超パラメータの反復探索を行うと、 H 通りの超パラメータ設定のそれぞれによって規定される CNN モデルが出来上がる。これら H 個の CNN モデルのうち、検証データに対する式(1)を最小にするモデルをひとつ選ぶのが普通であるが、ここでは、その他の CNN モデルも組み合わせることで性能が向上しないか検討した。組み合わせる方法としては、 H 通りの CNN の中から h 個 ($h < H$) を選択し、それら h 個の CNN からの出力の平均をとることとした。

ここで、 H 個のモデル集合の中からどのようにして h 個のモデルを選択するか、という問題が浮上する。これには、[Caruana 04] の Ensemble selection を適用した。この手法は、 H 個のモデル集合の中から、性能を最大にする h 個のモデルの組み合わせを、Forward stepwise selection の枠組みで決定するものである(詳細については [Caruana 04] を参照されたい)。なお、このアンサンブルにおいて最大化する性能指標は、評価データに対する BEP (5 章で後述)とした。

3.2.3. CNN によるスムージング

本地物抽出フレームワークから出来上がる結果は、図 1 の下段の右図のように、衛星画像の各画素に対して、地物の分類信頼度を格納した図である。筆者らは、実験の過程で、3.1 の基本モデルのみを使ってこの図を出力したところ、下記のような現象を確認した: (i) 地物が存在しない場所を誤抽出していた; (ii) 地物が存在すべき領域が、一部穴が開いたように欠損し、地物の平面的な連続性を再現できていなかった。そこで、基本モデルの後処理として、基本モデルからの出力をスムージングすることで精度が向上しないか検討した。ここでいうスムージングとは、(i) ブロップのような誤抽出を消し去ると同時に、(ii) 部分的に欠損して生じた地物の「穴」を補間することが狙いである。

具体的な方法としては、基本モデルからの出力(分類信頼度を格納した図)を新たな入力で見立て、この新たな入力に対して 3.1 の地物抽出フレームワークを再適用する、というものである。つまり、いったん基本モデルの学習が完了したのち、この学習済みモデルに対して、図 1 の上段左側の「学習」画像セットを入力しそれぞれの分類信頼度の図を得る; 学習画像セットをここで得られた分類信頼度の図に差し替え、以降は図 1 と同じ手順を踏む(フロムスクラッチで学習する)。

なお、このスムージングは、条件付き確率場やマルコフ確率場のような、近傍画素との関係性を事前知識として明示的に組み込んだものではなく、CNN の中で陰に表現したものである。

4. データ準備

CNN の地物抽出ツールとしての適用可能性を調べるために、教師付き学習の枠組みで実験を行った。以下では、まず、用意した源泉の画像データセットについて説明し、次に、実際に CNN の学習に用いたパッチ形式のデータセットの説明を行う。

4.1 衛星画像と Ground Truth 画像

衛星画像は、自社で保有する、世界のさまざまな地域を撮像した画像(空間解像度 50cm 相当)を使用した。いずれも画素サ

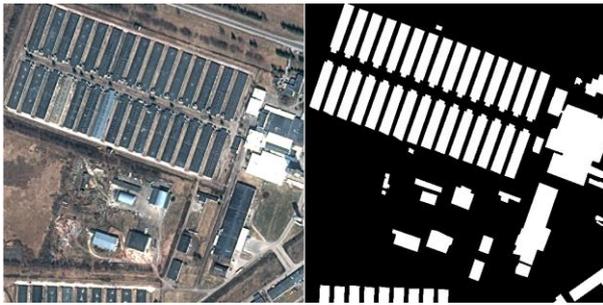


図 2: 用意したデータの一例: 左は衛星画像 (©2015 CNES – Distribution Airbus DS); 右は左の衛星画像に対して建物が存在する領域をラベリングしたものである。いずれも 625x625 の大きさの画像であり、画素当たり 1m 相当にリサンプリングしてある。

イズを 1 m にリサンプリングし、画像としては 625 x 625 の大きさに統一した。このような衛星画像を、建物について 312 枚、道路について 324 枚用意し、いずれの地物についても評価用に 67 枚、残りを学習用として分割した (以降、それぞれ評価画像セット、学習画像セットと呼ぶ)。CNN の教師付き学習を行うためには、衛星画像の他に、対象地物が画像上のどこにあるかを示した Ground Truth 画像 (GT 画像) が必要となる。GT 画像は、衛星画像の各画素に対して、対象地物の在・不在を示すラベルを付与することで作成した。図 2 に、建物について、衛星画像と GT 画像の一例を示す。

4.2 パッチセットの作成

今回設計した CNN は、入力に任意の大きさの衛星画像のパッチ (たとえば 64x64) を受け取り、その中心の画素集合 (たとえば 16x16) のそれぞれの画素に対して、地物の分類信頼度を予測する。つまり、学習時と評価時には、このパッチ形式の衛星画像と GT 画像との組が必要となる。この組は次のような手順で作成した (図 1 の上段左側参照): (i) 4.1 で述べた衛星画像と GT 画像のセットから、ランダムに一組を選ぶ; (ii) ここで選ばれた衛星画像からランダムな位置・角度でパッチを切り取ると同時に、この衛星パッチの中心の画素集合に対応する領域を GT 画像から切り出し、一組の学習データとする。

上記の手順を、学習画像セットに対して 450,000 回、評価画像セットに 45,000 回繰り返す。出来上がったそれぞれのパッチセットを、CNN の学習と検証データとした。また、データの標準化を行うために、衛星パッチの画素ごとの平均と標準偏差とを学習データから求め、これらの統計量を用いて、学習データと検証データ、評価データのすべてのパッチを標準化した。

5. 結果

図 3 の左図は、図 2 の衛星画像に対して基本モデルを適用し得られた分類信頼度の図である (この図は評価画像セットからの一例である)。この確率的な結果の評価指標として、評価データに対する BEP (Break-even Point) を算出した。表 1 に、検討した各手法に対する BEP の一覧を示す。ここで、「手動チューニング」とは、3.1 の基本モデルの超パラメータを手動で探索したものである; これ以外の 4 つの項目については、いずれも 3.2.1 の自動チューニングに基づく。建物と道路ともに、3.2 で述べた 3 つの検討項目をすべて組み合わせたもの (アンサンブル+スムージング) が、最も良い結果となった。

また、この BEP をとる分類信頼度をしきい値 (分岐点しきい値) とし、図 3 の左図を二値化したものが右図である。図 2 の GT 画像と比較すると、多少の抽出漏れや過抽出はあるものの、建物の位置や広がり良好に検出できていることがわかる。

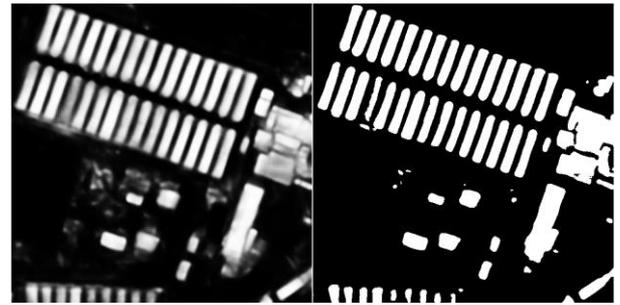


図 3: 図 2 の衛星画像に対する CNN の予測結果。左は CNN からの生の出力結果であり、各画素において、建物の分類信頼度をグレースケールで表示している。右は左を分岐点しきい値で二値化したものである。

表 1: 各検討手法に対する BEP (%) のサマリ。小括弧の中の数字は、対応するセクション番号を示す。

検討手法	道路	建物
基本モデル (3.1) の手動チューニング	69.9	79.1
基本モデルの自動チューニング (3.2.1)	71.7	81.8
アンサンブル (3.2.2)	74.8	84.9
スムージング (3.2.3)	75.7	85.7
アンサンブル+スムージング	76.2	87.2

6. おわりに

高空間解像度衛星画像からの地物抽出法として、CNN の有効性を検証した。ならびに、その高精度化技術についても検証した。その結果、独自に構築したデータセットに対して高い性能を示し、地物抽出のツールとして十分に使えることが確認できた。今後は、(i) 学習に用いたものとは異なる衛星センサで撮像された画像に対する汎化性能の確認 (つまり共変量シフトの確認); (ii) 教師作成の省力化 (半/弱教師付き学習や強化学習の検討); (iii) 実務への適用を視野に研究開発を進めていく。

参考文献

- [Caruana 04] R. Caruana, A. Niculescu-Mizil, G. Crew and A. Ksikes: Ensemble selection from libraries of models, *Proc. Inter. Conf. on Machine Learning*, pp. 137-144, 2004.
- [Castelluccio 15] M. Castelluccio, G. Poggi, C. Sansone and L. Verdoliva: Land use classification in remote sensing images by Convolutional Neural Networks, *arXiv: 1508.00092*, 2015.
- [Dollar 06] P. Dollar, Z. Tu and S. Belongie: Supervised learning of edges and object boundaries, *Proc. 2006 IEEE Comp. Soc. Conf. on Comp. Vis. and Pattern Recognition*, pp. 1964-1971, 2006.
- [Haralick 76] R. Haralick: Automatic remote sensor image processing, *Digital Picture Analysis*, pp. 5-63, 1976.
- [Hu 15] F. Hu, G. Xia, J. Hu and L. Zhang: Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery, *Remote Sensing*, Vol. 7, No. 11, 14680-14707, 2015.
- [Krizhevsky 12] A. Krizhevsky, I. Sutskever and G.E. Hinton: Imagenet classification with deep convolutional neural networks, *Advances in NIPS*, pp. 1097-1105, 2012.
- [Mnih 13] V. Mnih and G.E. Hinton: Learning to detect roads in high-resolution aerial images, *Proc. Eur. Conf. Comp. Vis.*, pp. 210-223, 2013.
- [Snoek 12] J. Snoek, H. Larochelle and R.P. Adams: Practical Bayesian optimization of machine learning algorithms, *Advances in NIPS*, pp. 2960-2968, 2012.

※本研究は経済産業省の委託業務「平成 24 年度小型衛星群等によるリアルタイム地球観測網システムの研究開発事業 (画像自動判読システムの研究開発)」の成果を元にしたものである。