

# 畳み込みニューラルネットを用いたすばる望遠鏡 Hyper Suprime-Cam による遠方銀河 Lyman-alpha emitter 観測データの自動分類

大倉真一希<sup>†</sup> 天笠 俊之<sup>††</sup> 伊藤 凌平<sup>†††</sup> 大内 正己<sup>††††</sup> 北川 博之<sup>††</sup>

<sup>†</sup> 筑波大学 情報学群 情報科学類 〒 305-8573 茨城県つくば市天王台 1-1-1

<sup>††</sup> 筑波大学計算科学研究センター 〒 305-8573 茨城県つくば市天王台 1-1-1

<sup>†††</sup> 東京大学 理学系研究科 物理学専攻 〒 277-8582 千葉県柏市柏の葉 5-1-5

<sup>††††</sup> 東京大学 宇宙線研究所 〒 277-8582 千葉県柏市柏の葉 5-1-5

E-mail: <sup>†</sup>okura@kde.cs.tsukuba.ac.jp, <sup>††</sup>{amagasa,kitagawa}@cs.tsukuba.ac.jp,

<sup>†††</sup>{itoh,ouchims}@icrr.u-tokyo.ac.jp

**あらまし** すばる望遠鏡に設置された Hyper Suprime-Cam (HSC) は一度の観測で大量のデータを得ることを可能にした。しかしそこから得られるデータには観測過程で混入する目的の天体と見なされない誤検出データが多く含まれる。従来の天体の観測では人手でのスクリーニングによって目的の天体と誤検出データを分類していたが、HSC での観測から得られるデータの数は  $10^8$  乗個にも達し、人手での分類は不可能となった。本研究では HSC によって行われた観測、特に遠方銀河 Lyman-alpha emitter (LAE) の観測結果から LAE と見なされないデータを取り除くための分類器を設計し、実環境データに適用することを目的とする。現在までに Convolutional Neural Network (CNN) を用いた分類器の設計及びその性能評価を行い、実環境データに対する有効性を検証した。

**キーワード** すばる望遠鏡, HSC, 天体画像, 画像分類, 深層学習

## 1 はじめに

2012 年よりすばる望遠鏡に搭載された超広視野 CCD カメラ Hyper Suprime-Cam (HSC) は一度の観測で  $10^8$  に及ぶ膨大な量の超遠方宇宙のデータを得ることを可能とした。観測画像より重要な天体を見つけ出す際は、画像中の光源の等級を測定し、設定された基準を超えたものを取り出すという処理を行う。しかし、その処理の結果として得られる天体の候補には、移動天体やノイズなど目的外の対象を誤検出したもの (spurious sources) や観測対象の同定条件を満たさないものが数多く含まれる。真に重要な天体を見つけ出すには、天体の候補からそれら誤検出データを取り除くことが必要となる。従来の観測は昨今のもものと比較して小規模であったため、人手のスクリーニングによって目的の天体と誤検出データを分類していた。しかし、HSC のような大規模カメラから得られる莫大な数のデータを同じように人手で分類することは困難である。そのため、人間と同様の基準を持って自動で分類を行えるような手法の開発が望まれている。

天体画像を自動で分類する試みは様々な対象に対して行われてきた。従来は画像中より取り出した特徴を用いて分類器の設計を行ってきた。しかし近年では、画像認識や画像分類の分野で大きな成果を挙げ、医療など様々な分野に応用されている Convolutional Neural Network (CNN) を用いて分類を行なった報告が多くされている。CNN を用いることで特徴量の設計を必要としない高精度な分類が可能となるが、その学習には大規模かつ高精度なデータセットが必要となる。現状、天体画像の分類に CNN を利用した例では、Sloan Digital Sky

Survey (SDSS) のように整備されたデータセットが用いられることが多い。一方、HSC による観測は SDSS と比較して歴史が浅く、また、観測対象となる天体も特異なものであるため、十分な学習用データセットは得られておらず、分類器の設計はチャレンジングである。

本研究では、HSC によって得られる観測データのうち、特に遠方銀河 Lyman-alpha emitter (LAE) の候補から LAE でないデータ (非 LAE) を取り除くモデルを設計し、実データに対して適用することを目的とする。現在までに Convolutional Neural Networks (CNN) を用いた分類器の設計及びその性能評価を行い、実観測データに対する有効性を検証した。

## 2 前提知識

### 2.1 Lyman-alpha emitter と誤検出データ

LAE は  $1216\text{\AA}$  の波長を持つ Ly $\alpha$  輝線を強く発する宇宙形成初期の銀河である。通常の銀河が発する Ly $\alpha$  輝線は銀河自身が含む水素原子などのダストによって錯乱され、観測されなくなる。一方で LAE のような初期の銀河はダストをほとんど含まないため、通常の銀河からは得られない Ly $\alpha$  輝線が観測される。この特性を用いることで、LAE の同定を行うことができる。

HSC での遠方銀河の観測では、主に 5 つの広帯域バンド (g, r, i, z, y) を決め撮影を行う。結果として、1 つの銀河に対して、異なる 5 つの波長で撮影された画像が得られる。LAE を検出する際は 5 つの広帯域バンドに加えて、対象の赤方偏移に応じた、Ly $\alpha$  輝線を観測するための narrow バンドを選択す

る。選択する narrow バンドは、対象とする赤方偏移  $z$  を用いて  $(1216 + z)\text{\AA}$  と算出できる。この時、広帯域バンドの範囲に光源が現れておらず、narrow バンドには現れているならば、LAE と同定することができる。分類器用の narrow バンドとの比較対象の広帯域バンドとしては、光源の有無が明確な g バンドを利用する。図 1 に LAE の例を示す。

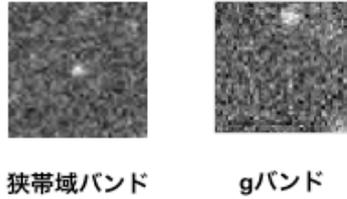


図 1 LAE の例. narrow バンドには中心に光源があるが、g バンドにはない。

LAE の候補は観測された画像中の光源に対して等級などを測定し、一定の基準を超えたものを取り出すことで得られる。しかし、LAE の候補には図 2 に示すような LAE でないデータ (非 LAE) が数多く含まれ、数万の観測結果の内およそ 98% を占める。非 LAE の内、移動天体やノイズなどのエラーデータを spurious sources と呼ぶ。また、天体を検出しているものの、g バンドの中心にも天体が現れている場合は、赤方偏移が無い近傍銀河と判定する。観測結果から真の LAE を得るには、それら非 LAE を取り除く必要がある。

種類		narrow	g	
非LAE	spurious sources	中心に光源なし		
		移動天体		
		ノイズ		
	近傍銀河			
Lyman-alpha emitter (LAE)				

図 2 LAE 観測において混入する LAE でないデータ (非 LAE) の例. narrow バンドにおいてノイズや移動天体などを誤検出しているものは spurious sources とする。narrow バンドと g バンドの両方の中心に光源がある場合は、赤方偏移が無い近傍銀河と判定する。

## 2.2 Convolutional Neural Networks

Convolutional Neural Network (CNN) は近年の画像認識の分野で大きな成果を挙げている手法であり、様々な分野に応用がされている。CNN はニューラルネットワークを発展させた構造を持ち、データから特徴を抽出する層と、抽出した特徴を元に分類を行う層から成っている。CNN の特徴量抽出部は任

意の数のフィルタの畳み込みにより画像から特徴マップを取り出す Convolution 層と、特徴マップを正方領域に分割し統計値に変換することでダウンサンプリングを行う Pooling 層を積み重ねた構造を持っている。分類結果の誤差を元に特徴量抽出部のパラメータを誤差逆伝搬方によって最適化することで、特徴量の設計を必要としない End-to-End な学習を可能としている。

### Convolution 層

図 3 に Convolution 層の処理の概要を示す。CNN の Convolution 層では、任意の数のフィルタの畳み込みにより、入力から特徴マップと呼ばれる多次元の特徴量を取り出す。具体的には、任意幅の正方形のフィルタを任意の移動幅 (stride) で逐次的に画像に適用していく。この処理を用意したフィルタの枚数分行う。結果として、フィルタの枚数と同じ数の特徴マップが得られる。サイズ  $m \times n$  のフィルタ  $w$  を  $N$  枚持つ Convolution 層へ、 $c$  チャンネルのテンソル  $x$  を入力することを考える。そのとき、 $k$  番目のフィルタに対する出力  $a$  の 1 要素  $a_{i,j}^{(k)}$  は以下のように表せる。

$$a_{i,j}^{(k)} = \sum_c \sum_{s=0}^{m-1} \sum_{t=0}^{n-1} w_{i,j}^{(k,c)} x_{i+s,j+t}^{(c)} + b^{(k)} \quad (1)$$

ここで  $b_k$  はバイアスである。複数のフィルタを適用することで、多様である入力に対してもそれ特異の特徴を捉えることができる。

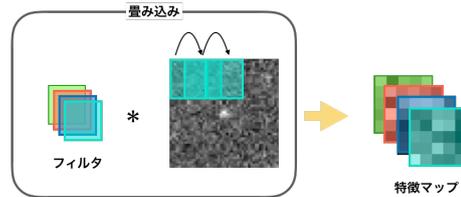


図 3 Convolution 層の概要図。

### Pooling 層

図 4 に Pooling 層の処理の概要を示す。CNN の Pooling 層では、入力として与えられた特徴マップを正方形の領域に分割し、その統計値に変換することで、ダウンサンプリングを行う。中間層における Pooling 処理のための統計値としては、一般的に最大値が利用される。入力テンソルを  $x$ 、Pooling に利用するフィルタサイズを  $l \times l$  とすると、Max Pooling 後の出力  $a$  の要素  $a_{i,j}$  は以下のように表せる。

$$a_{i,j} = \max\{x_{li+s,lj+t}\} \quad s, t \in [0, l] \quad (2)$$

Pooling 処理を行うことで、中間層のパラメータを減らすことができると共に、入力画像中のオブジェクトの位置変化に対して強固な特徴を得ることができると言われている。

## 3 関連研究

天体画像の自動分類に関する研究として様々な手法を利用したものが報告されている。Jorge [6] らは 2004 年に SDSS 内の銀河を形状によって自動分類することを目的として、主成分分

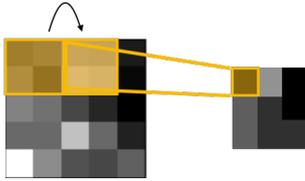


図4 Pooling 層の概要図.

析によって取り出した特徴を元にニューラルネットと locally weighted regression を学習させ、その voting をとる手法を提案し、91%の精度で分類が可能であることを確認した。同様のデータセットに対してより良い精度で分類を行える手法として、ナイーブベイズとランダムフォレストを用いるもの [7]、非負値行列因子分解を利用するもの [8] などが提案され、それぞれ精度向上を成し遂げた。近年では Khalifa ら [9] が近年の画像分類の分野で大きな成果を得ている CNN を利用し、97%を超える精度で分類が可能であることを確認した。また、Tuccillo らは、CNN を用いて HST/CANDELS というデータセット内の銀河が発する光の分布を予測することを行なっている [10]。

一方で、HSC のデータセットについては、2015 年に Morii らが初めて超新星爆発の実観測のデータに対する自動分類を試みた [3]。HSC による超新星爆発の観測データは未だ整理されたものなく、学習データとして利用できるものがなかったため、Morii らは二度の観測を行い、一度目の観測で得られた結果を元に天体画像のデータセットを自動で生成し、その中で分類器の訓練、性能検証を行い、二回目の観測に適用した。分類器にはニューラルネットとランダムフォレスト、AUC Boosting の voting を取る手法を採用し、結果として 45019 個の超新星爆発の候補を 16888 個まで減らすことに成功した。しかし、自動生成したデータのみで訓練を行なったため、実際の超新星の画像を分類させたところ、26 個のうち 22 個 (85%) のみを真の超新星として検出した。本研究で設計する分類器は従来と異なりマルチバンドの画像を対象としており、実用的な精度として 95%以上での LAE 検出率と 85%以上の非 LAE の除去が専門家から求められていることから、従来よりも高性能な分類器を設計する必要がある。

## 4 LAE 分類器の設計

### 4.1 画像の前処理

観測画像は天文分野にてよく用いられる fits 形式<sup>1</sup>として得られる。fits データには観測の際の情報なども含まれるが、今回は画像のみを利用する。fits 中の画像はピクセル値に上下限がないため、学習に利用できるよう正規化を行う必要がある。今回は実際に天体画像を見る際によく用いられる zscale を利用する。zscale は画像全体のピクセルの輝度を中央値付近から線形的に分布させるようなアルゴリズムであり、極端な輝度分布を画像に対して用いられる。本研究では python のモジュール

である astropy 中に実装された ZScaleInterval<sup>2</sup>を用いた。図 5 に正規化前の画像と zscale による正規化を行なった後の画像の比較を示す。画像は元画像より、中央 50x50 を切り出す。学習の際は画像のピクセル値を [0, 1] の範囲に納める。

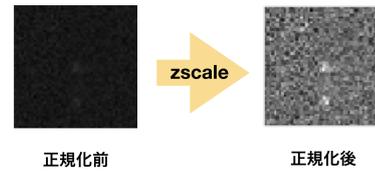


図5 zscale による正規化を行う前後の画像の比較.

### 4.2 CNN の構成

本研究で扱う天体画像は、その性質が観測対象や観測の際の環境などによって変化しやすいため、作成したデータセット、モデルが常に有用であるとは限らない。そのため、後の拡張が行いやすいよう、なるべくシンプルな CNN のアーキテクチャを利用することとした。図 6 に、実験に利用した CNN の構成を示す。特徴量抽出部では 3x3 のフィルタサイズを持つ Convolution 層と 2x2 のサイズの Pooling 層の組み合わせを 2 つ積み重ねている。実際に分類を行う FullConnect 層では、過学習を抑えるために有用とされている Dropout を用いている。Dropout は学習の際に、一定の確率でユニットからの出力を 0 にする手法である。最終的層では softmax 関数で出力を正規化している。

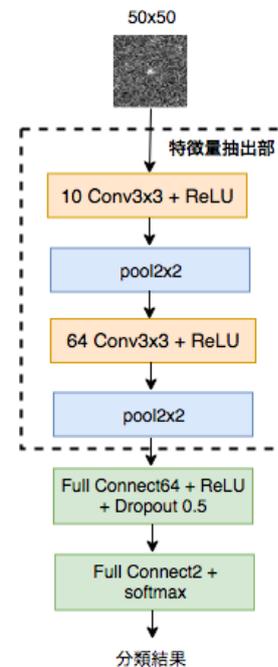


図6 本研究で利用した CNN アーキテクチャの構成.

1 : [https://ww1.fukuoka-edu.ac.jp/~kanamitu/fits/jdoc/fits\\_t53.pdf](https://ww1.fukuoka-edu.ac.jp/~kanamitu/fits/jdoc/fits_t53.pdf)

2 : <http://docs.astropy.org/en/stable/api/astropy.visualization.ZScaleInterval.html>

### 4.3 CNNの訓練とLAE検出のプロセス

CNNの訓練には大規模なデータセットが必要となる。その一方でLAEのデータは、大規模な観測が可能であるHSCにおいても一度の観測で1000個程度と、得られる数が少なく、CNNの訓練に十分な規模のデータセットを用意するのは難しい。よって本研究では、HSCの観測データの性質を考慮して天体画像の自動生成を行うことができるSynPipe[4]を用いて、不足するデータセットを補うこととする。

#### 4.3.1 SynPipe

SynPipe[4]は、HSCによる観測環境を考慮して、天体のデータを生成できるツールである。SynPipeでは、HSCによって得られた画像中に輝度の調整などの処理を施した光源を埋め込むことで、様々な環境下での任意の等級の天体の画像を生成する。図7に、SynPipeで生成した天体の画像の例を示す。

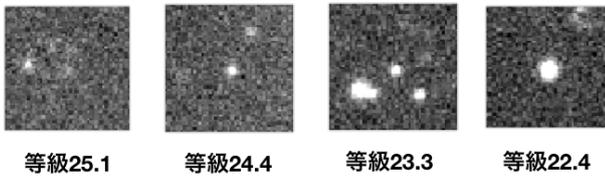


図7 SynPipeで生成した天体の例。様々な環境下での任意の等級の天体を生成できる。

SynPipeを用いることで、HSCから得られるデータに関するシミュレーションやデータセットの設計を行うことができる。一方で、LAEのようなマルチバンドで検出される天体のデータの生成は難しいため、直接LAE分類器を訓練するために用いることができない。

#### 4.3.2 訓練用データセットの設計とLAEの検出手順

本来、LAEは複数の周波数バンドで天体を見て、光源の有無を確認することで同定される。しかし、データセットの不足に対応するために利用するSynPipeで生成できるのはいずれか1つのバンド(シングルバンド)のデータのみであり、LAEのような複数のバンド間に関係を持つようなマルチバンドデータを生成することはできない。そこで本研究では、図8のような実際の観測で得られたspurious sourcesとSynPipeで生成した擬似天体画像から成るデータセットを用いて、シングルバンドのデータに対して中心に光源がある画像か、spurious sourcesかを判定する分類器を設計し、そのモデルを元にマルチバンドLAEの判別を行うこととする。天体がnarrowバンドに現れるが、gバンドには現れないというLAEの特性を利用すれば、各バンドへの分類結果を組み合わせてその同定を行うことができる。具体的には以下の手順でモデルの訓練およびLAE候補の分類を行う。

(1) 実際の観測から得られたspurious sourcesとSynPipeで生成した天体から成るシングルバンドのデータセットを用いて、中心に光源がある画像かspurious sourcesかを判別する分類器を訓練する。

(2) 訓練した分類器を用いて、LAE候補のnarrowバンド、gバンドに対してそれぞれ天体画像であるかspurious sources

であるかを判定する。

(3) 各バンドの分類結果から、表1の対応を用いてLAEかどうかの判定を行う。

表1 シングルバンドの分類結果とLAE判定の対応。Trueは天体画像、Falseはspurious sourcesを表す。

narrow バンド	g バンド	判定
False	False	spurious sources
True	False	LAE
False	True	spurious sources
True	True	近傍銀河

種類		画像の例
spurious sources	中心に光源なし	
	移動天体	
	ノイズ	
SynPipe天体		

図8 シングルバンドの天体とspurious sourcesを分類するためのデータセット。spurious sourcesは実際の観測から得られたものであり、天体はSynPipeを用いて生成したものである。

## 5 実験

### 5.1 データセット

本研究では、東京大学宇宙線研究所(ICRR)<sup>3</sup>より提供頂いたデータセットを利用する。学習とパラメータ調整に利用する訓練用データセットの概要を表2に示す。表2のデータのうち、spurious sourcesは実際の観測から得られたものであり、中心点に光源が存在しない画像と、移動天体やノイズなどの明らかなエラー画像からなっている。天体画像は、設定した条件の下で画像を自動生成できるSynPipe[4]を用いて作成したものと、実際のLAE観測より得られた天体からなっている。その内、実際の観測より得られた天体はハイパーパラメータを調整するためのvalidationセットとして利用し、モデルの訓練には利用しないこととする。また、最終的な実環境下でのシングルバンド分類性能を評価するために、表3のようなテストデータセットを用意した。また、実環境下でのマルチバンドによるLAE検出の性能を測るために表4のテストデータセットを用意した。表4中の誤検出データは実際の観測から得られたもの

3: <http://www.icrr.u-tokyo.ac.jp/>

であり、実観測天体は、表3中の天体をマルチバンドにしたものである。

訓練用データセットを用いて分類器の訓練を及びハイパーパラメータの調整を行い、2つテストデータセットを用いて設計した分類モデルの実環境下での性能を評価する。

表2 訓練用データセットの概要

ラベル	概要	個数
spurious sources	光源なし	18000
	宇宙ガスなど	18000
SynPipe 天体	等級 25.0~25.2	12000
	等級 24.5~25.0	12000
	等級 23.3~24.5	12000
	等級 23.0~23.3	12000
天体 (実観測)		300

表3 シングルバンドでの分類の性能評価用データセットの概要

ラベル	概要	個数
spurious sources	光源なし	51995
	宇宙ガスなど	10919
天体 (実観測)		877

表4 マルチバンドでの LAE 分類の性能評価用データセットの概要

ラベル	概要	個数
誤検出データ	narrow バンドと g バンド	37000
LAE	narrow バンドと g バンド	877

## 5.2 評価指標

設計する分類器の実用的な性能としては、95%以上の LAE 検出率と 85%以上の非 LAE 除去率が求められる。よって、分類器の性能評価の指標として、LAE の検出率を表す Recall と非 LAE 除去率を表す Specificity を用いる。Recall と Specificity は、表5に示す2クラス分類の結果を表す混合行列内の要素を用いてそれぞれ式(3)と式(4)のように表せる。

表5 混合行列

		分類結果	
		True	False
真のラベル	True	TP	FN
	False	FP	TN

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

$$\text{Specificity} = \frac{TN}{TN + FP} \quad (4)$$

## 5.3 実験手順

まず、訓練用データセット中の spurious sources の各クラスから 18000 個の画像と天体の各等級からそれぞれ 12000 個の画像を取り出す。また、300 個の実観測天体画像をハイパーパラメータ調整用の validation セットとして取り出す。取り出すデータは一定とし、残ったデータはテスト用データとして用いる。学習の際は、データを天体と spurious sources の2クラスとして扱い、分類を行う。取り出したデータを合わせた後、ランダムに5分割し、交差検定を行う。交差検定を行う際の validation セットとしては5分割されたうちの1つの spurious sources と validation 用に用意した 300 個の観測された天体画像を用いる。最終的に、5回の validation の平均結果をそのモデル、パラメータの性能として評価する。validation の平均結果が最良になるようなパラメータを決定したのち、36000 個の spurious sources と 48000 個の自動生成された天体を用いてモデルを訓練し、実際の観測より得られた非 LAE と LAE から成るデータセットで実環境での性能を測る。

## 5.4 ハイパーパラメータの選択

前述した実験手順に沿ってハイパーパラメータの一部である学習エポック数、学習率、最適化手法の調整を行なった。まず、validation セットに対する交差検定における Recall と Specificity を見て、最適化手法として確率的勾配法を利用し、学習率の初期値として 0.001 と設定し、200epoch で 0.0001 に変更することとした。また、損失関数において、天体データに関して2倍の重みをつけた。次に、図9の validation セットに対する平均学習曲線を元に学習エポック数を決定した。図9を見ると、400 エポック付近で Recall 及び Specificity が最大に近くなっていることから、それを採用した。決定したハイパーパラメータで交差検定を行なった際の validation セットに対する分類結果の平均と標準偏差を表6に示す。

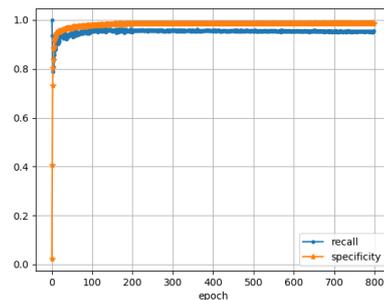


図9 validation セットに対して得られた5つの学習曲線の平均。

## 5.5 実観測環境を想定したシングルバンド分類器の性能評価

訓練データセット内での交差検定により決定したハイパーパラメータと全ての訓練データを用いてモデルを学習させ、表3のシングルバンドのテスト用データセットでその性能の確認を行なった。表7にテストデータセットに対する分類結果を示す。

表 6 最適なハイパーパラメータで交差検定を行なった際の validation セットに対する分類結果の平均と標準偏差

真のラベル \ 分類結果	天体	spurious sources
	天体	285.8(2.05)
spurious sources	99.6(13.2)	7100.4(69.2)
Recall	0.953(0.007)	
Specificity	0.984(0.001)	

表 7 最適パラメータで訓練した CNN によるシングルバンド検出テスト用データの分類結果

真のラベル \ 分類結果	天体	spurious sources
	天体	852
spurious sources	886	62028
Recall	0.972	
Specificity	0.986	

表 7 の結果を見ると, spurious sources の検出率を表す Specificity は目標である 85% を大きく上回っていることがわかる. 実際のカテゴリ結果を見ても, spurious sources を天体と間違っている例の多くがラベルの付け間違いによるものであった. よって本データセットに対してはシンプルな CNN でもその特徴を捉えられていると言える.

天体検出率を表す Recall は LAE 検出率の目標である 95% を 2% 程度上回っている. しかし, 実際の LAE の検出はマルチバンドで行うため, その精度は天体検出率である 97.2% を下回ることが予想される. 損失関数関数への重みを 2 倍にしているのにも関わらず, Specificity に比べ Recall が低くなった原因として, SynPipe を用いて生成された天体画像と実際の観測で得られた天体画像のデータ分布が異なっており, CNN がその違いに対応できていないことが考察される. Recall を向上させるための手段としては, 数の少ない実観測天体の画像を水増しして訓練に利用することが考えられる. また, spurious sources 中の間違っただけのラベルづけをされているデータを取り除くことによっても Recall が向上すると思われる.

## 5.6 実観測環境を想定した LAE 分類器の性能評価

実環境におけるマルチバンドによる LAE 検出性能を測るため, 前節において訓練した CNN を用いて表 4 のデータセットの分類を行なった. 表 8 にその結果を示す.

表 8 最適パラメータで訓練した CNN によるマルチバンド LAE の分類結果

真のラベル \ 分類結果	LAE	非 LAE
	LAE	826
非 LAE	4411	32589
Recall	0.942	
Specificity	0.881	

結果を見ると, 非 LAE 除去率を表す Specificity は最低目標である 85% を上回っているが, LAE 検出率を表す Recall は,

目標である 95% を少し下回っている. この原因として, 本来 narrow バンドと g バンドの情報を互いに比較してされるべき LAE の判定を, 各バンドへの分類結果を元にしたルールのみで行なっていることが挙げられる. この問題の対策としては, 訓練した CNN から得られる特徴を元に, 少量の LAE データで訓練を行うことが考えられる.

しかし, 分類結果の概要を見ると, 実際に専門家の手によって分類が行われた後の結果である本データセットでも, 非 LAE とラベルづけされているものの中に, 図 10 のような, LAE と見なせるようなものが多く含まれていることがわかった. 実際の観測においては, 最終的な LAE か非 LAE かの判断は専門家の手によって行われるため, これらのような判別のつきづらデータは LAE として検出すべきと言える. また, Morii らの報告 [3] では 3 分の 1 程度までしか絞れなかった観測対象の候補を 7 分の 1 程度まで減らすことができている. 全候補を 7 分の 1 まで減らしつつ, 目標である 95% に非常に近い精度で LAE の検出ができ, 専門家の目でも判別がつかないデータを捉えられていることを考慮すると, 分類器として十分な役割を果たすことが可能だと思われる.

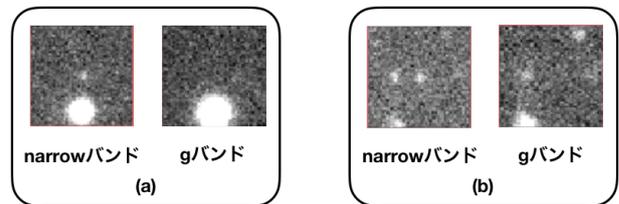


図 10 分類モデルが LAE 観測データから LAE として検出した, 判別が難しい非 LAE の例

## 6 まとめと今後の課題

本研究では, 実環境での利用を想定した CNN による LAE 分類器の設計を目指した. 訓練に利用できる LAE のデータセットが不十分であったため, 自動生成された天体画像での訓練が可能なら, 行うタスクを天体と spurious sources の分類に単純化し, モデルの訓練及び, 実環境データでの性能評価を行なった. 最終的な実観測 LAE データに対する分類結果として, 非 LAE の除去率については, 目標である 85% を上回る 88.1% の制度で行えることが検証できた. 一方で LAE の検出率は 94.2% と目標の 95% を少し下回った. この原因として, 本来 narrow バンドとこの原因として, 本来 narrow バンドと g バンドの情報を互いに比較してされるべき LAE の判定を, 各バンドの分類結果を元にしたルールでしか行なっていないことが挙げられる. 訓練した CNN から得られる各バンドの画像の特徴量を組み合わせ, 分類器を訓練することで, さらに良い精度で LAE の検出を行えると思われる. しかし, LAE を 95% に近い精度で検出でき, 専門家の目でも見分けるのが難しいデータを捉えられ, 全候補を 7 分の 1 以下まで減らせていることを考慮すると, 分類器として十分な性能を持っていると言える.

今後の展望として, データセット及び手法の改善によってモ

デルの性能を向上させていくことを目指す。また、実際の観測データへの適用とともに、別の LAE の観測結果が得られ次第、環境変化へのロバスト性などの評価を行なっていく必要がある。

## 文 献

- [1] Alex Krizhevsky et al, “ImageNet Classification with Deep Convolution Neural Networks,” NIPS, 2012.
- [2] H. Domínguez Sánchez et al, “Transfer learning for galaxy morphology from one survey to another ,” Monthly Notices of the Royal Astronomical Society, Volume 484, Issue 1, pp. 93-100, 2019.
- [3] Mikio MORII et al, “Machine-learning Selection of Optical Transients in Subaru/Hyper Suprime-Cam Survey ,” Publ. Astron. Soc. Japan, 2014.
- [4] Song Huang et al, “Characterization and Photometric Performance of the Hyper Suprime-Cam Software Pipeline,” Publ. Astron. Soc. Japan, 2014.
- [5] Akisato Kimura et al, “Single-epoch supernova classification with deep convolutional neural networks,” IEEE 37th International Conference on Distributed Computing Systems Workshops (ICDCSW), 2017.
- [6] Jorge de la Calleja et al, “Machine learning and image analysis for morphological galaxy classification,” Monthly Notices of the Royal Astronomical Society, Volume 349, Issue 1, pp. 87-93, 2004.
- [7] Maribel Marin et al, “A Hierarchical Model for Morphological Galaxy Classification,” Proceedings of the Twenty-Sixth International Florida Artificial Intelligence Research Society Conference, 2013.
- [8] I.M.Selim et al, “Galaxy Image Classification using Non-Negative Matrix Factorization,” International Journal of Computer Applications(0975-8887) Volume 137-No.5, 2016.
- [9] Khalifa et al, “Deep Galaxy: Classification of Galaxies based on Deep Convolutional Neural Networks,” arXiv preprint arXiv:1709.02245 (2017).
- [10] D. Tuccillo et al, “Deep learning for galaxy surface brightness profile fitting,” Monthly Notices of the Royal Astronomical Society, Volume 475, Pages 894?909, 2018.