

# 深層学習を用いた相互作用銀河の形態的分類と特徴量抽出

山谷 剛瑠

2026 年 6 月

---

## 概要

相互作用銀河は、潮汐尾、ブリッジ、ディスク構造の歪み、複数の核などの形態的特徴を示すことがあり、銀河進化や相互作用に伴う星形成を理解するうえで重要な対象である。一方で、大規模撮像サーベイでは多数の銀河画像が得られるため、目視のみによる相互作用銀河の探索には限界がある。本研究では、すばる望遠鏡 Hyper Suprime-Cam のアーカイブ画像と GALAXY CRUISE Season 1 カタログを用い、相互作用銀河と非相互作用銀河进行分类する畳み込みニューラルネットワークを構築した。分類ラベルは GALAXY CRUISE における相互作用投票率に基づき、HSC の  $i$  バンド画像を入力として 3 層 CNN による二値分類を行った。テストデータに対する分類性能は Accuracy が 0.894、`interaction` 再現率が 0.877、`non_interaction` 再現率が 0.908 であり、HSC 画像から相互作用銀河を自動分類できる可能性が示された。一方、学習曲線では検証値の大きな変動が見られ、SHAP 値の可視化では対象銀河以外の天体や銀河中心部の寄与が目立った。したがって、現段階のモデルは分類精度を示す一方で、潮汐尾や非対称構造などの低表面輝度構造を安定して捉えているとは言い切れない。今後は、単純なゼロマスクではなく、セグメンテーション、拡大画像、マルチバンド入力、数値シミュレーション、転移学習を組み合わせ、相互作用銀河の形態的特徴をより定量的に扱うことを目指す。

**Keywords:** 相互作用銀河、畳み込みニューラルネットワーク、HSC、GALAXY CRUISE、SHAP

---

## 1 はじめに (Introduction)

銀河同士が重力的に相互作用すると、潮汐尾やブリッジ、ディスクの歪み、複数の核などの構造が現れることがある。また、相互作用に伴ってガス分布が変化し、星形成活動が強まる場合もある。このため、相互作用銀河は銀河進化を考えるうえで重要な研究対象である。

しかし、相互作用銀河の判定はしばしば画像上の形態的特徴に基づく。人間は画像を見て相互作用らしさを判断できる一方で、その判断に使われている特徴がどの程度物理過程と対

応しているかは自明ではない。そこで本研究では、深層学習によって相互作用銀河と非相互作用銀河を分類するモデルを作成し、さらに SHAP 値を用いて、モデルが画像中のどの構造を分類に利用しているかを調べた。本研究の目的は、HSC 画像から相互作用銀河を自動検出する手法を検討するとともに、相互作用銀河の形態と分類に使われる特徴量の関係を定量的に議論することである。

## 2 使用データおよび手法 (Methods)

### 2.1 使用データと分類基準

本研究では、すばる望遠鏡に搭載された Hyper Suprime-Cam による撮像データを使用した [1]。HSC は高解像度かつ広視野の撮像装置であり、g、r、i、z、y<sup>1)</sup> の複数バンドのデータが利用できる。本研究では、まず形態分類に焦点を当てるため、星質量分布を比較的良好に反映すると考えられる i バンド画像を用いた。(表 1 参照)

対象天体の選定には GALAXY CRUISE Season 1 Data Release を用いた [2]。GALAXY CRUISE は市民天文学プロジェクトにより銀河形態の分類を行ったカタログであり、本研究では Tanaka et al. (2023) に基づく相互作用投票率を分類ラベルの基準とした。カタログに記載された赤経・赤緯 (RA, Dec) を用いて HSC アーカイブから画像を取得したため、取得画像では対象銀河が概ね画像中央に位置する。

表 1 使用データの概要

| 項目       | 内容                                  |
|----------|-------------------------------------|
| 撮像データ    | HSC アーカイブ画像                         |
| 使用バンド    | i バンド                               |
| 形態分類カタログ | GALAXY CRUISE Season 1 Data Release |
| 画像サイズ    | 128 pixel × 128 pixel               |
| データ数     | 訓練用 3378、検証用 724、テスト用 725           |
| 入力形式     | 1 チャンネル画像                           |

分類ラベルは、GALAXY CRUISE における相互作用投票率から定義した。投票率を式 (1) のように置く。

$$P_{\text{int}} = \frac{N_{\text{int}}}{N_{\text{all}}} \quad (1)$$

本研究では、 $0.15 \leq P_{\text{int}} \leq 0.79$  にあるような中間的な投票率を持つ銀河は、目視分類上の曖昧さが大きい可能性があるため学習対象から除外し、 $P_{\text{int}} > 0.79$  の銀河を interaction、

1) HSC で使用されている測光系のことで、可視光の波長帯を 5 バンドに分けたものである。g から y にかけて長波長になっていき、g は青や緑、y は近赤外線寄りの有効波長となっている。

$P_{int} < 0.15$  の銀河を `non_interaction` とした。この  $P$  の閾値は2つのクラスのサンプル数に大きな差が出ず、曖昧な分類にならないよう設定した。

## 2.2 データの前処理

画像前処理として、入力画像のサイズを統一するため各画像を切り抜くのではなく 128 pixel  $\times$  128 pixel にリサイズし、画素値を正規化した。この処理ではアスペクト比は保持していない。さらに、極端に暗い画素と明るい画素の影響を抑えるため、下位 1 % 以下の画素値を 1 % の値に、上位 1 % 以上の画素値を上位 1 % の値に置き換えた。一方で、この段階では画像内に写り込む恒星や背景銀河など、対象銀河以外の天体に対する明示的なノイズ除去は行っていない。

## 2.3 CNN による分類と評価方法

分類器には 3 層の畳み込みニューラルネットワークを用いた<sup>2)</sup>。入力はいバンド画像を 1 チャンネルのテンソルとして扱い、出力は `interaction` と `non_interaction` の 2 ラベルとした。最適化手法には Adam を使い、損失関数にはクロスエントロピー誤差を採用した。

評価には、テストデータに対する Accuracy、各クラスの再現率、混同行列を用いた。Accuracy は全テストサンプルのうち正しく分類された割合であり、再現率は各クラスに属する天体のうち、正しくそのクラスとして分類された割合である。さらに、各画素が CNN の分類結果にどのように寄与したかを調べるために SHAP 値を算出した [5]。これにより、分類結果に対して正または負に寄与した画素領域を可視化し、相互作用銀河に特徴的な構造がモデルの判断に反映されているかを確認した。

## 3 結果

テストデータに対する分類性能を表 2 に示す。Accuracy は 0.894、`interaction` 再現率は 0.877、`non_interaction` 再現率は 0.908 であった。i バンド画像のみを用いた 3 層 CNN でも、相互作用銀河と非相互作用銀河の分類に有効な情報を学習できたといえる。

表 2 テストデータに対する分類性能

| 評価指標                             | 値     |
|----------------------------------|-------|
| Accuracy                         | 0.894 |
| <code>interaction</code> 再現率     | 0.877 |
| <code>non_interaction</code> 再現率 | 0.908 |

学習曲線を図 1 に示す。訓練データに対する損失は全体として低下し、訓練データに対する正解率も上昇しているため、学習自体は進行している。一方で、検証損失および検証正解

---

2) CNN に関する詳しい説明はこの文献が参考になる [4]

率は大きく変動しており、汎化性能が安定していない可能性がある。このことから、サンプル数不足や前処理の影響による過学習の可能性が考えられる。




図1 学習曲線。訓練データでは損失の低下と正解率の上昇が見られるが、検証値には大きな変動が見られる。

混同行列を図2に示す。interactionのうち291件を正しく分類し、41件をnon\_interactionと誤分類した。また、non\_interactionのうち357件を正しく分類し、36件をinteractionと誤分類した。2クラス間で極端な偏りは見られないが、相互作用銀河の検出を目的とする場合には、interactionの取りこぼしをさらに減らす必要がある。




図2 テストデータに対する混同行列。

## 4 SHAP 値による特徴量表現の解析

分類器が画像中のどの領域を判断に利用したかを調べるため、SHAP 値を可視化した。図 3 では、赤色の領域が interaction 側に寄与し、青色の領域が反対側のクラスに寄与することを表す。




図 3 SHAP 値の可視化例。銀河中心部のほか、画像左下の対象外天体付近にも寄与が見られる。

SHAP Map では、中心領域にリング状の構造、中心の外縁部に淡い構造、画像左下部の構造が確認された。しかし、寄与が対象銀河のみに集中しているわけではなく、画像内に写る対象外天体の影響も大きい。特に、点状に集中した光源やその周囲が分類に寄与している様子が見られた。これは、CNN が必ずしも潮汐尾や潮汐橋、銀河形状の非対称性といった相互作用銀河に固有の形態だけを学習しているわけではないことを示唆する。

## 5 考察

本研究の分類性能は比較的高く、HSC 画像から相互作用銀河を自動的に分類する手法として CNN が有効である可能性を示した。特に、目視分類に基づく GALAXY CRUISE のカタログを教師データとして用いることで、大規模サーベイ画像に対して機械的な候補抽出を行える見通しが得られた。

一方で、分類精度が高いことと、モデルが物理的に意味のある相互作用構造を見ていることは同じではない。SHAP 値では対象銀河以外の天体や銀河中心部の寄与が目立ち、目的としていた潮汐尾や低表面輝度の連続構造は明瞭ではなかった。低表面輝度構造は背景や周辺天体の影響を受けやすく、パーセンタイル処理やリサイズによって情報が弱まる可能性がある。

また、検証値の変動が大きいことから、学習結果が epoch 数に対して不安定であることも課題である。サンプル数が十分でない場合、CNN は対象銀河の形態ではなく、データセットに偶然含まれる明るい天体や背景構造を分類の手がかりとして利用しやすい。したがって、本研究の現段階での課題は、サンプル数不足による過学習、低表面輝度構造の検出の難しさ、対象銀河以外の写り込みの影響の 3 点に整理できる。

## 6 予備的な改善検討と今後の展望

対象外天体の影響を抑えるため、予備的な改善として、画像中央を中心とする 60 pixel × 60 pixel の正方形領域以外を 0 にするマスク処理を検討した。また、i バンドのみではなく、g、r、i、z、y の 5 バンドを用いる学習も試みた。しかし、この設定では学習結果が片方のクラスに大きく偏り、数 epoch ごとに interaction のみ、または non\_interaction のみを出力するような挙動が見られた。このことから、領域外の画素値を完全に 0 にする単純なマスクは、入力画像の分布を不自然に変化させ、学習を不安定にする可能性がある。

今後の改善方針として、第一に、単純なゼロマスクではなく、対象銀河周辺を拡大して入力する方法を検討する。RA, Dec に基づいたデータ取得を行っていることにより対象銀河は概ね画像中心にあるため、中央領域を利用する方針自体は妥当であるが、周辺部を急に 0 へ置き換える処理は避けるべきである。第二に、セグメンテーション [6] により恒星や背景銀河などを分離し、対象銀河に由来する輝度分布をより明確にする。第三に、銀河衝突の数値シミュレーション画像を観測画像と同様に処理し、相互作用の進行段階に応じた形態の多様性を補う。第四に、Zoobot [9] や ResNet など、既到大規模データで学習されたモデルを利用する転移学習を検討する。特にサンプル数が限られる場合、初期特徴抽出器を一から学習するより、既存モデルを用いて再学習する方が安定した結果を得られる可能性がある。

## 7 結論

本研究では、HSC の i バンド画像と GALAXY CRUISE Season 1 カタログを用いて、相互作用銀河と非相互作用銀河を分類する 3 層 CNN を構築した。テストデータに対して Accuracy 0.894、interaction 再現率 0.877、non\_interaction 再現率 0.908 を得たことから、深層学習による相互作用銀河の自動分類には一定の有効性があると考えられる。

一方で、SHAP 値の解析から、分類器は対象銀河の潮汐構造だけでなく、銀河中心部や周辺天体にも影響を受けていることが分かった。また、検証値の変動が大きく、過学習の可

性能も残る。今後は、セグメンテーション、拡大画像、マルチバンド入力、数値シミュレーション、転移学習を組み合わせ、分類精度だけでなく、相互作用銀河の物理的・形態的特徴をより適切に反映するモデルへ改善する必要がある。

## 謝辞

本研究では、すばる望遠鏡 HSC-SSP 公開データ (PDR3) および HSC アーカイブを使用した。また、形態分類には GALAXY CRUISE Season 1 カタログを用いた。本研究の遂行にあたり、N 高研究部アドバイザーの齋藤隆太様よりご支援・ご協力を賜った。ここに感謝申し上げます。

## 参考文献

- [1]Hyper Suprime-Cam, *HSC-SSP Public Data Release*, <https://hsc-release.mtk.nao.ac.jp/doc/>
- [2]GALAXY CRUISE, *GALAXY CRUISE Season 1 Data Release*, [https://galaxycruise.mtk.nao.ac.jp/en/dr\\_season1.html](https://galaxycruise.mtk.nao.ac.jp/en/dr_season1.html).
- [3]Tanaka, M. et al., PASJ 75, 986 (2023).
- [4]我妻幸長, はじめてのディープラーニング *Python* で学ぶニューラルネットワークとバックプロパゲーション, SB クリエイティブ株式会社 (2018).
- [5]Lundberg, S. M. and Lee, S.-I., *Advances in Neural Information Processing Systems* 30, 4765–4774 (2017).
- [6]Haigh, C. et al., *A&A* 645, A107 (2021).
- [7]Walmsley, M., Smith, L., Lintott, C. et al., *MNRAS* 491, 1554–1574 (2020).
- [8]Walmsley, M., Scaife, A. M. M., Lintott, C. et al., arXiv:2110.12735 (2021).
- [9]Zoobot, <https://github.com/mwalmsley/zoobot>.