

# 植物化石検出のためのスタイル変換を用いた 疑似化石画像自動生成によるデータ拡張

稲村佑哉<sup>†</sup> 和座旭宏<sup>‡</sup> 井上勝文<sup>‡</sup> 吉岡理文<sup>‡</sup> 山田敏弘<sup>††</sup>

大阪府立大学 大学院工学研究科<sup>†</sup> 大阪公立大学 大学院情報学研究科<sup>‡</sup>

大阪公立大学 大学院理学研究科<sup>††</sup>

## 1. はじめに

化石は生物や地球の成り立ちを知るための重要な要素の一つである。化石の発見には時間と労力が必要で、発見数の増加にはアマチュアの参入が不可欠である。しかし、岩肌に露出している化石でさえ、それを化石と見抜くスキルが必要で、これがアマチュアの参入を阻んでいる。このハードルを下げる第一歩として、化石を自動検出するシステムの需要が高まっており、本研究もこれに属す。具体的に本研究では、Deep Neural Network (DNN)による物体検出のアプローチで特に岩肌に露出している植物化石の検出タスクに取り組む。

DNNを用いた手法の学習には大量の画像データが必要とされている。しかし、化石画像には大規模なデータセットが存在せず、アノテーションに専門的な知識が必要であるため、大量の画像を用いた学習は難しい。本研究では問題の解決のために、植物標本画像を岩石画像でスタイル変換し、疑似的な化石画像を生成することで様々な植物の形状と岩石に対応が可能な学習用のデータ拡張手法を提案する。

## 2. 提案手法

提案手法では植物化石の形状を学習するために植物標本画像を用いる。植物標本画像は化石画像と比較して画像枚数が多く、植物が大きく写っている。そのため、植物標本画像を学習に用いることで植物の形状を学習できると考える。しかし、植物標本画像は背景が単色であるものが多く、化石とは大きく異なる。更に、化石となった植物はその色が大きく変化していることが多い。したがって、植物標本画像をそのまま学習に用いた場合、植物化石の検出は難しいと考えられる。

本研究ではこの問題の解決のためにスタイル変換手法である Adaptive Convolution (AdaConv)

Data Augmentation By Automatic Pseudo Fossil Image Generation Using Style Transfer For Plant Fossil Detection

<sup>†</sup>Graduate School of Engineering, Osaka Prefecture University

<sup>‡</sup>Graduate School of Informatics, Osaka Metropolitan University

<sup>††</sup>Graduate School of Science, Osaka Metropolitan University

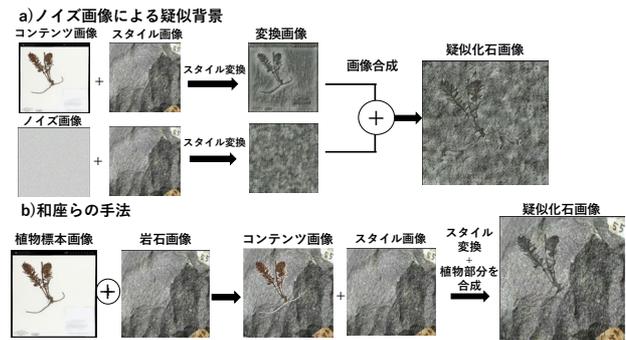


図1: 提案手法での植物標本画像の変換方法

[1]を用いる。これは Adaptive Instance Normalization (AdaIN)の手法[2]を基に、局所的な変換能力を向上させ、個々のスタイル画像について学習が必要ない手法である。

本研究ではスタイル変換した植物標本画像について、植物の部分抜き出し、別の背景画像へ貼り付けることで学習データを生成する。これにより植物部分と背景部分を組み合わせることで複数の画像を生成可能になり、撮影環境などに対して頑健な学習ができると考えられる。提案手法では以下の二種類の背景画像を用いる。一つはノイズ画像をスタイル変換することで得られる疑似的な石のテクスチャを背景画像とする方法である。図1 a)のように植物標本画像も同じ石の画像でスタイル変換することで母岩と同じ色の化石を疑似的に作成する。これにより、母岩との色が似通った化石の学習が可能と考える。

もう一つは和座らの手法[3]のように堆積岩の画像を背景画像とする方法である。和座らは図1 b)のように堆積岩画像に植物標本画像を合成した後、スタイル変換し、得られた画像の植物部分を元の堆積岩画像へ戻すことで、疑似的な化石画像を生成する。これは化石のセグメンテーションのための学習に利用されたが、物体検出の学習にも利用できると考える。

提案手法では一枚の植物標本画像に対して、図1の変換画像のように、画像に手を加えず岩石画像でスタイル変換することで二枚、背景画像を組み合わせた図1a) b)の二つの手法で一枚ずつ、

表1：定量評価

	Average Precision	Recall
<b>ours</b>	<b>0.249</b>	<b>0.336</b>
non-style	0.078	0.169

計四枚の学習データを生成することでデータを拡張する。この時、スタイル画像の岩石はそれぞれ異なる画像を使用する。これにより、実環境に近い画像と植物の形状を学習しやすい画像の両方を学習することが可能になる。

### 3. 実験

#### 3.1 実験条件

植物標本画像は The Herbarium 2021 Half-Earth Challenge Dataset[4]を用いた。これは博物館に保管されている維管束植物の画像分類のためのデータセットであり、250万枚以上の画像が存在する。本実験にはこの中からランダムに800枚を選び、アノテーションして用いた。

提案手法(以下 ours)では Google 画像検索などで入手した岩石画像50枚の中から各変換に対してスタイル画像をランダムに選択し、3200枚のデータセットを生成した。test データには Google 画像検索などで入手した植物化石画像88枚を使用した。物体検出のためのネットワークには、画像内の化石のサイズは撮影条件などによりさまざまであることから、スケールに頑健である Scaled-YOLOv4[5]を用いた。

実験では ours の他に、スタイル変換を行わない植物標本画像のみのデータセットでの学習(以下 non-style)を行い、結果を比較した。

また、ネットワークの学習回数を合わせるため、バッチサイズは4とし、non-style では300エポック、ours では75エポックの学習を行った。

#### 3.2 実験結果

表1に定量評価を示す。定量評価では Average Precision, Recall 共に ours が高い値を示した。この結果から、スタイル変換により植物標本画像の見た目を化石に近づけ、精度を上げることができていると考えられる。

図2に定性評価を示す。図2上段の化石画像は葉の形がはっきりしている画像であり、どちらの手法でも化石が検出されている。しかし、non-style では岩石と背景の境界や画像に写っている指先を化石と判定し、誤検出が多く存在している。一方 ours では植物化石のみを検出している。また、下段の化石画像は化石と岩石の色

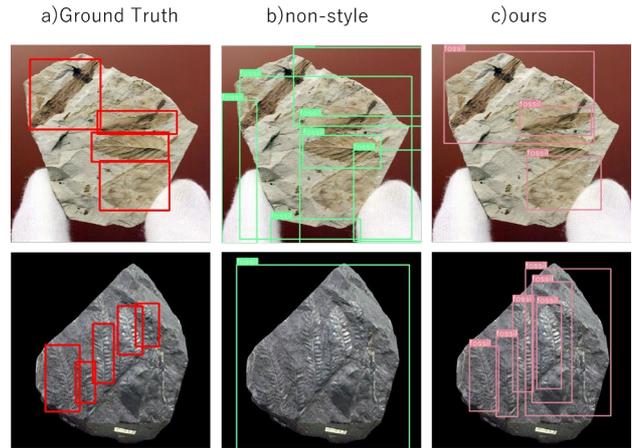


図2：定性評価

が似ており、検出が難しい。non-style の手法では岩石全体を覆う形で検出が行われ、化石の正確な位置を認識できていない。対して ours では植物化石一つ一つを検出している。これらの結果から、スタイル変換によるデータ拡張により誤検出が減少し、検出が難しい化石の検出が可能になっていると考えられる。

#### 4. おわりに

本研究では画像枚数が少ない化石検出のタスクに対して、植物標本画像とスタイル変換を用いた学習用のデータ拡張を提案した。

実験結果から、スタイル変換を用いることでデータの質を高め、様々な植物や岩石に対応した学習が可能になった。今後は植物化石以外の化石検出への利用などが考えられる。

#### 参考文献

[1] P. Chandran et al. Adaptive convolutions for structure-aware style transfer. In Proceedings of the CVPR, pp. 7972-7981, 2021.

[2] X. Huang and S. Belongie. Arbitrary style transfer in real-time with adaptive instance normalization. In Proceedings of the ICCV, pp. 1501-1510, 2017.

[3] 和座旭宏ら. 化石画像セグメンテーションのためのスタイル変換によるデータ拡張. 信学技法, PRMU2022-17, pp. 43-48, 2022.

[4] R. de Lutio et al. The herbarium 2021 half-earth challenge dataset. arXiv preprint arXiv:2105.13808, 2021.

[5] C.-Y. Wang et al. Scaled-yolov4: Scaling cross stage partial network. In Proceedings of the CVPR, pp. 13029-13038, 2021.