

深層学習を用いた孔壁展開画像における亀裂検出

非会員 和田 直史* 非会員 鈴木 利実** 非会員 立野 直樹**

Crack Detection in Borehole-wall Panoramic Images using Deep Learning

Naofumi Wada*, Non-member, Toshimi Suzuki**, Non-member, Naoki Tatsuno**, Non-member

(2023年9月22日受付, 2024年2月15日再受付)

In geological surveys, a borehole camera is used to photograph the vertical cylindrical borehole-wall to investigate underground cracks. Currently, the identification of cracks from borehole-wall images is performed visually by skilled workers, which requires a great deal of time and effort. In this study, we use deep learning to detect sine-curve-like cracks from borehole-wall panoramic images. We designed a two-class classification model that discriminates the presence or absence of cracks using existing network architectures. Furthermore, we introduced a new data augmentation technique called “CyclicShift”, which takes advantage of the unique properties of borehole-wall panoramic images. Through experiments using our own dataset, we showed that both WideResNet and ViT achieve over 98% accuracy under the limited condition of a single crack in one image. Additionally, we confirmed the effectiveness of data augmentation and fine-tuning of pre-trained models. We also demonstrated the potential of using Grad-CAM to locate the positions of cracks.

キーワード: ボアホールカメラ, 孔壁展開画像, 亀裂検出, 深層学習

Keywords: borehole camera, borehole-wall panoramic image, crack detection, deep learning

1. まえがき

地質調査は、構造物建設や防災対策の基礎となる重要な調査である。地質調査におけるボアホールカメラ調査では、地中に垂直円筒状の孔を掘り、その孔にボアホールカメラを入れて孔壁を撮影し、亀裂の幅や方向を調査する。現状、撮影した画像から亀裂箇所を特定する作業は熟練技術者が目視で行っており、多大な時間と労力を要するため、コンピュータによる自動化が望まれている。

そこで、本研究では、円筒状の孔壁を平面に展開した孔壁展開画像からサインカーブ状の亀裂を画像認識技術を用いて検出することを目的とする。具体的には、深層学習を用いた2クラス分類により、画像中の亀裂の有無を判別する。

ここでは、ResNetやViTなど既存のネットワークアーキテクチャを使用し、独自に構築した学習用データセットを用いて各モデルの判別精度を評価する。また、孔壁展開画像の特性を利用した新たなデータ拡張手法として「CyclicShift」を提案し、実験によりその有効性を示す。さらに、Grad-CAMを用いて分類モデルの判断根拠を可視化することにより、亀裂の有無だけでなく、画像内の亀裂の位置を特定することが可能であることを示す。

以下、2章では、本研究で使用するボアホールカメラと孔壁展開画像について述べる。3章では、深層学習モデルについて述べ、4章では、我々が構築したデータセットおよびデータ拡張について述べる。5章では、亀裂有無の判定に関する実験結果を示し、6章では、亀裂箇所の特定に関する実験結果を示す。最後に、7章でまとめを述べる。

2. ボアホールカメラと孔壁展開画像

本研究では、ボアホールカメラとしてBIPシステム (Borehole Image Processing System)⁽¹⁾を使用する。BIPシステムは、Fig. 1のように、プローブの先端に可視光カメラと円錐鏡が備え付けられている。この円錐鏡の側面に映った孔壁全周 (Fig. 1中の“Scan line”)をラインスキャンすることによって円筒状の孔壁画像を撮影し、平面に展開する

* 北海道科学大学

〒006-8585 北海道札幌市手稲区前田7条15丁目4-1
Hokkaido University of Science
15-4-1, Maeda 7-jo, Teine-ku, Sapporo, Hokkaido 006-8585,
Japan

** (株)レアックス

〒065-0024 北海道札幌市東区北24条東17丁目1-12
RaaX Co., Ltd.
1-12, Higashi 17-chome, Kita 24-jo, Higashi-ku, Sapporo,
Hokkaido 065-0024, Japan

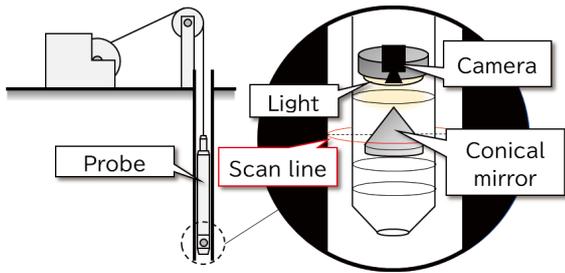


Fig. 1. Borehole camera.

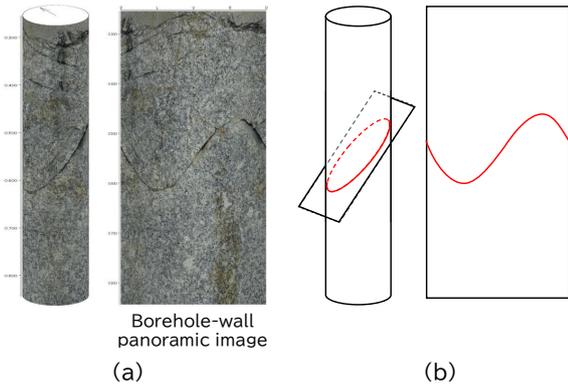


Fig. 2. Borehole-wall panoramic image.

ことで孔壁展開画像を生成する。円錐鏡方式は、広角レンズや魚眼レンズを用いた方式に比べ、撮影した画像に歪みが少ないという利点がある。

孔壁展開画像の例を Fig. 2 に示す。Fig. 2 (a) は、実際に撮影した画像であり、左が円筒状の孔壁画像、右が孔壁展開画像である。また、Fig. 2 (b) は、Fig. 2 (a) 中の亀裂の見え方を示した模式図であり、孔壁画像における断面は、孔壁展開画像上でサインカーブ状となって現れることがわかる。このサインカーブ状の亀裂を解析することにより、地質調査に必要な亀裂の数や幅、走向傾斜などの情報を得ることができる。一方で、1 章でも述べたように、孔壁展開画像上の亀裂箇所の特定やサインカーブによる近似は、熟練技術者が手作業で行わなければならないという課題がある。

3. 亀裂検出のための深層学習モデル

画像から亀裂を検出する手法については、古くから数多く研究がなされている。亀和田ら⁽²⁾は、本研究と同様に孔壁展開画像を対象とし、コントラスト補正やメディアンフィルタ、エッジ検出などの基本的な画像処理を用いて亀裂検出を試みている。しかしながら、多様な色や明るさ、複雑なテクスチャを持つ地層画像では、検出対象であるサインカーブ状の亀裂以外のエッジを過剰に検出してしまうという問題があった。

一方、類似の研究として、建物のコンクリート壁や道路のアスファルトにおける亀裂 (割れ目、ひび割れ、変状などとも呼ばれる) の検出に関する研究が多く存在する^{(3)~(6)}。近年は深層学習を用いた手法が主流であり、主に [1] 画像分類、[2] 物体認識、[3] セマンティックセグメンテーシ

ンの 3 つに大きく分類される⁽⁶⁾。亀裂の有無を検出するレベルは、[1] が画像単位、[2] が領域単位、[3] が画素単位となり、[1]~[3] の順に検出難易度が上がる。また、教師あり学習のアノテーション作業も、一般的には同じ順番で難易度・時間・労力が増していく。深層学習モデルに関しては、畳込みニューラルネットワーク (CNN) をベースとしたものが多く、画像分類では VGG⁽⁷⁾ や ResNet⁽⁸⁾、物体認識では YOLO⁽⁹⁾、セマンティックセグメンテーションでは U-Net⁽¹⁰⁾ などが使用されている。また、近年は Transformer をベースとしたモデルも検討されている⁽¹¹⁾。しかしながら、文献 (3)~(6) (11) は、いずれも孔壁展開画像を対象としたものではなく、また、特定の形状の亀裂を検出対象としたものではない。本研究では、孔壁展開画像を対象とし、「サインカーブ状」という特定の形状特徴を持つ亀裂を検出する深層学習モデルの構築を目指す。

本稿では、[1] の画像分類を用いる。その理由として、アノテーションの容易さが挙げられる。孔壁展開画像は、コンクリート壁などに比べて岩盤などのテクスチャが複雑であり、人手による画素レベルのアノテーションが困難である。画素レベルの正解付けは熟練技術者であっても判断が曖昧となる可能性があるため、画像内の亀裂の有無のみを判別する 2 クラス分類モデルとし、教師データ作成コストを軽減する。一方、実際の現場作業を自動化するためには、亀裂の有無だけでなく、亀裂の位置や形状まで認識する必要がある。本研究では、亀裂位置を特定した後に亀裂形状を推定する 2 段階の処理を想定し、まずは縦に長い孔壁展開画像から亀裂の位置を絞り込む。ここでは、亀裂有無の判別に加え、分類モデルの判断根拠を可視化する Class Activation Mapping (CAM) により亀裂箇所を特定する方法の可能性について検討する。

4. データセットとデータ拡張

〈4・1〉 データセット 2 章で述べた BIP システムを使用して実際に撮影した 1,220 本の孔壁展開画像を用いて学習用データセットを構築した。孔壁展開画像のサイズは、横幅が 360 pixel または 720 pixel であり、縦幅は孔の深さによって異なる。データセットを作成するにあたり、まず、全ての孔壁展開画像の横幅を 256 pixel になるようリサイズした。次に、1 枚の画像が 256×256 pixel となるように、1 本の孔壁展開画像から領域を切り出した。ここでは、64 pixel ずつオーバーラップさせながら領域を切り出し、1,220 本の孔壁展開画像から 347,753 枚の画像データを作成した。さらに、抽出した画像データを Fig. 3 に示すように次の 5 種類に分類した。

- (1) No crack … 亀裂がない
- (2) Single crack (center) … 画像中央付近に亀裂が一つある
- (3) Single crack (aside) … 画像端付近に亀裂が一つある
- (4) Partial crack … 亀裂の一部分だけがある
- (5) Multi crack … 亀裂が二つ以上ある

本論文では、検討の初期段階として、(1) No crack と (2) Single crack (center)のみを使用する。(3) Single crack (aside), (4) Partial crack, (5) Multi crack に関しては、「サインカーブ状」という亀裂の形状特徴を学習する上でノイズとなるため、ここでは対象外とした。このような複雑な亀裂への対応は今後の課題とする。使用した画像の例をそれぞれ Fig. 4 に示す。実験では、これらの画像群を訓練用、検証用、評価用に分割して用いる。この際、訓練用、検証用、評価用がそれぞれ異なる孔壁展開画像から抽出したデータとなるように分割した。

〈4・2〉 データ拡張 〈4・1〉節では亀裂の条件を限定することにより、モデルが学習すべき特徴を単純化した。しかしながら、条件を限定したことで訓練データの数が少な

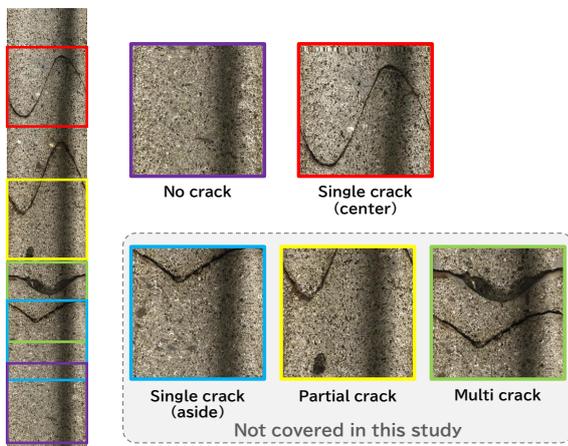


Fig. 3. Examples of image data extracted from a borehole-wall panoramic image.

くなり、識別精度や汎化性能が低下する恐れがある。これを防ぐ方法として、データ拡張 (Data Augmentation) を導入する。

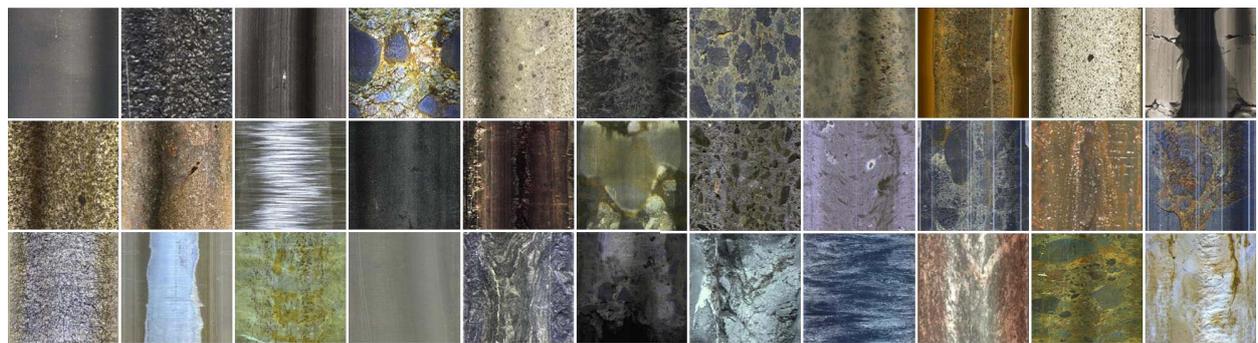
ここでは、一般的なデータ拡張である水平・垂直方向回転の他に、孔壁展開画像特有の性質を利用した新たな拡張手法を導入する。孔壁展開画像は、もともと円筒状の孔壁を展開したものであるため、画像の端は連続している。つまり、展開する際にどこで切断するか (切断線) によって異なる孔壁展開画像を作成することが可能である。この性質を利用し、画像の横幅 W に対して分割数 $N (< W)$ を設定し、 N 個の等間隔で短冊状の切断線を考えることで 1 枚の画像から N 枚の画像を生成することができる。 $N = 4$ としたときの例を Fig. 5 に示す。Fig. 5 における $P_0 \sim P_3$ が切断線であり、左からそれぞれ P_0, P_1, P_2, P_3 を切断線とした画像である。このデータ拡張手法を、新たに“CyclicShift”と呼ぶ。

5. 評価実験 I – 亀裂有無の判定 –

〈5・1〉 実験条件 亀裂の有無を判別する 2 クラス分類モデルの精度を実験により評価する。モデルは、19 層の VGG⁽⁷⁾ (以下、VGG19)、50 層の ResNet⁽⁸⁾ (以下、ResNet50)、50 層の ResNeXt⁽¹²⁾ (以下、ResNeXt50)、50 層の WideResNet⁽¹³⁾ (以下、WideResNet50)、パッチサイズ 8×8 で Base モデルの Vision Transformer⁽¹⁴⁾ (以下、ViT.l8) の 5 種類を用いた。学習および評価に使用するデータセットは、〈4・1〉節で述べた亀裂あり (Single crack (center)) と亀裂なし (No crack) の 2 種類を使用し、訓練



(a) “Single crack (center)” images



(b) “No crack” images

Fig. 4. Examples of “Single crack (center)” and “No crack” images in the dataset.

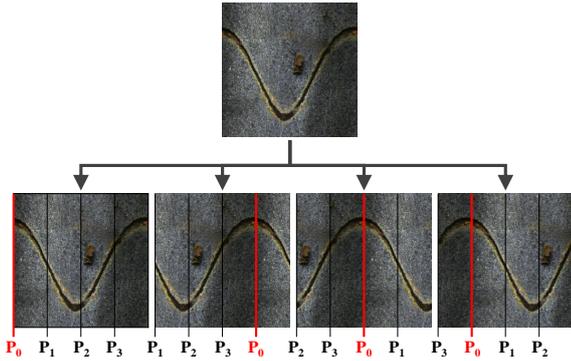


Fig. 5. Examples of CyclicShift ($N = 4$).

Table 1. Performance evaluation of crack detection by image classification models.

Model	Accuracy	Precision	Recall	F1-score
VGG19	0.970 ±0.005	0.965 ±0.006	0.973 ±0.011	0.969 ±0.006
ResNet50	0.955 ±0.005	0.983 ±0.006	0.922 ±0.011	0.952 ±0.006
ResNeXt50	0.973 ±0.010	0.981 ±0.007	0.963 ±0.019	0.971 ±0.011
WideResNet50	0.983 ±0.008	0.982 ±0.009	0.983 ±0.013	0.982 ±0.008
ViT_b8	0.982 ±0.006	0.984 ±0.007	0.979 ±0.013	0.982 ±0.006

用 2,628 枚 (亀裂有 1,297 枚, 亀裂無 1,331 枚), 検証用 176 枚 (亀裂有 76 枚, 亀裂無 100 枚), 評価用 194 枚 (亀裂有 94 枚, 亀裂無 100 枚) とした。画像サイズは全て 256×256 pixel である。また, 訓練時は水平方向反転, 垂直方向反転, 〈4・2〉節で述べた CyclicShift の 3 種類のデータ拡張を適用した。CyclicShift の分割数 N は 32 とした。訓練時のハイパーパラメータは, バッチサイズを 16/GPU, 学習率の初期値を 1.0×10^{-4} , エポック数を 100 epoch とし, 学習率を 10 epoch ごとに半減させた。最適化手法は Adam を用いた。また, ImageNet⁽⁴⁵⁾ で事前学習されたモデルをファインチューニングすることにより学習を行った。実行するプログラムは乱数で決まる要素を含むため, 同じ条件で 10 回試行した結果を評価する。

〈5・2〉 実験結果 実験の結果を Table 1 および Fig. 6 に示す。Table 1 は, 各モデルに対して学習・評価をそれぞれ 10 回ずつ試行した際の Accuracy, Precision, Recall, F 値の平均値および標準偏差を示したものである。また, Fig. 6 は Accuracy の分布をボックスプロットにより表したグラフである。Table 1 および Fig. 6 より, WideResNet50 と ViT_b8 の精度が高く, 識別率 98% 以上を達成している。最も精度が低かった ResNet50 でも 95% 以上の識別率となった。一方, 今回使用した亀裂ありの画像は, 画像中央付近に一つの亀裂が存在する場合のみを扱っているため, 〈4・1〉節で述べた複数の亀裂や部分的な亀裂などは今後検討が必要となる。

〈5・3〉 データ拡張および事前学習の効果 データ拡張および事前学習の効果について実験により検証を行った。実験結果を Table 2~4 に示す。データ拡張と事前学習以外の実験条件は〈5・1〉節と同様であり, 各表の数値は Accuracy の平均値である。

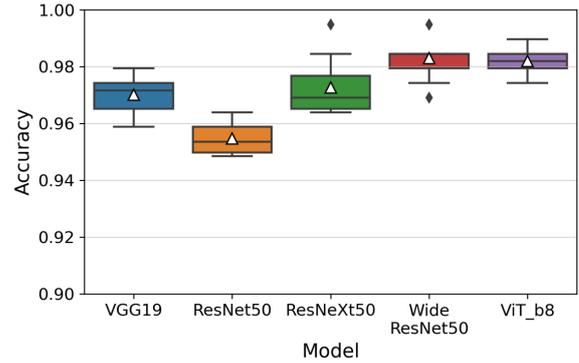


Fig. 6. Comparison of accuracy in each model.

Table 2. Comparison of accuracy to show the effects of data augmentations in each model (without pre-training).

Model	HF: Horizontal Flip, VF: Vertical Flip, CS: CyclicShift					
	w/o Aug.	HF+VF	CS(4)	CS(8)	CS(16)	CS(32)
VGG19	0.943	0.973	0.956	0.962	0.968	0.952
ResNet50	0.796	0.904	0.832	0.834	0.877	0.891
ResNeXt50	0.794	0.905	0.798	0.801	0.857	0.881
WideResNet50	0.849	0.921	0.864	0.861	0.920	0.939
ViT_b8	0.718	0.748	0.729	0.738	0.752	0.794
Average	0.820	0.890	0.836	0.839	0.875	0.891

†The number in parentheses of CS indicates the number of partitions, N

Table 3. Comparison of accuracy with and without pre-training in each model (without augmentation).

Model	(A)	(B)	(B)-(A)
	No pre-trained	Pre-trained	
VGG19	0.943	0.975	+0.032
ResNet50	0.796	0.946	+0.150
ResNeXt50	0.794	0.969	+0.175
WideResNet50	0.849	0.977	+0.128
ViT_b8	0.718	0.900	+0.182

Table 4. Comparison of accuracy to show the effects of data augmentations in each model (with pre-training).

Model	HF: Horizontal Flip, VF: Vertical Flip, CS: CyclicShift		
	w/o Aug.	HF+VF	HF+VF +CS(32)
VGG19	0.975	0.972	0.970
ResNet50	0.946	0.949	0.955
ResNeXt50	0.969	0.962	0.973
WideResNet50	0.977	0.972	0.983
ViT_b8	0.900	0.950	0.982
Average	0.953	0.961	0.973

†The number in parentheses of CS indicates the number of partitions, N

Table 2 は, データ拡張の効果を示している。ここでは, データ拡張なし (w/o Aug.) に対して, 水平・垂直方向反転 (HF + VF) または CyclicShift (CS) によるデータ拡張を適用した。CS における括弧内の数字は分割数 N を表し, 訓練データ数が N 倍に増加することを意味している。なお, 事前学習はおこなっていない。Table 2 より, いずれのデータ拡張もデータ拡張なしと比べて Accuracy が向上しており, データ拡張の有効性が確認できた。一方, HF+VF と CS(4) を比較すると, データ数を 4 倍に増やす効果は同じであるが, CS(4) は HF+VF に比べて改善幅が小さくなっ

た。CyclicShift は N を増やすことによって Accuracy が向上しており、 $N = 32$ では WideResNet50 と ViT_b8 で最も高い値を示し、CyclicShift の有効性を確認できた。

Table 3 は、事前学習の効果を示している。なお、データ拡張は起こっていない。Table 3 より、全てのモデルにおいて、事前学習をおこなわない場合 (A) よりも事前学習済みモデルをファインチューニングした場合 (B) の Accuracy が向上した。特に、VGG19 以外の 4 つのモデルで改善幅が大きく、ViT_b8 で最も大きい改善幅を示した。一般的に、Transformer は CNN に比べて大量の学習データを必要とするため、限られたデータで効果を得るためには事前学習済みモデルをファインチューニングする方法が効果的である。本実験においても ViT における事前学習の有効性が確認できた。

Table 4 は、事前学習済みモデルに対するデータ拡張の効果を示している。データ拡張なし (w/o Aug.) に対して、水平・垂直方向反転 (HF+VF)、 $N = 32$ の CyclicShift (CS(32)) を順に追加した。Table 4 より、ViT_b8 を除く 4 つのモデルでは、Table 2 と比較してデータ拡張の効果が小さくなった。一方、ViT_b8 では、データ拡張の効果が他のモデルに比べて大きく、事前学習済みモデルにおいてもデータ拡張が精度向上に寄与することが確認できた。これは、ViT が訓練データの増加による性能改善の余地をより多く残していることを示唆していると考えられる。

6. 評価実験 II – 亀裂箇所の特定 –

5 章では画像ごとに亀裂の有無を判定したが、最終的には亀裂のサインカーブを特定し、孔壁展開画像における亀裂の位置や幅、向きなどを分析する必要がある。そのため、画像中の亀裂箇所を特定する方法として、Class Activation Map (CAM) の情報を利用することを考える。Table 1 で識別率の高かった WideResNet50 と ViT_b8 に対して、Grad-CAM⁽¹⁶⁾ を適用した例をそれぞれ Fig. 7 に示す。Fig. 7 の一番左の列は入力画像、中央が WideResNet50、右が ViT_b8 における Grad-CAM の結果がヒートマップで示されたものであり、亀裂ありと判定した判断根拠となる箇所が赤く色づけされている。Fig. 7 より、WideResNet50 ではサインカーブの山や谷付近の一部のみが赤くなっている。このような傾向は、CNN をベースとした VGG19, ResNet50, ResNeXt50 でも同様であった。それに対し、Transformer をベースとした ViT_b8 では、Fig. 7 の上から 3 つの画像で亀裂のサインカーブに沿って全体的に赤色が現れている。これは CNN が周辺の画素の情報を見ているのに対し、Transformer がパッチ間の関係から画像全体の情報を見ているという違いが考えられる。今後、亀裂のサインカーブを推定するために ViT における Grad-CAM の結果を利用できる可能性があることがわかった。

一方、ViT_b8 では、Fig. 7 最下段のように亀裂上が赤くならない画像も見られた。そこで、ViT における CAM の精度および安定性を評価するため、5 章で使用した評価用の

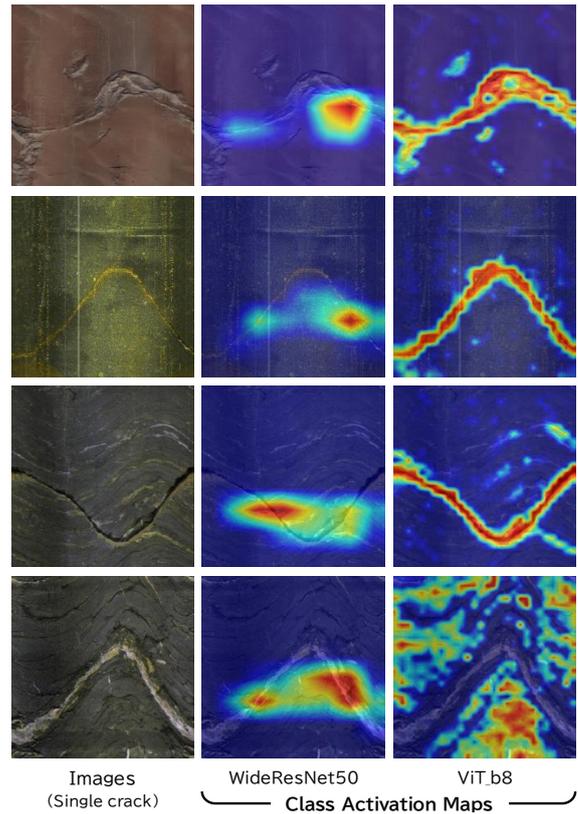


Fig. 7. Results of Grad-CAM on WideResNet50 and ViT_b8.

Table 5. Comparison of crack detection rates on CAM of ViT_b8 to show the effects of data augmentations.

HF: Horizontal Flip, VF: Vertical Flip, CS: CyclicShift		
w/o Aug.	HF+VF	HF+VF +CS(32)
27.9 ± 11.1 %	43.0 ± 14.1 %	61.7 ± 15.1 %

†The number in parentheses of CS indicates the number of partitions, N

亀裂あり画像 94 枚に対して、CAM の赤色領域が亀裂上に現れているか否かを目視により判定し、正しくサインカーブ状に出現している割合 (以下、成功率) を調査した。また、Table 4 と同様の実験条件でデータ拡張の効果を確認した。各条件における成功率の平均と標準偏差を Table 5 に示す。Table 5 より、データ拡張を適用しない場合の成功率は約 28% であり、データ拡張の水平・垂直方向反転を適用した場合は約 43%、さらに、CyclicShift を追加した場合は約 62% となった。また、Fig. 8 の CAM の例を見ると、データ拡張を適用することで赤色領域がより明確に亀裂上に現れている。これらの結果から、データ拡張が CAM による亀裂位置特定の精度向上に有効であることが確認できた。しかしながら、安定的にサインカーブを推定するためには成功率が十分とは言えず、また、標準偏差が 10% 以上とばらつきも大きい。したがって、ViT における CAM の精度および安定性の改善が今後の課題である。

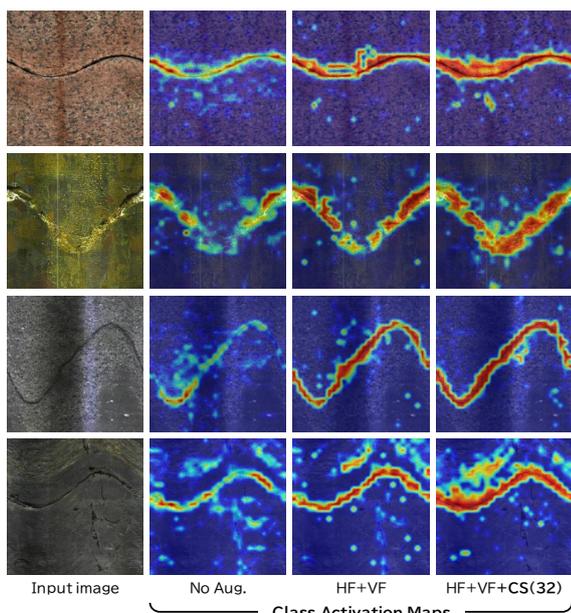


Fig. 8. CAMs of ViT_b8 to show the effects of data augmentations.

7. むすび

本論文では、ボアホールカメラで撮影した孔壁展開画像におけるサインカーブ状の亀裂を深層学習を用いて検出する方法について検討を行った。深層学習モデルは、既存のネットワークアーキテクチャを使用し、亀裂の有無を判別する2クラス分類モデルとした。また、孔壁展開画像特有の性質を利用した新たなデータ拡張手法として **CyclicShift** を導入した。独自データセットを用いた実験の結果、1枚の画像に1つの亀裂があるという限定的な条件下ではあるが、98%以上の精度が得られることを確認した。さらに、データ拡張や事前学習済みモデルのファインチューニングが有効であることを確認した。また、**Grad-CAM** を用いて判断根拠の可視化を行った結果、ViTを用いた場合に亀裂箇所を特定できる可能性があることを示した。

一方、本研究の最終目的は亀裂のサインカーブ形状を推定することであり、亀裂の位置特定はその前処理という位置づけである。今回、亀裂有無の判別に関しては高い精度が得られたものの、**Class Activation Map (CAM)** による位置特定精度および安定性に関しては検討の余地が残されている。今後は、CAMによる位置特定精度の向上を図るとともに、CAMからサインカーブ形状を推定する手法について検討する。また、複数の亀裂や部分的な亀裂への対応についても検討を進め、孔壁展開画像における亀裂解析の自動化を目指す。

文 献

(1) S. Kamewada, T. Endo, H. Kokubu, and Y. Nishigaki: "The Device and Features of BIP System", Proc. of the Symposium on Rock Mechanics, Vol.21, pp.196-200 (1989) (in Japanese)

亀和田俊一・遠藤 努・国分英彦・西垣好彦:「BIP システムの装置とその能力について」, 第 21 回岩盤力学に関するシンポジウム講演論文集, Vol.21, pp.196-200 (1989)

(2) S. Kamewada, T. Endo, Y. Nishigaki, and T. Sugie: "Image Processing Technique for Borehole Walls and Its Image Recognition", Journal of the Japan Society of Engineering Geology, Vol.34, No.6, pp.309-317 (1994) (in Japanese)

亀和田俊一・遠藤 努・西垣好彦・杉江剛史:「ボーリング孔壁画像処理手法とその解析について」, 応用地質, Vol.34, No.6, pp.309-317 (1994)

(3) H. Nagaya, T. Asada, and S. Kameyama: "Development of A Method to Determine The Cause of Cracks in Pavement using An Explainable AI", Journal of Japan Society of Civil Engineers, Ser.E1 (Pavement Engineering), Vol.77, No.1, pp.28-38 (2021) (in Japanese)

長屋弘司・浅田拓海・亀山修一:「説明可能な AI を用いた舗装のひび割れ発生原因判別手法の開発」, 土木学会論文集 E1 (舗装工学), Vol.77, No.1, pp.28-38 (2021)

(4) Y. Nomura, S. Murao, Y. Sakaguchi, and H. Furuta: "Crack Detection System for Concrete Surface based on Deep Convolution Neural Network", Journal of Japan Society of Civil Engineers, Ser.F6 (Safety Problem), Vol.73, No.2, pp.189-198 (2017) (in Japanese)

野村泰稔・村尾彩希・阪口幸広・古田 均:「深層畳み込みニューラルネットワークに基づくコンクリート表面のひび割れ検出システム」, 土木学会論文集 F6 (安全問題), Vol.73, No.2, pp.189-198 (2017)

(5) Q. Zou, Z. Zhang, Q. Li, X. Qi, Q. Wang, and S. Wang: "DeepCrack: Learning Hierarchical Convolutional Features for Crack Detection", IEEE Trans. on Image Processing, Vol.28, No.3, pp.1498-1512 (2019)

(6) Y. Hamishebahar, H. Guan, S. So, and J. Jo: "A Comprehensive Review of Deep Learning-based Crack Detection Approaches", Applied Sciences, Vol.12, No.3, 1374 (2022)

(7) K. Simonyan and A. Zisserman: "Very Deep Convolutional Networks for Large-scale Image Recognition", International Conference on Learning Representations (ICLR), (2015)

(8) K. He, X. Zhang, S. Ren, and J. Sun: "Deep Residual Learning for Image Recognition", IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), (2016)

(9) J. Redmon, S. Divvala, R. Girshick, and A. Farhadi: "You Only Look Once: Unified, Real-Time Object Detection", IEEE Conf. on Computer Vision and Pattern Recognition (CVPR) (2016)

(10) O. Ronneberger, P. Fischer, and T. Brox: "U-Net: Convolutional Networks for Biomedical Image Segmentation", International Conf. on Medical Image Computing and Computer-Assisted Intervention (MICCAI) (2015)

(11) H. Liu, X. Miao, C. Mertz, C. Xu, and H. Kong: "CrackFormer: Transformer Network for Fine-grained Crack Detection", IEEE/CVF International Conf. on Computer Vision (ICCV) (2021)

(12) S. Xie, R. Girshick, P. Dollár, Z. Tu, and K. He: "Aggregated Residual Transformations for Deep Neural Networks", IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), (2017)

(13) S. Zagoruyko and N. Komodakis: "Wide Residual Networks", British Machine Vision Association (BMVC), (2016)

(14) A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. Weissenborn, X. Zhai, T. Unterthiner, M. Dehghani, M. Minderer, G. Heigold, S. Gely, J. Uszkoreit, and N. Houlsby: "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale", International Conf. on Learning Representations (ICLR), (2021)

(15) J. Deng, W. Dong, R. Socher, L. Li, K. Li, and L. Fei-Fei: "ImageNet: A Large-Scale Hierarchical Image Database", IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), (2009)

(16) R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra: "Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization", IEEE International Conf. on Computer Vision (ICCV), (2017)

和田直史 (非会員) 2002年北海道大学工学部卒業, 2004年同大学大学院工学研究科修士課程修了。2015年同大学大学院情報科学研究科博士課程修了。2004-2009年(株)東芝, 2009-2016年(株)サムスン日本研究所にて勤務。2016年北海道科学大学講師。2020年同大学准教授。画像映像処理の研究に従事。電子情報通信学会, 映像情報メディア学会, 情報処理学会, 精密工学会各会員。博士(情報科学)。



鈴木利実（非会員）1995年札幌ソフトウェア専門学校卒業，1995年（株）レアックス入社。地質調査部門，機器開発部門を経て，営業部門に異動後の2016年2月から2019年2月まで，ボリビアでのJICA・中小企業海外展開支援事業「効果的な診断・改修による井戸の長寿命化普及・実証事業」に従事。



立野直樹（非会員）1987年日本工学院北海道専門学校卒業，1987-1991年丸和電機（株），1991-1994年（有）マキシマ札幌にて勤務。1994年（株）レアックス入社。社内製品，受託開発製品のソフトウェア制作に従事。

