

X線 CT 画像の深層学習を用いた農業水利施設により採取した
コンクリートコアのひび割れ検出
Crack Detection for Concrete Core taken from Irrigation and Drainage Structures
by Deep Learning of X-ray CT Images

○池田弘毅*, 柴野一真**, 向井萌華**, 鈴木哲也***

○Koki IKEDA*, Kazuma SHIBANO**, Moeka MUKAI** and Tetsuya SUZUKI***

1. はじめに

コンクリート材料に対する X 線 CT 法は、損傷の進展評価や弾性波伝播のシミュレーションなど、コンクリート内部における物理現象の解明に用いられている。これらの解析は、コンクリート内部構造の幾何学的特徴を基に実施されている。内部構造の検出精度を向上させるために、高度な画像処理手法の開発が進められており、これまでに多様な手法が提案されてきた。本研究では、深層学習を用いてコンクリート内部構造の検出を試みた。

2. 解析方法および実験方法

既設の 7 基の鉄筋コンクリート水利施設から採取されたものに加え、実験室で作製した供試体の CT 画像を使用した。

本研究では、深層学習モデルの訓練と精度検証には、CT 画像とそれに対応するアノテーション画像のペアを用いた。アノテーション画像は手動で作成し、各ピクセルに対して正確なラベルを付与した。

コンクリート供試体の CT 画像を軸方向に沿って取得し、ボクセルデータから矢状面(A面)、冠状面(B面)、横断面を抽出した。入力画像は 512×512 pixels にトリミングし、画像の実スケールとの整合性を保つため、リサイズ処理は行っていない。

計 591 枚の X 線 CT 画像を用い、581 枚を訓練用、10 枚をテスト用としてセマンティックセ

グメンテーションのモデル構築を行った。データ分割には Hold-out 法を用い、訓練データのうち 90%を学習用、10%を評価用とした。モデルには U-Net を採用し、アーキテクチャは Fig. 1 に示す。最適化手法には Adam を使用し、学習の安定性と収束性を確保した。活性化関数はクロスエントロピー損失 (Cross Entropy Loss) を用いた。モデル評価には混同行列を用い、macro-F1 スコアを指標として性能を定量的に検証した。

3. 結果および考察

損傷検出における分類方式の違いがひび割れ検出精度に与える影響について検討した。

Table 1, 2 に、2 クラス分類および多クラス分類による分類結果を示す。ひび割れを正しくひび割れとして分類できた割合は、2 クラス分類

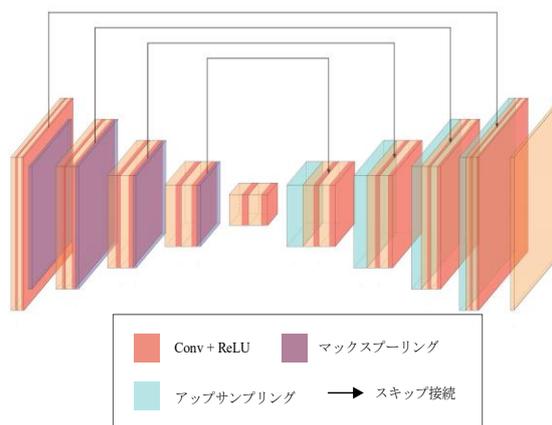


Fig. 1 U-Net アーキテクチャ
U-Net Architecture

*新潟大学農学部 Faculty of Agriculture, Niigata University

**新潟大学大学院自然科学研究科 Graduate School of Science and Technology, Niigata University

***新潟大学自然科学系(農学部) Institute of Agriculture, Niigata University

キーワード: X線 CT, U-Net, 機械学習, ひび割れ, セグメンテーション, 頭首工, 開水路

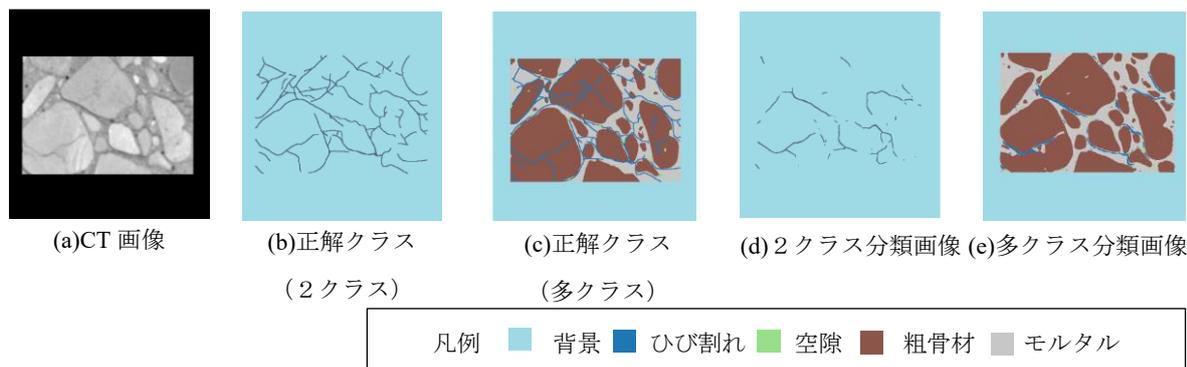


Fig. 2 ひび割れの2クラスおよび多クラス分類結果

2 classes and multi-class of cracks classification results

で7%, 多クラス分類で12%であった。2クラス分類においては、非ひび割れクラスに空隙、粗骨材、モルタル、および背景がすべて含まれる。Kimらの報告では、異質な要素が混在するクラスではクラスの特徴表現が貧弱となり、識別性能が低下する可能性があるとして指摘されている¹⁾。これら非ひび割れに分類される要素は形状が多様であり、形状表現が過度に一般化される傾向にある。その結果、ひび割れとの識別が困難となり、検出精度が低下すると考えられる。一方、多クラス分類では、非ひび割れ部を細分化しひび割れとの境界が明確化され、識別空間におけるクラス間の分離性が向上した。Fig. 2に、ひび割れ分類結果の一例を示す。コントラストの高いひび割れ部では正しく検出されていたが、粗骨材とモルタルが接する境界付近では、ひび割れの未検出が顕著であった。Cheniourらは、ラベル付けが困難な曖昧な領域において、アノテーションの質が分類性能に影響を与えることを指摘している²⁾。2クラス分類および多クラス分類のF1スコアおよびmacro-F1はそれぞれ0.409, 0.660であった。

4. おわりに

本研究では、コンクリートのX線CT画像に対するひび割れ検出にU-Netを適用し、多クラスラベルの付与によって検出性能が向上することを示したが、微細なひび割れや粗骨材とモルタルの界面に生じるひび割れの

Table 1 2クラス分類結果

2-class classification results

		予測	
		ひび割れ	非ひび割れ
正解	ひび割れ	0.07	0.93
	非ひび割れ	0.00	1.00

Table 2 多クラス分類結果

Multi-class classification results

		予測				
		1	2	3	4	5
正解	1	0.12	0.00	0.11	0.77	0.00
	2	0.01	0.60	0.06	0.31	0.01
	3	0.00	0.00	0.90	0.10	0.00
	4	0.01	0.00	0.16	0.83	0.00
	5	0.00	0.00	0.00	0.00	1.00

* クラス1：ひび割れ，2：空隙，3：粗骨材，4：モルタル，5：背景

検出には課題が残った。今後は、不明瞭な境界を扱えるセグメンテーションモデルの導入により、検出精度のさらなる向上を図る必要がある。

引用文献

- Kim, B., Cho, S. (2018) : Automated vision-based detection of cracks on concrete surfaces using a deep learning technique, *Sensors*, 18(10), 3452.
- Cheniour, A., et al. (2024) : A mesoscale 3D model of irradiated concrete informed via a 2.5 U-Net semantic segmentation, *Construction and Building Materials*, Vol. 412, 134392.