

# 物体検出を用いたマルチスケールなひび割れの検出手法に関する研究

茨城大学 学生会員 ○XIONG ZELONG

茨城大学 正会員 吳 智深

茨城大学 正会員 車谷 麻緒

## 1. はじめに

近年、深層学習を活用したひび割れの検出が注目されている。カメラ設備の発展に伴い、高解像度の写真を撮り、遠くから撮った写真でもひび割れを検出することが可能になった。しかし、高解像度の画像をネットワークに学習させるには、必要な計算量が膨大で、ネットワークも有意な特徴を抽出することが困難であり、検出結果がなかなかうまく行かない。よって、ネットワークにひび割れの特徴をうまく抽出させることは、検出精度の向上や効率化を図る上で、重要な課題であった。

Young-Jin<sup>2)</sup>らは、スライディングウィンドウ法で大画像を小画像に切り出し、大画像から微小ひび割れを検出することができた。しかし、切り出した画像が増えるほど、検出に要する時間は倍に増加する。

寺野<sup>3)</sup>らは、畳み込みニューラルネットワーク(CNN)でひび割れ判別器を作った。この判別器を使用して、ひび割れのある小画像のみセマンティックセグメンテーションを行うことができた。しかし、モデル自体は、小画像の位置情報を得ることができないので、抽出したひび割れの位置も分からなくなった。

そこで本研究は、セマンティックセグメンテーションすべき領域を減らす同時にひび割れの位置情報も得ることができる物体検出モデルを作成し、有用性評価を行った。

研究手法の流れは、図-1 に示す。

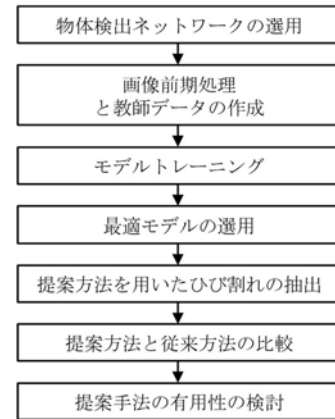


図-1 研究手法の流れ

## 3. BiFPN を用いた特徴融合器

従来の畳み込みネットワークは、ボトムアップの構造で、効率的に下層の特徴を抽出できるが、上の層に至るまほど、位置情報が徐々に失われていく。FPN (Feature Pyramid Netowrk) 検出ヘッドは、下層の特徴マップに上層の特徴情報を付加し、特徴を融合することができる。BiFPN (Bidirectional Feature Pyramid Netowrk)<sup>4)</sup> は、更に上層の特徴マップの画素を下層に追跡可能な検出ヘッドである。BiFPN にオリジナルの検出ヘッドを交換し、上層の微小ひび割れの位置情報を下層に追跡することを図る。BiFPN を使用したネットワーク構造は、図-2 に示す。




図-2 BiFPN を使ったネットワーク構造

## 2. 研究方法

本研究では、BiFPN (Bidirectional Feature Pyramid Netowrk) 検出ヘッドを使用した YOLOv5s ネットワークを用い、マルチスケール教師データを用いてモデルに学習させて検出モデルの訓練を行った。モデルの性能を検証するため、同じ方法で Faster-R CNN とオリジナル YOLOv5s 二つのネットワーク構造のモデルを訓練して比較検証を行った。

## 4. 教師データの作成

本研究に使用した元画像は、コンクリート梁曲げ実験の側面写真 87 枚(6000px\*4000px)、コンクリート構造物の表面ひび割れ写真 30 枚(4032px\*3024px)である。マルチスケールな教師データを作るため、原画像をそれぞれ 1280px\*1280px と 640px\*640px サイズの画像に切り出した。切り出した画像の中に、ひび割れない画像

キーワード 物体検出, マルチスケール, ひび割れ, コンクリート, YOLOv5s

連絡先 〒316-8511 茨城県日立市中成沢町 4-12-1 TEL : 0294-38-5162

を抜き、1280px\*1280px 画像 532 枚、640px\*640px 画像 1077 枚のデータセットを作成した。

正解データは、labelimg を使用して切り出し画像をラベリングした。抽出したひび割れも連続的に検出できるように、隣接するアンカーフレームをある程度で重ねた。アンカーフレームのサイズは、セマンティックセグメンテーションを行いやすいため、正方形に設定した。

## 5. モデルトレーニング

作成された教師データを、Faster R-CNN、オリジナル YOLOv5s、BiFPN YOLOv5s の 3 つのネットワークに導入して学習させた。学習用と検証用データを 7:3 で分けた。batch size を 6 で、epoch 数は 100 とした。転移学習を用い、学習前に COCO 重みを導入した。最初の 30 epoch は backbone をフリーズして、初期の学習で重みが増えすぎないようにした。30 epoch 後に cos-lr 学習率変化関数を使用し、データのばらつき防止を行った。

バウンディングボックスは、ひび割れの線形形状の原因で、一般的なバウンディングボックスは、うまくひび割れを囲むのが困難なので、自適応計算の代わりに、0.05\*0.05, 0.1\*0.1, 0.2\*0.2(1\*1 は画像のフルサイズ) 三つのサイズに設定し、バウンディングボックスの中心点座標は、 $(X_{min}, Y_{min})$ を(0,0),  $(X_{max}, Y_{max})$ を(1,1)で、X と Y の数値は、0.025 の倍数のみに設定した。

## 6. 有用性評価

モデルの適性評価方法は、適合率・再現率・F 値及び mAP を用いて評価した。その結果を表-1 に示す。

図-3 に示すように、1280px\*1280px の画像を 2 枚を例にとし、従来方法と提案方法でセマンティックセグメンテーションまで行い、検証を行った。セマンティックセグメンテーションは、沈ら<sup>1)</sup>が提案した U-Net に基づくモデルを使用した。バウンディングボックスのつながりにあるひび割れの検出漏れを避けるため、バウンディングボックスのサイズを 0.06\*0.06, 0.12\*0.12, 0.24\*0.24 にさ検出したひび割れ画像を切り出した。評価は、IoU という予測画像と正解画像との重複率や、二つ方法の検出時間コストで行った。従来方法での IoU は、それぞれ 95.17, 65.98, 検出時間コストは、それぞれ 1425ms, 8938ms であった。提案方法での IoU は、それぞれ 95.46, 80.29, 検出時間コストは、それぞれ 325ms, 389ms となった。

検出時間コストは、表-2 に示す。

## おわりに

本研究は、物体検出モデルを用い、セマンティックセグメンテーションにおける誤検出や検出漏れを減らし、計算量を削減する方法を提案した。スライドウィンドウ法を用いたセマンティックセグメンテーションと比較して、同じ画像からのひび割れ検出は、IoU が平均 8% を上昇し、1280px\*1280px の画像からの検出時間は、75%以上削減することができた。しかし、本手法は物体検出モデルの正解率に大きく依存するため、今後は、物体検出モデルの精度を更に向上させる必要がある。

表-1 モデルの評価結果

	Precision	Recall	F1score	mAP
Faster R-CNN	0.71	0.82	0.76	0.71
オリジナルYOLOv5	0.76	0.62	0.68	0.70
BiFPN YOLOv5	0.79	0.81	0.80	0.78

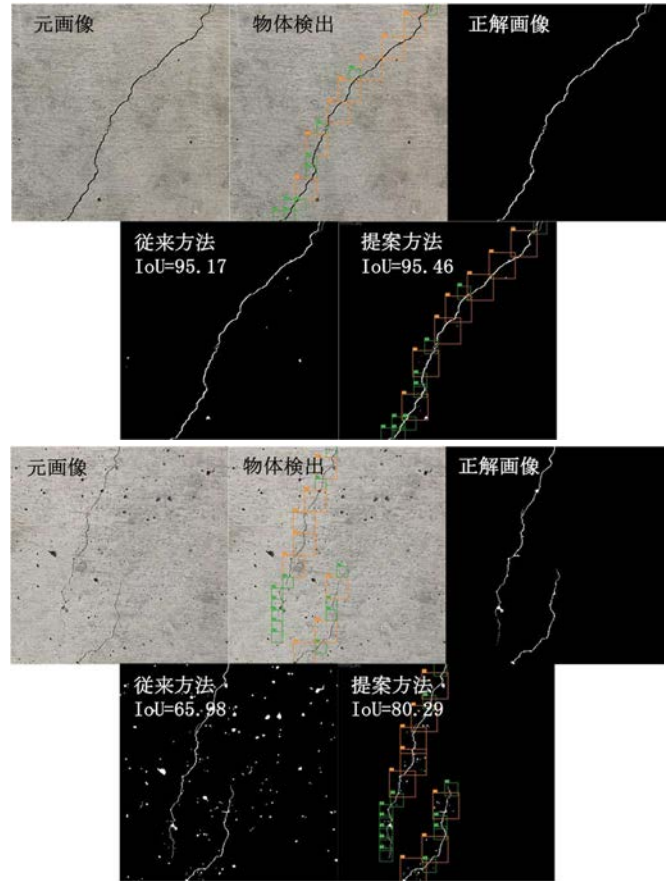


図-3 従来方法と提案方法のひび割れ抽出結果

表-2 検出時間コスト

	スライドウィンドウ法	物体検出モデルを用いた方法	
		物体検出	セマンティック
1	1425ms	12ms	313ms
2	8938ms	8ms	381ms

## 参考文献

- 1) 沈海峰, 吳智深, (2021). 深層学習を用いたコンクリート表面におけるひび割れ検知手法に関する研究. 第 48 回土木学会関東支部技術研究発表会, VI-26.
- 2) Cha, Y. J., Choi, W., & Büyüköztürk, O. (2017). Deep learning - based crack damage detection using convolutional neural networks. Computer - Aided Civil and Infrastructure Engineering, 32(5), 361-378.
- 3) 寺野聡恭, 出水享, 古賀掲維, 中島賢哉, & 松田浩. (2020). 深層学習を用いたコンクリート構造物のひび割れ抽出・判別方法に関する研究. 長崎大学大学院工学研究科研究報告, 50(95), 71-76.
- 4) Tan, M., Pang, R., & Le, Q. V. (2020). Efficientdet: Scalable and efficient object detection. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 10781-10790).