

ディープラーニングおよび Random Forest によるコンクリートのひび割れ自動検出手法

愛媛大学 学生会員 ○瀬々大樹 正会員 全邦釘
学生会員 嶋本ゆり 正会員 大窪和明

1. 序論

近年コンクリート構造物の劣化・損傷が顕在化しており、適切な点検・評価・記録が必要不可欠である。点検項目の中でも、ひび割れは重要な指標のひとつであるが、現在ひび割れ点検は、目視や打音により行われており、人為的なミスが発生および手間や費用が掛かりすぎるといった問題がある。そのため近年、コンクリート表面を撮影した画像に画像処理を施し、自動的にひび割れの検出を行うことで、効率化・省力化しようとする試みが多くなされている。しかしこれらの多くは、ひび割れとひび割れでない箇所の画素値の差を利用し検出を行っているため、ひび割れと画素値が酷似している汚れや、撮影時に発生した影の部分で、誤検出が多く発生するという課題を抱えている。そこで画像処理に加え、機械学習を用いることで、誤検出を減らし定量的な検出を可能にする研究が行われてきた。機械学習を用いた手法では、画素値だけでなくひび割れの形状的な特徴にも着目し検出を行うため、誤検出が減少し、精度が大幅に向上することが報告されている。しかし、従来の機械学習を用いたひび割れ検出では、画像特徴量を人為的に決定していることから、量的にも質的にも限界があるため、ひび割れと形状および画素値が似ている型枠跡などに対応できず、誤検出が発生してしまうという問題があった。そこで本研究では、ディープラーニングおよび Random Forest を用いたひび割れ検出手法の開発を行うことで、より高精度かつ効率的な手法の確立を目指す。本手法ではディープラーニングの中でも画像認識で高い精度を誇る Convolutional Neural Network¹⁾ (CNN) を用いた。これによって、これまでひび割れとの明確な特徴量の差を定義することが困難であるため、ひび割れと誤認識していた型枠跡などの正しい検出が期待できる。これらの検出結果を細線化およびベクトル化し、CAD データとして活用できる形式に変換することで、より実用的な手法の提案を目指す。

2. ひび割れ検出手法

図-2 のようなコンクリート表面を撮影した画像（サイズ：3456×5184px）は、天候やフラッシュの有無および表面の汚れなど、撮影時の状況それぞれ異なるため、median フィルタを用いた濃淡の補正および正規化を行うことで画像ごとの偏りを無くす。そして、前処理後の画像を用いてディープラーニングモデルを作成する。本研究ではディープラーニングの中でも画像認識で高い精度を誇る CNN を用いた。図-1 に CNN モデルの例を示す。CNN は畳み込み層とプーリング層という特別な層を持つものを指し、これらが人間の脳が物を認識するときの働きに近いことを、画像認識において高い精度を誇ると言われている。

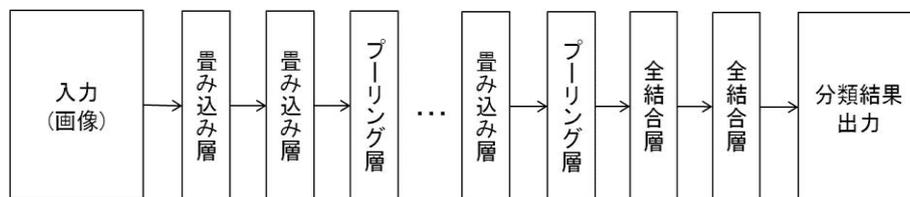


図-1 CNN モデルの例

前処理後の画像を 256×256px の小領域に分割したものを学習データとして用いる。その際、分割したものだけでは学習データ枚数が不十分であるため、回転・ノイズの付加・合成を行った。本研究では、モデルを 2 種類作成した。1 つ目のモデルは各小領域がひび割れを含むか含まないかを判定するためのものである（以下モデル 1 とする）。2 つ目のモデルは各小領域が、型枠跡を含むか含まないかを判定するためのものである（以下モデル 2 とする）。学習データ枚数はモデル 1 で各クラス約 100 万枚、モデル 2 で各クラス約 1 万枚用意した。そして学習済みのモデルに、未知の画像を投入することで図-3~4 のような結果が得られる。図-3 は、モデル 1 の結果で、画素値が高いほどひび割れの確率が高いことを示している。図-4 はモデル 2 の結果で、画素値が高

いほど、型枠跡の確率が高いことを示している。ここで、ひび割れの確率が0と判定された領域は、次以降のRandom Forestの解析では省略することで、解析の効率化を図る。Random Forestとは、機械学習手法の1つで、多数の決定木の集合によって構成され、過学習に強いことで知られている。今回はRandom Forestを2段階にわたって用いており、1段階目では数種類のフィルタ処理後の画素値を特徴量として用い、画素単位で判定を行った。2段階目では、1段階目で得た検出結果を二値化後、連結領域の面積や周辺長を算出し、学習のパラメータに用いることで、連結領域ごとに判定を行った。1段階目と2段階目はそれぞれ学習データの特徴量が異なる全く別のモデルである。また学習の際は、これらの特徴量と共に正解のクラスラベルを与える。ここでのクラスラベルは、‘ひび割れである’、‘ひび割れでない’の2クラスである。Random Forestでの検出結果を図-5~6に示す。型枠跡などで誤検出は発生しておらず、正しくひび割れのみを検出できていることが分かる。次に、検出画像に対して、ひび割れ幅の可視化を行う。最後に、CADデータとして活用することを想定し、検出結果に対して細線化を行う。

3. 検出結果

本研究では、構築したRandom Forestモデルを交差検証および、表-1に示す指標を用いることで評価を行う。また、比較対象として既往の研究でも用いられている大津の二値化手法²⁾による結果を用いた。表-1を見ると、感度が大津の方法よりも低い値であることが分かる。大津の方法では、画像の広範囲を、ひび割れと検出しており、結果として、大半のひび割れ部を網羅することが出来ているため感度が高くなったと考えられる。また、F値・特異度、正解率に関しては、大津の二値化手法と比較して、非常に高い結果が得られた。以上より、本研究で提案する手法は、精度の高い判別ができていると言える。

表-1 本手法と大津の方法の比較

評価尺度	本手法	大津の方法
感度	0.871	0.976
適合率	0.518	0.013
特異度	0.996	0.633
F値	0.650	0.025
正解率	0.995	0.609



図-2 撮影画像

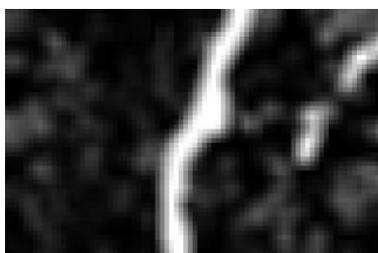


図-3 確率画像 (ひび割れ)

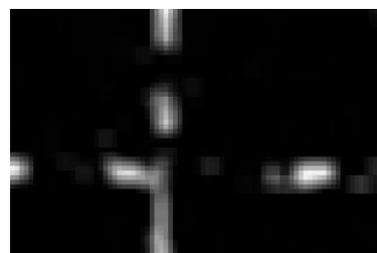


図-4 確率画像 (型枠跡)



図-5 Random Forest
検出結果 (1段階目)



図-6 Random Forest
検出結果 (2段階目)



図-7 細線化結果

4. 結論

- 1) コンクリート表面を撮影した画像から、ディープラーニングとRandom Forestを用いることで高精度にひび割れを検出することができ、F値は0.65という結果が得られた。
- 2) 従来の検出手法では誤検出されていた型枠跡を正しく検出することが出来た。
- 3) CNNによるスクリーニングによって解析時間を短縮することが出来た。
- 4) ひび割れ幅の可視化システムの構築および細線化を行った。