

Deep Learning を用いたコンクリート表面のひび割れ検出に関する基礎的研究

愛媛大学大学院 ○学生会員 井後 敦史 愛媛大学大学院 学生会員 三輪 知寛

愛媛大学大学院 正会員 大賀水田生 愛媛大学大学院 正会員 全 邦釘

1. 序論

コンクリート構造物において、ひび割れは構造物内部の鉄筋の腐食を促進し、剥離・剥落・落下など重大な事故に繋がる危険性がある維持管理の上で欠かせない重要な指標である。そのため、ひび割れの損傷を正確に把握することが重要となり、近年、コンクリート構造物のひび割れを撮影したデジタル画像から画像処理を用いてひび割れを検出するという試みが行われている。しかし、これらの試みの多くはコンクリート表面の汚れや、影などといった光の影響を誤検出してしまい、実用化には至っていない。ひび割れの正確な検出が困難である理由として、ひび割れの色や形状は多種多様であり、これを正確に指定することは非常に困難であることが挙げられる。しかし、既往の研究ではひび割れの画素値や形状を何らかの手法で人為的に決定し、その値を基にひび割れを検出していた。一方で人の目は撮影画像を見た際に瞬時にひび割れの有無を確認することができる。これは、脳の中にひび割れに対する何らかの判断基準を持っているためである。つまり、この判断基準を獲得することができればひび割れの正確な特徴を捉えた検出を行うことが可能となる。そこで本研究では、画像認識の分野で高い性能を発揮している Deep Learning を用いる。Deep Learning とは多層ニューラルネットワークを用いた機械学習の総称である。従来の手法では、学習の段階で事前にその対象物がどのような特徴をもつか抽出する必要があった。しかし、Deep Learning はこれを必要とせず、画像からその対象物がどのような特徴をもつかという概念を学習することで、ひび割れ検出を行うことが可能である。これにより、ひび割れ検出において Deep Learning の有効性を示すことを目的とする。

2. 画像解析手法

本研究では、撮影画像に対し、Median フィルタを用いて影などの影響を補正した後にその画像を正規化する。そして、その画像を小領域 $100 \times 100 \times 3$ に分割しその領域を 3 クラス(ひび割れ、ノイズ(光の影




図-1 CNNの層間結合の様子

響や汚れ)、背景)に分類し、そのデータを訓練データとして畳み込みニューラルネットワーク(以下 CNN と記述)を用いて学習を行う。CNN とは Deep Learning の一種であり、画像認識の分野で特に高い性能を発揮している。その理由として、CNN は生物の脳の視覚野における知見に基づく構造を持つところにある。生物の視覚系では外界から取りこんだ光は網膜で電気的な信号に変換され、その後、脳の視覚野に伝達されている。そこにある無数の神経細胞の中には、網膜の特定の場所に特定のパターンが入力されると反応し、それ以外では反応しないというものがある。それらは、網膜の特定の位置に、特定の方向・太さの線分が入力されたときのみ反応する。CNN はこの反応を、図-1 に示すように、ユニットごとの結合を局所に限定し層間の結合を疎にすることによって表現している。具体的には、画像の局所的な特徴抽出を担う畳み込み層と、局所ごとに特徴をまとめ上げるプーリング層を繰り返した構造となっている。図-2 に本研究で構築した Deep Learning モデルの簡略図を示す。次に、撮影画像から本研究で構築した Deep Learning モデルを用いてひび割れの発生範囲を特定する。ひび割れの発生範囲の特定は、学習時と同様に撮影画像に Median フィルタによる補正、正規化を行った後に $100 \times 100 \times 3$ の小領域を切り出し、本研究で作成したニューラルネットワークモデルを用いて、該当範囲のそれぞれクラスに属する確率を算出する。これによって得られた各クラスに属する確率をそれぞれ画像の RGB 成分 (R: ひび割れの確率, G: ノイズの確率, B: その他の確率) に当てはめたものを図-3 中央に示す。そ




図-2 本研究で用いた Deep Learning
モデルの簡略図




図-3 左：撮影画像，中央：各クラスに属する確率
を示した図，右：検出結果

の後、正確なひび割れ位置の特定を行う。正規化後の画像から図-3 中央の画像においてひび割れの確率が高い部分のみ抽出する。これにより得られた画像をグレースケール変換し、二値化を行う。このとき、検出された各領域はひび割れであるか、もしくはひび割れ周囲のノイズである可能性が高い。また、ひび割れ部分の未検出を防ぐため、正規化後の画像に対してもグレースケール変換し、二値化を行う。このとき、Deep Learning から得られた二値画像の各領域と照らし合わせ、これらが隣接する領域はひび割れ等の未検出部分の可能性が高い。よって、その領域を Deep Learning 後の二値画像に加える。これによって得られた二値画像は、コンクリート表面の空隙など、ひび割れ以外の領域も多く含んでいるため、各領域の面積や偏心率等の特徴量を算出し、決定木を用いて学習することによりこれを除去する。それによって得られた画像が図-3 右である。

3. 検出結果

構築した Deep Learning モデルを leave-one-out 交差検証を用いて検証する。定量的指標として本研究では感度・適合率・特異度・ F 値を用いた。その結果を表-1 にまとめる。本研究の比較対象としては既往の研究に倣い大津の方法による結果と比較した。表-1 より、感度で比較すると大津の方法の方が提案手法より高い。これは、大津の方法による二値化で

は曖昧なものは全てひび割れと判定しているためであり、そのために逆に適合率、特異度は大幅に低くなっている。特に適合率に着目すると、大津の方法により検出された結果がわずか 1.3%のみが正解画像においてもひび割れということを意味しており、まともな検出ができていないことがわかる。感度と適合率を同時に評価する指標である F 値を見ても、本研究で提案する手法は感度では大津の方法にやや劣っているが適合率で大きく優るため大きな差がついている。このことから本研究で提案する手法は精度よくひび割れを検出できていると言える。しかし、コンクリート表面の P コン跡や線上の汚れ等は未だに誤検出の多い結果となった。しかし、これら誤検出となった小領域を見るとその多くは、ひび割れのある小領域と比較して人の目においても判断が難しい画像が多く存在した。このことから本研究で構築した Deep Learning モデルは人の判断基準に近い判断基準を獲得したと言える。また、今回 $100 \times 100 \times 3$ の小領域で学習を行ったが、人の目でひび割れとノイズ、その他の部分の判断がつく程度の大きな領域で学習を行うことにより更なる精度の改善を行なえると考ええる。

4. 結論

第3章より本研究で構築した Deep Learning モデルはひび割れ検出において高い精度を誇ることがわかった。また、誤検出部分においてもその判断基準は人のそれに近く、適切な学習がなされていたことがわかる。このことから Deep Learning はひび割れ検出において有効であることを示すことができた。

5. 参考文献

- 1) 中山英樹：深層畳み込みニューラルネットワークによる画像特徴抽出と転移学習，2015。
- 2) 浅川伸一：ディープラーニング，ビッグデータ，機械学習 あるいはその心理学，新曜社，2015。

表-1 本研究の手法と大津の方法の定量的な比較

	本研究の提案する手法	大津の方法
感度	0.7476	0.9764
適合率	0.8358	0.0129
F 値	0.7619	0.0252
特異度	0.9995	0.6334