

深層学習を用いたコンクリートの ひび割れ検出プログラムに関する研究

寺野聡恭*・古賀掲維**・松田浩***

A Study on Concrete Crack Detection Program using Deep Learning

by

Sosuke TERANO*, Aoi KOGA** and Hiroshi MATSUDA***

In a local government, proper maintenance and management of social infrastructure such as roads and bridges is a very important activity to live a life. However, in recent years, the aging of concrete structures constructed during the period of high economic growth has become a problem. Under such circumstances, the demand for maintenance of social infrastructure is expected to increase in the future, and it is necessary to develop more efficient methods. In the inspection of concrete structures, it is fundamental to observe the occurrence of cracks. In this study, we aimed to develop a diagnostic method for cracks and confirmed that it is effective for remarkable cracks in concrete structures by transfer learning, which is one method of deep learning from digital photographs.

Key words : concrete structure, cracks, deep learning, transfer leaning

1. はじめに

地方自治体において、道路や橋梁などの社会インフラを適切に維持管理していくことは住民生活の利便性確保だけでなく、防災・減災の面から住民が安心・安全な生活を送るためにも非常に重要な公共事業である。国土交通省の調査によると 2033 年頃には、橋梁はその約 6 割が、トンネルはその約 4 割が、建設後 50 年を超えると報告されている。一方、公共事業にかけられるコストは限られており、効率良く適切に社会インフラを維持管理していく維持管理手法の確立が急務となっている。

コンクリート構造物の点検では、近接目視点検において、例えば、PC 橋であれば、0.2mm 以上の、RC 橋であれば 0.3mm 以上のひび割れの発生状況をスケッチすることが基本とされている。これは、コンクリート構造物において、ひび割れは耐久性の低下や耐荷力の低下、水密性や防水性の低下など、コンクリート構造物の安全性や機能性に悪影響を及ぼす可能性が高く、また、構造物の美観を損なう原因となるためである。

一方、コンクリート構造物の点検で用いられている

近接目視点検は、定性的で点検結果が他者に伝わりやすいという長所もあるが、以下のような多くの欠点も抱えている。

- ① 膨大な作業時間・作業量を要する
- ② 検査者の知識及び経験に依存する
- ③ 地方自治体の技術者不足
- ④ 検査者の個人差によるばらつきがある¹⁾
- ⑤ 高精度かつ客観的な評価が難しい

これらの問題を解決するためには、近接目視点検を効率化するとともに、その情報に定量的な情報を持たせる必要がある。

本研究は、デジタルカメラによる写真画像から画像解析によりコンクリート表面のひび割れをひび割れ幅も含めて自動検出することを目的としたものである。ひび割れを正確に自動検出することにより、近接目視点検の欠点を補いつつ、迅速性・客観性を兼ね合わせたコンクリート構造物のひび割れ評価手法を構築し、将来的には、ひび割れの発生原因、補修方法、対象のコンクリート構造物の耐荷力等を自動的に診断できるようなシステムの構築を目指す。

平成**年**月**日受理

* 長崎大学大学院博士前期課程総合工学専攻 (Department of Advanced Engineering)

** 長崎大学 ICT 基盤センター (Center for Information and Communication Technology)

*** 長崎大学大学院工学研究科 (Division of System Science)

2. 深層学習

2.1 深層学習による画像認識

近年、深層学習を用いた画像認識が注目を集めている。深層学習の導入により、ILSVRC(ImageNet Large Scale Visual Recognition Challenge)という画像認識の大会では、2015年2月には、精度において人間による認識を超えたことが報告されたことにより注目が高まった²⁾。(Fig.1)

本研究では、コンクリートのひび割れ検出に深層学習を用いたアプローチの導入を検討する。深層学習の導入により、これまで自動化が難しかったひび割れ部位の特定の自動化を実現する。ひび割れ部位が特定できればひびわれ検出のための画像処理が容易になり、ひび割れ検出の精度及び効率を大幅に向上させることができる。さらに、画像認識を行うことによって、コンクリート構造物以外が写り込んだ画像についても適用範囲を広げることができると考えられる。(Photo.1)



Photo.1 コンクリート構造物以外が写りこんだ画像

2.2 転移学習

通常、深層学習を行うためには、膨大な画像データを収集し、学習を行うための時間・労力を要する。それを解決する手法の一つとして、転移学習がある。この手法は学習済みのモデルを利用し、その一部を再学習させることによって、画像認識等を行うものである。転移学習を用いることで比較的少ないサンプル数でも認識精度の向上が期待できる³⁾。

本研究では、ImageNet というデータセットを用いて学習を行った VGG16 という学習済みモデルを利用して転移学習を行った。VGG16 は先に述べた 2014 年の ILSVRC において優秀な成績を収めたモデルであり、隠れ層が 16 層のシンプルな構成をしているので転移学習の事前学習済みモデルとしてよく用いられる。

(Fig.2)



Fig.1 ILSVRC における精度推移




Fig.2 ネットワーク層の例

3. 試験概要

本研究で用いた転移学習を行う上での動作環境を Table. 1 に示す。

本研究では、コンクリートのひび割れ部位の検出問題を、入力された画像の中にひび割れが有るか無いかを判断する二値分類の問題として設定した。なお、撮影データに特別な条件は設けていない。その理由としては、撮影データの条件の大部分は、使用機材の性能に依存するためである。また、将来使用する際の汎用性も鑑み、あえて特別な条件は設定していない。

また、画像サイズについては、原画像を 224×224 ピクセルとして分割するため画像サイズに対する制約もない。

3.1 教師画像について

教師画像として用いる画像は1枚の画像を分割して作成し、画像数を増やしている (Fig. 3)。分類のクラスは前章で述べた通り、Fig. 4 のようにひび割れが有るもの (Fig. 4 上部)、ひび割れが無いもの (Fig. 4 下部) の2種類で作成し、様々な種類のコンクリートのひび割れを判別できるようにコンクリートの色、画像の明るさやひび割れ幅が様々な種類の画像を用意した。また、今回の画像のクラスはひび割れの有無のみをクラスとしている。そうすることで、コンクリート構造物とひび割れ以外に写りこんだ画像をどう判断するかを試す。

本研究での教師画像の総数は、訓練用に計 1600 枚、テスト用に 800 枚使用している。




Fig. 3 教師データの作成手順




Fig. 4 教師データ

Table. 1 動作環境

Python	3.6.8
Tensorflow	1.5.0
keras	2.1.6
CUDA	9.0
CuDNN	7.0.5(for CUDA 9.0)
GPU	GEFORCE GTX 1080Ti

3.2 学習について

転移学習を行う上でどの程度の深さまでネットワーク層を再学習させるかを定めることができる。本研究では、特徴抽出層の最終層と分類層に関して再学習を行った。

また、エポック数(学習回数)は100回とし、バッチサイズは2の乗数である64, 128, 256に設定し試行を行った。教師データの数が1600であるため、1600をバッチサイズで除した数が1エポックごとの学習の反復回数となる。深層学習の学習は、一回の学習の中には訓練とテストを行っており、訓練して出来上がったネットワークをテストし、精度と損失値が不十分であれば、重みバイアスを変更する。この繰り返しを行うことで、より良いネットワーク層を構成する。

Fig. 5, Fig. 6, Fig. 7 に示す図は、学習の様子を示したものである。それぞれバッチサイズは64, 128, 256であり、それぞれの図の上段のグラフは縦軸が精度、下段のグラフは損失率を表し、横軸はエポック数を表している。上段のグラフから学習が進むにつれて精度が高くなっていることが確認できる。一方、下段のグラフは、エポック数が増えても損失率の値が低くならず、十分に学習効果があがっていないことがわかる。

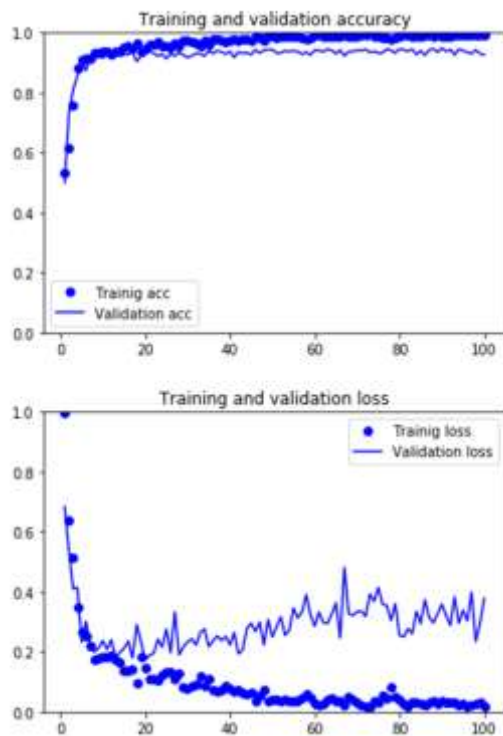


Fig. 5 学習過程 1 (Batch_Size64)

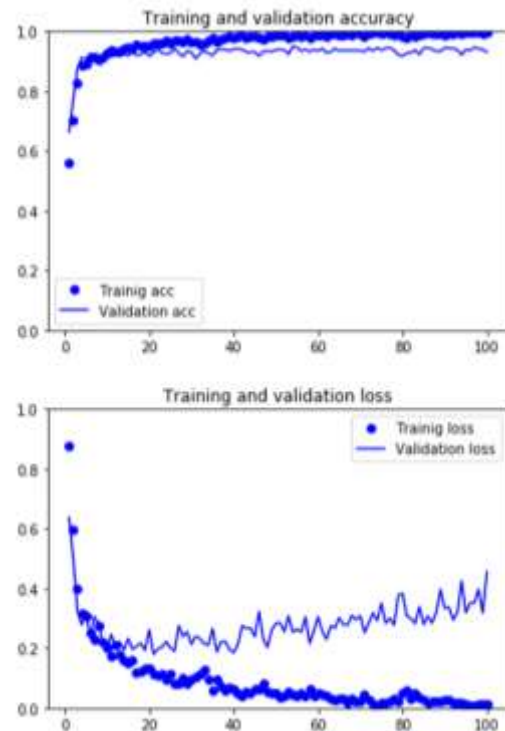


Fig. 6 学習過程 1 (Batch_Size128)

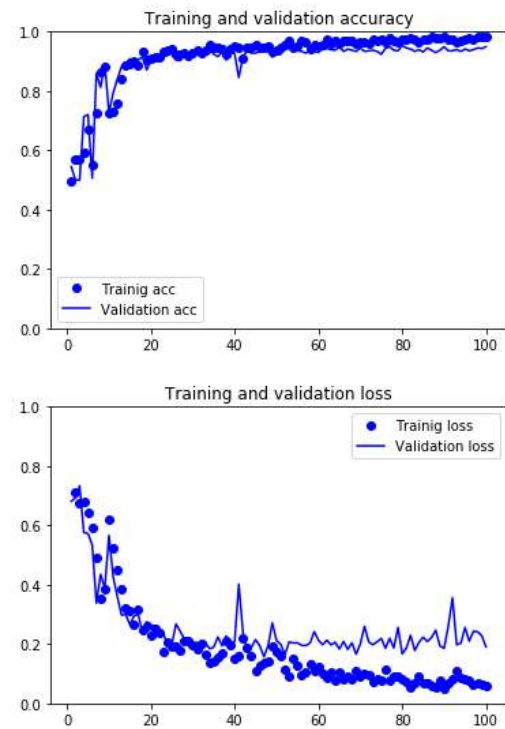


Fig. 7 学習過程 1 (Batch_Size256)






出力値	画像
1.0-0.75	
0.75-0.6	
0.6-0.5	
0.5-0.4	
0.4-0.25	
0.25-0	

Fig.10 出力結果 3

5. まとめ

深層学習を用いた画像認識によるコンクリートのひび割れ検出を行ってみた結果、ひび割れが顕著である画像に対してはその有効性を確認することができた。しかし、型枠跡、植物や表面の汚れに対しては、誤判別が多く見受けられた。また、類似した状況の画像に対して違う判別を行った例も多くあり、判別の安定性が課題となった。

今後、教師データの選定・事前処理の試行、エポック数やバッチサイズを調整することによる学習方法の最適化、事前学習済みネットワークの違いによる精度への影響の観察、転移学習を行う層の再検討等を行い判別の精度向上を図っていきたいと考えている。

参考文献

- 1) 鵜飼正人：画像処理によるトンネル構造物ひび割れ検査精度の向上，信号通信技術，Vol.24，No.3，pp53.
- 2) 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，電子情報通信学会技術研究報告，vol. 115，no. 146，SP2015-45，pp. 55-59，2015年7月
- 3) 神畷敏弘：(解説)転移学習Transfer Learning，産業技術総合研究所，人工知能学会誌，25巻4号，pp.1，2010年7月