

DCGANにより生成された教師画像によるコンクリート表面変状の 自動検出モデルの精度検討

Study on the accuracy of automatic detection model of concrete surface deteriorations with training images generated by DCGAN

北海道大学工学部環境社会工学科 ○ 学生員 町 優貴(Yuki Machi)
北海道大学大学院工学研究院 正会員 鄧 朋儒 (Pengru Deng)
北海道大学大学院工学研究院 正会員 松本 高志(Takashi MATSUMOTO)

1. はじめに

現在日本の社会インフラは経年劣化による老朽化が大きな懸念材料となっている。さらには構造物の点検が定期的に行われる一方で、点検の専門的技術を持つ人材の不足やコストの問題も表面化してきている。こうした状況において効率的な維持管理が求められている。効率的な維持管理のためにはコンクリート構造物の画像からひび割れなどの表面変状を自動検出する技術が考えられる。前もって判別したい特徴パターンをコンピュータに学習させ、その特徴を含んだ画像が入力されたとき、画像の特徴データと学習データを比較して判別を行う。

本研究では、学習に Deep Learning を用いる。Deep Learning は人間の脳の神経回路と似たようなシステムを持ち、膨大なデータの蓄積から特徴パターンを自動検出する学習方法である。本研究では画像認識の分野でよく用いられる畳み込みニューラルネットワーク、通称 CNN (Convolutional Neural Network) ¹⁾に DCGAN(Deep Convolutional Generative Adversarial Network)によって生成された画像を教師データとして用いた時に、実際の画像を教師データとして用いたときと同程度の精度が得られるかを検討することが目的である。

2. 実験概要

GAN は生成ネットワークと呼ばれ、実際にある画像データと似た特徴を持つ画像を新たに生成するネットワークである。本研究では GAN の一種である DCGAN を使ってコンクリートのひび割れ画像をコンクリートの表面画像データセットから生成する。

CNN は識別ネットワークと呼ばれ、画像の持つ特徴を抽出することで、その画像が何を表しているか確率的に出力するネットワークである。CNN は識別の基準として教師データと呼ばれるデータセットを必要とする。通常は実際のコンクリート画像をデータセットとして使用するのが本来の CNN による画像認識であるが、本研究では GAN によって生成した画像を教師データとして利用した時の精度を調べるために、教師データの一部として DCGAN によって新たに”生成した”ひび割れ画像を使用する。

3. DCGAN

3.1 DCGAN の手法

DCGAN は仕組みとして Generator と Discriminator と呼ばれる二つの機能を持つ。Generator は画像を生成す

る役割を持ち、Discriminator は Generator が生成した画像が”実際(本物)の画像”か、それとも”偽物(生成した)の画像”か判断する。Generator は Discriminator の判断を参考にして自身を訓練する。同時に Discriminator は用意された実際の画像と Generator によって生成された偽物の画像を参考に自身を訓練する。この二つの機能の競争によって Generator が生成する画像の精度が向上する。

3.2 DCGAN の画像生成と結果

はじめに Discriminator に参照させる実際の画像のデータセットとして 100 枚のひび割れ画像を用意した。Generator と Discriminator の競争による GAN のパラメータの更新を 50000 回行った後、Generator によってひび割れクラスの生成画像が 2500 枚得られた。

本研究における DCGAN の条件では生成画像は図 1(A)のように粗いものが多く見られた。これらは教師データとして十分な効果を持たない。しかし図 1(B)のようにひび割れの特徴を捉えたひび割れ画像も同数程度生成された。

4. CNN

4.1 CNN の手法

CNN はあらかじめ膨大な枚数の画像を Deep Learning を使って学習させ、新たに入力された画像がそのデータセットの画像クラスの中でどのクラスのデータセットと似た特徴を持つかを確率的に出力する。本研究で準備したコンクリート表面画像のデータセットは図 2 のようにひび割れ、エフロレッセンス、打ち継ぎ目、チョーク文字、通常表面の 5 つのクラスに分けられている。画像データはそれぞれ 5892 枚、2821 枚、4509 枚、2996 枚、5014 枚集めた。これらを 64*64pixel にリサイズする。リサイズ後の画像を上下/左右反転、90 度回転させることでデータ数を 4 倍に拡張している。その後前処理として画像の各画素から、画素の平均値を引きすべての画素の平均値を 0 にしている。DCGAN によって得られた 2500 枚のひび割れ画像に関しても同様の処理を施した。

なお、本実験で使用する分類器のパラメータを表 1 に示した。

4.2 CNN の実験条件

4.2.1 実験 1

4.1 で集めたコンクリート表面の画像を教師データとして CNN に学習させた後、学習させた教師データとは別の異なるコンクリート画像を集めたテストデータ 200 枚を使って各画像がどのクラスに属するかという確率の

出力を行った。

4.2.2 実験 2

実験 1 で教師データとして用いたひび割れ画像 5892 枚のうち 2500 枚を DCGAN で生成したひび割れ画像 2500 枚と差し替えて CNN に学習させた。実験 1 と同じテストデータ 200 枚を使って各画像がどのクラスに属するかという確率の出力を行った。

5. 結果と考察

実験 1、2 におけるテストデータのひび割れクラスの画像の分類精度の結果をまとめたグラフが図 3 である。実験 1 では安定して高い精度を示しているが、実験 2 においては精度が低い上に安定性の低下も見られた。

また、他クラスとの関係をまとめるため実験 1、2 の各クラスの分類精度を表 2、3 にまとめた。

表 2、3 より、DCGAN で生成された画像を教師データとして使用した実験 2 では他クラスの分類に影響を与えて精度が低下してしまっていることがわかる。特に通常表面の分類精度はひび割れを除く他のクラスよりも精度が下がり、実験 2 は実験 1 に比べて 5.5% 精度が落ち込んでいる。これは DCGAN において用意する本物画像 100 枚、パラメータの更新回数 50000 回という条件ではひび割れの特徴を完全に捉えきれず、通常表面のような画像がいくつか生成されてしまったからであると考えられる。ひび割れクラスについては、教師データとして使用した GAN による生成画像にひび割れクラスの特徴を捉えている画像が 2500 枚中、半数以上あったため 50% 以上の精度は常に維持することができたと考えられる。

6. まとめ

本実験では全く同じ分類器を用いて実験 1 では本物の教師データを、実験 2 では実験 1 の本物の教師データのうちひび割れクラスの画像 2500 枚を DCGAN によって生成したものと差し替えて学習をさせて、分類精度を比較した。

実験 1 と同程度の分類精度を実験 2 においても得ることができれば DCGAN による生成画像は教師データとして認められるが、本実験では精度が下がった。原因としては、パラメータ更新回数の少なさと DCGAN に手本として入力する本物のひび割れ画像の少なさが挙げられる。今後の課題としては、現状のひび割れ画像の生成精度を改善し、他クラスに関しても同様の画像生成を行うことが挙げられる。そして入力画像が全て偽物になっても本物と同程度の分類精度を発揮できるような DCGAN の改善を目指す。



図 1 DCGAN による生成画像
(A)ひび割れの特徴が表れていない生成画像
(B)ひび割れの特徴がよく表れている生成画像




図 2 クラス分けされたコンクリート画像
(A)ひび割れ、(B)エフロレッセンス、(C)打ち継ぎ目、
(D)チョーク文字、(E)通常表面

表 1 本実験に使用する分類器のパラメータ²⁾

層	バッチ	出力マップサイズ	関数	dropout
data		128×128×1		
conv1	3×3	128×128×32	ReLU	
conv2	3×3	128×128×32	ReLU	0.2
pool2	2×2	64×64×32		0.25
conv3	3×3	64×64×32	ReLU	0.25
conv4	3×3	32×32×64	ReLU	
pool4	2×2	64×64×64		0.3
conv5	3×3	32×32×64	ReLU	
conv6	3×3	32×32×64	ReLU	
conv7	3×3	32×32×64	ReLU	
conv8	3×3	32×32×64	ReLU	
pool8		1×1×5440		0.4
fc9		1×1×1024	ReLU	0.5
fc10		1×1×5	softmax	

表 2 実験 1 における各クラスの分類

分類精度[%]	入力画像				
	ひび割れ	エフロレッセンス	打ち継ぎ目	チョーク	通常表面
	82.7	79.9	89.5	90.1	90.8

表 3 実験 2 における各クラスの分類

分類精度[%]	入力画像				
	ひび割れ	エフロレッセンス	打ち継ぎ目	チョーク	通常表面
	72.46	78.1	89.4	89.9	84.5




図 3 分類精度結果の比較

参考文献

- 岡谷貴之:深層学習、講談社、p79-97、2015
- 横山傑、松本高志:Deep Learning によるコンクリートの変状自動検出器の開発と Web システムの実装、土木学会第 19 回応用力学シンポジウム講演論文集、p125-126、2016