

CNN を用いた路面のひび割れ検出モデルの構築と最適化

永田 睦稀[†] 戴 瑩[†]岩手県立大学ソフトウェア情報学部[†]

1. はじめに

現在の日本は、道路の老朽化が進んでいるため、定期的な点検が必要とされている。高速道路などは、路面性状測定車で点検を行っているが、県道や市道などは十分に点検が行われていない。道路の安全を守るためには定期的な点検が必要不可欠であり、それを実現するためには効率的かつ低コストで点検を行う手法が求められる。¹⁾

CNN(Convolutional Neural Network)²⁾とは、何段もの深い層を持つニューラルネットワークのことで、特に画像認識の分野で優れた性能を発揮している。CNN を用いた路面のひび割れ検出を行っている既存研究³⁾がある。手法としては、収集した画像を、亀裂のあるピクセルとその亀裂のすぐ近くにあるピクセルを正、それ以外を負と定義し、CNN を用いて分類を行う。検出精度は 92.51% であるが、実用化のためには、さらに高い検出精度が求められる。

2. 提案手法

2.1. システム概要

本研究では、高性能かつ低コストで、効率的な路面の点検を行うことを目指し、自動的にひび割れを検出するモデルを提案する。車内に設置したカメラで撮影した写真に、路面状況の異常レベルを付け、学習データセットを作成する。そして、CNN を用いて路面の異常レベルを判定するモデルを構築し、その結果を地図上に表示する。今回は、CNN モデルの構築と最適化を行う。図 1 にシステム構成図を示す。

2.2. データセット

今回、自らデータ収集を行い、独自のひび割れ画像学習データセットを作成した。手法としては、車内にデジタルカメラを設置し、路面の写真または動画の撮影を行い、動画は画像に変換する。画




図 1 システム構成図

像のひび割れ部分をトリミングし、画像サイズを 75×150pixels にする。ひび割れの本数や大きさによって、異常度 0 から 3 までのラベル付けを行う。合計 3827 枚の画像を用いてデータセットを作成した。異常レベルごとの画像の枚数を以下の表 1 に示す。

表 1 異常レベルごとの画像枚数

異常レベル	0	1	2	3
枚数(枚)	2857	786	157	27

3. 実装環境と実現方法

CNN に基づく道路のひび割れ検出モデルの構築は、MATLAB(R2017a)を利用する。実現方法は、データセットの画像から特徴を抽出し、ひび割れ画像の分類を行うモデルを構築する。畳み込み層とプーリング層と全結合層で特徴抽出を行い、ソフトマックス層で分類を行う。モデルを構築する上で、利用する主な関数は、trainNetwork と classify である。trainNetwork は、分類問題用の学習済みネットワークを返す関数で、classify は、判別分析を行う関数である。これらを利用して路面のひび割れ検出モデルの構築を行った。

4. 評価実験

4.1. CNN layer 設計実験の内容

最適な CNN layer を設計するため、いくつかの実験を行った。1 つ目は、畳み込み層のフィルターの枚数を 2~40 枚、大きさを 1×1~15×15 と変化させ、最適なフィルターの大きさと枚数を求める実験である。2 つ目は、畳み込み層、プーリング層の数、全結合層の数を変化させ、最適な layer を求める実験である。この 2 つの実験を行うことにより、最

The model of road crack detection and its optimization based on CNN

Mutsuki Nagata[†] and Ying Dai[†]

[†]Faculty of Software and Information Science, Iwate Prefectural University

適な CNN layer を設計することができる考えた。

評価は、学習データとテストデータで同じデータを用いた場合と 5 分割交差検証で行う。

4.2. transfer learning との比較実験の内容

alexnet を利用した transfer learning の実験を行い、4.1 の実験で得られた結果との比較を行う。先程と同様、学習データとテストデータで同じデータを用いた場合と 5 分割交差検証で行う。また、データセットは、先程と同じものを用いる。

4.3. layer 設計実験の結果

まず、学習データとテストデータで同じデータを用いた場合の実験を行った。以下に利用した layer を示す。

```
layers=[...
    imageInputLayer([75 150 3])
    convolution2dLayer(m,n)
    reluLayer
    maxPooling2dLayer(2,'Stride',2)
    fullyConnectedLayer(4)
    softmaxLayer
    classificationLayer()];
```

この layer をもとに層の数を変化させ、3つのパターンの実験を行った。

- [1] 上記の relu 層を除いて利用した場合
- [2] 畳み込み層を 2 層, relu 層を 2 層, プーリング層を 2 層に増やした場合
- [3] 畳み込み層を 2 層, relu 層を 2 層, プーリング層を 2 層, 全結合層を 2 層に増やした場合

[1]の場合、フィルターの大きさが 4×4、枚数が 20 枚のとき、99.16%と高い精度になった。この結果より、[2]と[3]の畳み込み層の 1 層目のフィルターの大きさを 4×4、枚数を 20 枚に設定する。[2]の場合、2 層目のフィルターの大きさが 11×11、枚数が 38 枚のとき、96.37%と最高の精度になった。[3]の場合、2 層目のフィルターの大きさが 14×14、枚数が 34 枚のとき、93.34%と最高の精度になった。

次に、5 分割交差検証を行った。先ほどの結果で精度の高かった、[1]と[2]のパターンを実験し、評価を行う。

[1]の場合、フィルターの大きさが 4×4、枚数が 26 枚のとき、93.57%と最高の精度になったが、上記の[1]の場合の 99.16%と比べると精度がかなり落ちた。それは[1]の場合に過学習しやすいと考える。[2]の場合、1 層目のフィルターの大きさを 4×4、枚

数を 20 枚に設定し、2 層目のフィルターの大きさが 13×13、枚数が 36 枚のとき、95.06%と最高の精度になった。

5 分割交差検証を行った結果、精度が一番高くなったのは、[2]の畳み込み層を 2 層, relu 層を 2 層, プーリング層を 2 層に増やし、全結合層を 1 層にした場合であった。

4.4. transfer learning との比較実験の結果

まず、学習データとテストデータで同じデータを用いた場合の実験を行った結果、精度は 96.47%となった。次に 5 分割交差検証を行った結果、精度は 95.24%となった。

5. 考察

CNN layer の最適化実験では、畳み込み層と relu 層とプーリング層をセットで増やしたときに精度が高くなり、全結合層を増やしたら精度が低くなった。畳み込み層をもっと増やすことで精度が上がる可能性があるため、今後実験していく必要があると考えている。

CNN layer の最適化実験と transfer learning との比較実験の 5 分割交差検証の結果から、前者の精度は最大で 95.06%、後者の精度は最大で 95.24%となり、transfer learning を利用した時のほうが良い結果になった。

6. まとめ

本稿では、CNN を用いた路面のひび割れ検出モデルの構築と最適化を行った。5 分割交差検証の結果、自分で CNN layer の設計を行った場合の最大精度は 95.06%となり、transfer learning を用いた場合は、95.24%といずれも精度の高い結果を得ることができた。

参考文献

- 1) 舗装点検要領の制定について
<http://www.kkr.mlit.go.jp/osaka/kanri/maintenance/09kaigi/07.pdf>
- 2) 畳み込みニューラルネットワーク(CNN)-MATLAB
<https://jp.mathworks.com/discovery/convolutional-neural-network.html>
- 3) Lei Zhang, et al. Road crack detection using deep convolutional neural network, Proc. of IEEE ICIP 2016, DOI: 10.1109/ICIP.2016.7533052, USA, 2016