

# 道路画像の深層学習を用いた路面ひび割れ状況の把握に向けた基礎検討

15T0240A 古市 直也  
指導教員：丸山 喜久

## 1. 研究背景と目的

我が国では道路ストックの老朽化が深刻化している。現存する社会基盤施設は主に高度経済成長期に整備されており、2033年時においては建設から50年を経過した道路施設が全体の半数に達することが分かっている<sup>1)</sup>。道路ネットワークの安全性を維持するために保守作業は必要であるが、現状の路面性状測定車での測定は費用が高額であり、保守作業の質が道路管理者の予算に依存している。さらに、ひび割れ率の評価には目視による判断やスケッチ等の膨大な作業が課せられており、これらの方法は客観的な判断が困難である上に、多くの時間を費やしている。

近年、人工知能が注目されるなど、深層学習の研究が盛んである。深層学習は画像、動画認識の分野で利用されており<sup>2)</sup>、従来の機械学習を上回る精度を記録している。深層学習を用いて画像から路面状況の評価することによって、客観的な路面性状評価を実現するだけでなく、道路維持管理のコスト削減や検査員の負担を軽減することができると思われる。

そこで、本研究では車載カメラによる画像を用いて、ディープラーニングを行い、画像判別モデルを構築した。さらに、この画像判別モデルを用いて、学習に使用しなかった未知の画像を判別させて精度の検証を行った。

## 2. 対象地域と使用画像データ

本研究の対象地域は神奈川県横浜市の神奈川県道 2 号東京丸子横浜線の一部区間 (9.14km) と神奈川県道 109 号線青砥上星川線の 7.34km、調布市内の市道 6 路線(総距離 2.125km)である。鹿島道路株式会社が多機能路面測定車によって撮影された道路画像を、同社によって測定されたひび割れ率  $P(\%)$ <sup>3)</sup>に応じて画像を 3 段階にクラス分けした。

また、多機能路面測定車で撮影された画像は対向車や沿道の建物などが写り込んでいるため、1920px×1080px のうち、図-1 のように 960px×530px の範囲でトリミングを行った後に正規化を行い、訓練用画像とテスト画像を 6:4 の比率で分類した。ひび割れ率が 0%、0~7.5%以下、7.5%より大きいものの 3 クラスに画像を分類し、各クラスの画像数に大きな差が出ないように、左右の反転やコントラストの変更を行うことで画像枚数を調整し、表-1 のように合計 6573 枚用意した。

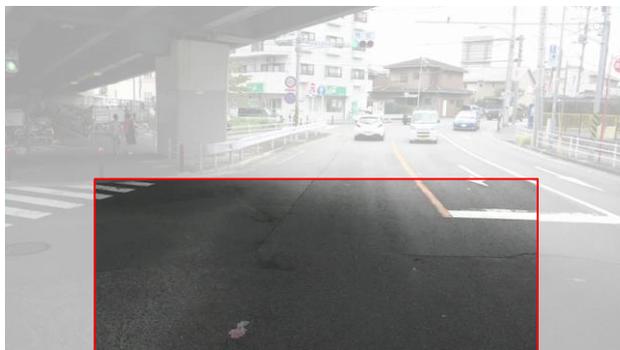


図-1 画像のトリミング範囲

表-1 使用した画像の内訳

| ひび割れ率 $P[\%]$  | $P=0$ | $0 < P \leq 7.5$ | $P > 7.5$ |
|----------------|-------|------------------|-----------|
| 訓練用画像(横浜) [枚]  | 1266  | 1205             | 1308      |
| テスト用画像(横浜) [枚] | 845   | 805              | 872       |
| テスト用画像(調布) [枚] | 85    | 98               | 89        |
| 合計 [枚]         | 2196  | 2108             | 2269      |

## 3. 深層学習のアルゴリズム

本研究では深層学習を行う際に Caffe を使用した。Caffe はオープンソースで開発されているディープラーニングフレームワークの中で画像認識の分野に向いていること、GPU を利用した計算処理速度が高速であること、コード設計が容易であることが特徴として挙げられる。Caffe を利用することによって CNN(Convolutional neural network) による画像判別器を作成した。CNN は、動物の視覚野から発想を得た、畳み込み層とプーリング層を含むディープニューラルネットワークの一種であり、画像や動画認識に広く使われているモデルである<sup>4)</sup>。この判別器を用いて入力した路面画像のひび割れの有無を評価する。

## 4. 最適化手法

ニューラルネットワークの重みの最適化には勾配法を用いた。勾配法は数値計算で関数の最小値を算出する際に利用される方法で、式(1)のように計算される<sup>2)</sup>。

$$x_{i+1} = x_i - \varepsilon \frac{\partial f}{\partial y} \quad (1)$$

$x_i$  はある時点での変数の値、 $x_{i+1}$  は次の変数の値、

$\frac{\partial f}{\partial x}$ は勾配,  $\epsilon$ は学習率である. 本研究の最適化においては, 出力層と学習データの値の差分の二乗の総和を小さくするように, この勾配法が用いられている. 学習率 $\epsilon$ の計算方法は一定(fixed)とした. 初期の学習率(based\_lr)は0.001であるため, 本研究では学習を行う際の学習率は常に0.001となる. また, 勾配法の中でも訓練用の画像から少数の画像をランダムで選んで更新処理を行うミニバッチ法を使った.

## 5. ネットワークパラメータ

ネットワークパラメータファイルはリファレンスモデルのCIFAR-10のものを参考とし, 一部変更して用いた. 入力層の後に畳み込み層とプーリング層が交互に3層ずつ並び, 全結合層, 出力層と続くネットワークである. 一部のモデルには訓練データに対する過学習を防ぐことができる仕組みであるDropout層を追加した.

また, 活性化関数はCIFAR-10と同様にReLU(Rectified Linear Unit)関数を使用した. 活性化関数とは, 前の層のノードとエッジの重みの積の和に対して施す関数のことである. ReLU関数は学習の速度が速く, 学習が止まることが少ないことが特徴である<sup>2)</sup>.

## 6. 学習結果

本研究では1000回の学習毎にテストを行い, 訓練時は100回毎に損失関数(loss)と正解率(accuracy)を, テスト時はテストを行う毎に損失関数と正解率を表示させた. 本研究では比較のために基準モデルを含め5つのモデルを作成した. 各モデルの設定と学習結果は表-2, 表-3の通りである.

表-2 各モデルの設定

|       | 分類数 | 学習回数  | Dropout | テストデータ |
|-------|-----|-------|---------|--------|
| 基準モデル | 3   | 30000 | 無       | 横浜     |
| モデル1  | 2   | 30000 | 無       | 横浜     |
| モデル2  | 3   | 50000 | 無       | 横浜     |
| モデル3  | 3   | 30000 | 有       | 横浜     |
| モデル4  | 3   | 30000 | 無       | 調布     |

表-3 学習結果

|       | 損失関数   | 正解率    | 計算時間     |
|-------|--------|--------|----------|
| 基準モデル | 1.218  | 70.08% | 1時間0分35秒 |
| モデル1  | 0.5874 | 88.52% | 1時間0分35秒 |
| モデル2  | 1.185  | 68.83% | 1時間41分9秒 |
| モデル3  | 1.098  | 34.30% | 1時間0分33秒 |
| モデル4  | 1.710  | 63.18% | 1時間0分42秒 |

Dropout層を追加したモデル3を除いて学習は成功

した. 損失関数と正解率において最も良い値を示したのは分類数を減らしたモデルであったが, これは分類数が少なく判別が容易なことに起因していると推定される.

本研究で利用した路面画像は県道が大半であり, 比較的保守作業が頻繁に行われていることが考えられる. 特に神奈川県道2号線においては判別がしやすいと考えられる条件が数多く見られたことから, 汎用性のあるモデルを作るためにも画像の枚数を増やすことが必要であると考えられる.

過学習を防ぐために導入したDropout層のあるモデルでは精度が著しく低くなった. Dropout層の適切な位置やパラメータ等も考慮していくことがより精度の高い判別器の作成に必須と思われた.

また, 学習済の判別器を使用してFine-tuning<sup>3)</sup>を行ったモデル4では精度は劣るものの約63%の判別精度が得られ, 画像への処理の工夫や適切なパラメータに調整することで多様な路線に深層学習を用いた路面性状評価が可能であることを示すことができた.

## 7. まとめ

本研究では客観的な路面性状評価の実現と道路維持管理コストや負担の軽減を目的とし, 車載カメラによる画像を用いて, 深層学習により路面のひび割れ評価を行う判別器の構築を行った. 分類数などの条件を変えることで最高で約88%の判別精度が得られた.

ネットワークの構成やパラメータの調整, 新たな路線画像をデータに加えることで, さらなる精度の向上や汎用性の高いモデルを構築することができると考えられる. 今後は判別結果と画像の撮影地の位置情報を使用し, GISを用いて地図上に路面の性状評価を図示することによって, 路面状況の見える化を図る予定である.

## 参考文献

- 1) 国土交通省近畿地方整備局: 1. 道路老朽化の現状老朽化の現状, <https://www.kkr.mlit.go.jp/road/maintenance/roukyu/genjyou.html> (2018年12月10日閲覧)
- 2) 武井宏将: 初めてのディープラーニング, リックテレコム, 2016.
- 3) 大阪府: 大阪府舗装点検要領, [http://www.pref.osaka.lg.jp/attach/28101/00000000/070\\_hosou\\_honpen.pdf](http://www.pref.osaka.lg.jp/attach/28101/00000000/070_hosou_honpen.pdf) (2018年12月10日閲覧)
- 4) 中山英樹: 深層畳み込みニューラルネット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.
- 5) 藤田一弥, 高原歩: 実装ディープラーニング, オーム社, 2016.