

AI を用いたアスファルト舗装ひび割れの検出

岡山大学大学院 学生会員 ○石崎 未帆 崎田 晃基 正会員 西山 哲
国際航業株式会社 正会員 藤木 三智成

1. 序論

アスファルト舗装は環境の変化を受けやすく、劣化の進行速度のバラつきが大きい。現在、アスファルトの舗装点検は路面性状測定車により、舗装の健全性を評価しているが、ひび割れに関しては点検者が舗装撮影画像から手作業で行い、ひび割れ率を算定している。そのため、膨大な時間とコストを要し、目視作業のために判断結果に個人差が出るといった課題を抱えており、効率的でかつコストの低い方法を検討することは必要不可欠である。

そこで、こうした背景と現状の舗装点検の課題を踏まえて、舗装画像に AI を適用することを考える。路面性状測定車から得られる対象画像と AI の技術とを組み合わせ、舗装画像内からひび割れの自動判読が可能となれば、現状のひび割れ点検において時間とコストを抑えることができ、定量的な評価を行うことが出来ると考える。

本研究では、計算コストが多くかからず、照明変化に頑健な LBP 特徴量を用いる。LBP 特徴量は教師データ内の輝度差を特徴量としているため、教師データ内のコントラストが重要なパラメータとなっている。そこで、画像処理技術を用いてひび割れ箇所を強調することで、特徴量を明確にし、検出精度向上を目的に検証を行った。また、教師データの抽出方法によっても学習するひび割れ形状が変化し、コントラストが変化するため、抽出方法の比較による検証も行った。

2. 機械学習と画像処理技術

2.1 物体検出の手順

物体検出は、画像中から特定の物体を検出する処理であり、学習フェーズと認識フェーズの二段階から成り立っている。




図 2-1 物体検出フロー

学習フェーズにおいては、認識対象画像(ひび割れ画像)に所定の処理を施し、ピクセルデータから学習に適した LBP 特徴量に変換する。

認識フェーズでは、学習で用いたものと同様の手順で学習に用いていない画像を特徴量データへと変換する。抽出した特徴量は、事前に生成された多クラス分類器に入力し、学習結果を用いて写っている画像が検出対象か検出対象外かを判断する。

2.2 LBP 特徴量の基礎理論

LBP (Local Binary Pattern) 特徴量は種々のパターン認識問題において、高い性能を示している。以下に LBP 特徴量の抽出フローを示す。




図 2-2 LBP 特徴量の概略

次の手順により LBP 特徴量を抽出する。

- ① 画像を分割し、分割した 1 部分に着目する。
- ② 取り出した 1 部分の 3×3 画素に注目し、中心画素と周辺画素の輝度値の差を計算する。

キーワード AI 画像処理

連絡先 〒7008530 岡山県岡山市北区津島中 1 丁目 1-1 岡山大学 大学院 環境生命科学研究科
TEL 086-252-1111

- ③ 求めた差が 0 以上であれば 1 を返し, 0 未満であれば 0 を返し, バイナリデータを生成する.
- ④ ②～③の処理を取り出した 1 部分全体に対して行い, 得られたバイナリデータからヒストグラムを生成する.
- ⑤ ①～④の処理を画像全体に対して行くと, ヒストグラムの集まりが得られ, これが LBP 特徴量となる.

2.3 検出器作成

本研究では OpenCv による “WebCamPhoto” というアプリケーションを用いて検出器作成を行った. 正解データ (ひび割れを含む画像) と不正解データ (ひび割れを含まない画像) を用意し, 正解データからひび割れ部をマーキングし教師データとした. 正解データと不正解データに AdaBoost とよばれる機械学習を用いることで, 検出器を作成した.




図 2-3 AdaBoost の概要

2.4 画像処理手法

本手法で用いる LBP 特徴量は, 画像内のコントラストが重要なパラメータとなっており, 教師データ内のコントラスト変化が検出率に影響を与えると考えられる. そこで, ひび割れ箇所を強調するためにフィルタリング等の画像処理を教師データにかけた学習の検証を行った.




図 2-4 平均化処理 (左: 処理前, 右: 処理後)

本研究で用いたフィルタとしては, ノイズ成分を除去するガウシアンフィルタ, エッジ成分を強調するハイパスフィルタ, ソーベルフィルタ, ラプラシアンフィルタ, エンボスフィルタ, 鮮鋭化フィルタ, コントラストを調整する平均化フィルタである.

3. 精度検証実験

3.1 実験概要

本手法で用いる LBP 特徴量は, 画像内のコントラストが重要なパラメータとなっており, 教師データ内のコントラスト変化が検出率に影響を与えると考えられる. そこで, フィルタリング等の画像処理を教師データにかけた学習の検証を行った. また, 学習するひび割れ形状が変化すると, コントラストが変化するため形状を考慮した学習の検出率への影響に関しても検証を行った.




図 3-1 LBP の精度向上に向けた学習

3.2 撮影環境・使用機器

本実験では, 岡山大学環境理工学部周辺の道路舗装をスマートフォンで撮影し, 撮影画像から教師データを作成し検出器の精度検証を行った.

撮影機器は Apple 社の iphone8 を使用し, 絞り値は $f=1.8$ で, 画素数は 1200 万画素である. 水平方向, 垂直方向の解像度は共に 72dpi で, 焦点距離は 4mm とした. 撮影枚数は 100 枚である.

3.3 評価方法

本手法は実際の舗装評価に用いられているひび割れメッシュ評価法を用いて評価を行った. この手法は, 路面に 0.5m 区画のメッシュを表示させ, メッシュ内にひびが 1 本入ればメッシュの 60%の面積が, ひびが 2 本以上入ればメッシュの 100%の面積がひび割れを起こしているとして, 面積換算するものである.

$$\begin{aligned} & \text{目視によるひび割れ率} \\ &= \frac{\text{ひびを含むメッシュの面積}}{\text{撮影画像の面積}} \end{aligned} \quad (3-1)$$




図 3-2 ひび割れ率算定の例

上記の例であると、区画数 80 のうち、ひび割れが 1 本だけある区画が 33、ひび割れが 2 本以上ある区画が 4 のため、ひび割れ率は $(33 \times 0.6 + 4 \times 1) / 80 = 0.2975$ と判定される。

次に、舗装画像から検出器でひび割れを検出し、検出したひびを含むメッシュを全体の面積で割ることで検出器によるひび割れ率を求めた。

$$\begin{aligned} & \text{検出器によるひび割れ率} \\ &= \frac{\text{検出したひびを含むメッシュの面積}}{\text{撮影画像の面積}} \end{aligned} \quad (3-2)$$

また、検出器の精度を定量的に評価するために検出率を以下のように定義する。

$$\text{検出率} = \frac{\text{検出したひびを含むメッシュの面積}}{\text{ひびを含むメッシュの面積}} \quad (3-3)$$

3.4 実験結果

3.4.1 教師データ抽出方法の比較

ひび割れの方向性を考慮せず、画像内からひび割れを抽出する正方形抽出と、縦方向・横方向に延びるひび割れを分けて抽出する長方形抽出の二種類の抽出方法の比較を行った。抽出方法の定義は以下の通りである。

表 3-1 教師データ抽出方法の定義

	幅(比)	高さ(比)
正方形抽出	1	1
長方形抽出(横)	3	1
長方形抽出(縦)	1	3

学習データ数は、正方形抽出、長方形抽出ともに正解データに 2800 枚、不正解データに 2000 枚与えた。評価画像は 10 枚として、以下に検出結果を掲載する。

2 列目は目視によるひび割れ率、3 列目は検出器によるひび割れ率を示しており、各値から算出した平均検出率を最下段に示した。

表 3-2 正方形（左）と長方形（右）の抽出結果

正方形抽出	目視	正方形抽出	長方形抽出	目視	長方形抽出
画像.1	13.9%	9.6%	画像.1	13.9%	9.6%
画像.2	16.3%	10.3%	画像.2	16.3%	12.3%
画像.3	28.3%	10.3%	画像.3	28.3%	15.6%
画像.4	18.0%	6.2%	画像.4	18.0%	7.4%
画像.5	10.1%	6.5%	画像.5	10.1%	9.4%
画像.6	24.3%	18.3%	画像.6	24.3%	14.9%
画像.7	5.9%	1.4%	画像.7	5.9%	5.0%
画像.8	5.8%	2.2%	画像.8	5.8%	4.3%
画像.9	7.2%	6.5%	画像.9	7.2%	4.3%
画像.10	9.9%	1.4%	画像.10	9.9%	7.0%
平均検出率		50.90%	平均検出率		68.60%

以下に、抽出方法比較による検出結果を示す。




図 3-2

正方形抽出の結果




図 3-3

長方形抽出の結果

3.4.2 フィルタ処理による精度検証

教師データにフィルタリング処理を与えた学習結果を以下に示す。ただし、抽出方法に関しては検出精度が高い傾向にあった方を掲載する。

表 3-3 フィルタ処理による結果

フィルタの種類	平均検出率
フィルタなし(正方形抽出)	50.9%
フィルタなし(長方形抽出)	68.6%
ガウシアンフィルタ(長方形抽出)	56.0%
ハイパスフィルタ(長方形抽出)	56.2%
ソーベルフィルタ	0%
エンボスフィルタ	0%
ラプラシアンフィルタ(正方形抽出)	16.6%
鮮鋭化(正方形抽出)	39.3%
平均化(長方形抽出)	71.1%

上記の結果より、抽出方法に長方形抽出を採用し、平均化処理を施すことで検出率向上の傾向があった。

3.5 路面性状測定車撮影画像への適用

本研究において使用した車両は、路面性状自動測定装置 ROADMAN であり、撮影位置は車両中央部、撮影方式はデジタルカメラ方式(画角横 60 度、縦 45 度)である。撮影画素数は 130 万画素で、撮影間隔は 5m である。検証画像数は 30 枚で抽出方法、フィルタ処理に関しては 3.4.2 で提案された手法を採用した。結果としては検証画像 30 枚に対する平均検出率は 71%となり、路面性状測定車による撮影画像に対しても iPhone8 による撮影画像と同程度の検出率を得た。




図 3-4

検出率 90%を超える
画像




図 3-5

検出率 50%を下回る画
像

また、ひび割れ幅と検出率の関係に関しては以下の結果を得た。

表 3-4 ひび割れ幅と検出率の関係

ひび割れ幅	1~3mm	3~5mm	5~7mm	7~9mm	9mm以上
検出率	49%	65%	75%	82%	90%

3.6 考察

結果としては、平均化フィルタ以外のフィルタに関しては検出精度が下がる傾向にあった。輝度ヒストグラムを平坦にすることで、エッジ成分を残しつつ画像全体のコントラストを高めるため、データの質を落とさず、不均一な照明を取り除くことが出来たと考える。そのため、異なるフィルタよりも高い検出率を示す傾向にあったと考えられる。

次に抽出方法の比較の結果に対する考察を述べる。正方形抽出に比べ長方形抽出の方が、検出率が向上する傾向にあった原因について考察する。正方形抽出では方向性を考慮せずひび割れを自己抽出し教師データとした。そのため縦ひび割れ、横ひび割れの特徴量が混在し、一つの検出器を作成する際に

ヒストグラムにばらつきが存在することから誤検出や見落としが増える傾向にあったと考える。一方、長方形抽出は縦ひび割れと横ひび割れで分けて検出器を作成したため、ヒストグラムのばらつきが小さくなる。そのため入力データから特徴量を捉えやすくなり、正方形抽出よりも検出率が向上する傾向にあったと考える。

4. 結論

本論文では、アスファルト舗装ひび割れの自動検出を目的に、LBP 特徴量と画像処理技術を用いて検証を行った。

教師データにフィルタリング処理を施した学習結果ではフィルタなしの長方形抽出・平均化の長方形抽出の検出精度は約 70%程度だったが、そのほかの処理では検出精度は向上しなかった。

この結果に基づき、路面性状測定車による画像への教師データの抽出方法に関して長方形抽出を採用し、平均化処理を教師データにかけることで検出精度向上の傾向があった。また、本手法における検出器は表 3-5 より、幅1~3mm のひび割れを 49%, 3~5mm のひび割れを 65%, 5~7mm のひび割れを 75%, 7~9mm のひび割れを 82%, 9mm 以上のひび割れを 90%の検出率で検出した。

この結果をうけて、技術者による目視によって舗装点検を実施している場所においては、どの箇所にひび割れが多く発生しているかを人工知能に判断させ、損傷箇所が重大であるところを点検者が目視で見るといった作業を分担させることで、現状の点検作業の効率化を図ることが出来ると考える。

次に今後の課題を述べる。本研究ではひび割れ形状を考慮した学習にとどまったが、舗装の損傷原因を考慮した学習により、ひび割れの有無だけでなく損傷パターンの評価にもつながると考えられるため今後さらなる検証は必要である。

参考文献

- 1) 日本道路協会 舗装調査・試験法便覧
- 2) 国土交通省 道路局 道路メンテナンス年報
- 3) OpenCv による画像処理入門 小枝正道, 上田悦子, 中村恭介
- 4) デジタルシリーズ 画像処理 白鳥則郎 監修