

深層学習の手法によりドライブレコーダー撮影画像からポットホールを検出する技術に関する検討

国立研究開発法人 土木研究所 寒地土木研究所 寒地道路保全チーム ○佐藤 圭洋
丸山 記美雄

深層学習の手法により車載カメラの画像からポットホールの検出を行う技術の検討を行っている。本検討では、ドライブレコーダーを車載カメラとして使用し、道路を走行して取得したドライブレコーダー撮影動画から切り出した画像から、深層学習の手法によりポットホール損傷箇所を検出する技術について検討した。また、ポットホールの検出処理モデルにより得られた検出情報の活用について検討したので、それらについて報告する。

キーワード：深層学習、ドライブレコーダー、ポットホール、画像解析

1. はじめに

北海道においてはポットホールが融雪期や春先に多く発生するため、ポットホールの発生状況を把握して適切に対処する必要がある。また、舗装の修繕の目安となる基準として、ひび割れ率、わだち掘れ量、IRIの3つの管理基準が一般的に用いられているが¹⁾、舗装内部の構造的破損が進むと、ポットホールが再発しやすくなると考えられることから、ポットホールによる舗装の損傷に関する定量的な指標として、ポットホールの発生個数などの指標が有用な指標になり得るのではないかと考えられる。

これまで、深層学習の手法を用いて車載カメラの画像からポットホールの検出を行う技術の検討を行っている²⁾。この技術は、車内に設置したビデオカメラによって走行路面を動画撮影して取得した画像を用いて、深層学習の手法によりポットホールの検出を行うものである。深層学習による手法は、機械的に簡便にかつ短時間でポットホールの検出を行うことができるため、ポットホールによる舗装の損傷箇所を容易に把握することが可能である。

本検討では、近年一般にも普及し、高性能化しつつある民生品のドライブレコーダーを車載カメラとして使用し、道路を走行して取得したドライブレコーダー画像から、深層学習の手法を用いてポットホール損傷箇所を検出する手法について検討した。また、ポットホールの検出処理モデルにより得られた検出情報の活用について検討したので、それらについて報告する。

2. 検討手法

深層学習（ディープラーニング）の一つである畳み込みニューラルネットワーク（Convolutional Neural Network、CNN）は、画像認識に最も有効であると考えられる。この深層学習の方法を用いて、ポットホールを機械に学習させ、画像データからポットホールを検出する手法とした。

図-1にポットホールを検出する手法の検討手順を示す。北海道内の国道の冬期のポットホールが発生した区間を撮影した画像から、学習用と検証用のデータを用意し、学習に用いるデータから機械学習をさせて処理モデルを構築した。その後、検証データを機械に解析処理させ、機械が解析処理した結果と、検証データと人間が判定した結果を照合して整合度を検証した。




図-1 ポットホールを検出する手法の検討手順

表-1 ドライブレコーダー撮影条件

レンズ画角	水平113°、垂直60°
記録映像サイズ	Full HD(1920×1080)
取付位置	車内フロントガラス中央上部
本体レンズの向き	前方中央方向(地面と水平)
フレームレート	19fps
車両走行速度	50km/h



写真-1 ドライブレコーダーにて取得した解析対象画像の一例

表-1にドライブレコーダー撮影条件、写真-1にドライブレコーダーにて取得した解析対象画像の一例を示す。使用した画像は、市販のドライブレコーダーを車両に取り付け、道路を走行しながら路面を動画撮影して取得した画像としている。ドライブレコーダーは、車内フロントガラス中央上部に取り付け、車両前方方向の路面を画像サイズ1920×1080 pixel (Full HD)でほぼ水平に近い角度から撮影している。過年度に実施しているデジタルビデオカメラで撮影した場合には、車内へのデジタルビデオカメラの位置、光学ズームによる道路の撮影範囲、設置高さ、ビデオカメラ本体の角度などの調整が可能であり、撮影範囲の中に道路部分を比較的広く取り込み易かった。一方、今回使用したドライブレコーダーでは、ドライブレコーダーの取付位置と視界前方にあるボンネットとの位置関係により、ほぼ水平に近い状態で撮影しているので、撮影画像内に道路部分を広く取り込むことができず、撮影画像範囲全体に対して道路部分の占める面積の割合が小さくなった。そのため、画像解析を行う上では、デジタルビデオカメラで撮影した画像を用いて行う場合と比較して、ドライブレコーダーで撮影した画像を用いる方が不利な条件であると言える。ただし、ドライブレコーダーでの撮影は、取付位置が車内フロントガラス中央上部にほぼ固定されるので、取得する画像の構図がほぼ一定となり、同一の構図の画像として機械的に画像解析する上で汎用性は高くなると考えられる。

3. 学習による処理モデルの構築

学習の方法は教師あり学習とし、教師（人間）が目視画像を見てポットホールを指定して教師データとし、それを機械に学習させた。学習用データの元となる画像は、道央圏の国道約1kmにおいて、2月初旬から3月下旬にかけて週約2回の頻度で合計64回走行してドライブレコーダーにて撮影して得た動画の中から、曇りの日に路面がほぼ乾燥した状態で撮影されたポットホール画像58枚、ポットホールなし画像71枚を切り出して学習に用いて、処理モデルを構築することとした。

SATO Takahiro, MARUYAMA Kimio

表-2にモデル構築作業前段階における事前検討状況を示す。モデルの構築方法として、ビデオカメラ撮影画像で深層学習したモデルでドライブレコーダー画像に適用するケース（CASE 1）と、ドライブレコーダー画像で深層学習したモデルでドライブレコーダー画像に適用するケース（CASE 2）の2つの方法が考えられたため、この2種類のケースで事前検討を行った。CASE 1のビデオカメラ撮影画像で深層学習したモデルでドライブレコーダー画像に適用するケースでは、ポットホールを精度良く検出することができない傾向が見られた。これは、ビデオカメラ撮影画像と比較してレンズが広角となる影響で画像の視野範囲が広くなること、関心領域（ROI）の位置や画素数が異なること、画像の色合いが異なることなどの影響があったと考えられる。一方、CASE 2では、ドライブレコーダー画像にて深層学習を行い試行した結果、ポットホールを一定程度適切に検出できることが目視で判断できた。そこで、本検討では、CASE 2のドライブレコーダー画像を用いてポットホールを学習させ、処理モデルの構築を行うこととした。

図-2及び図-3に画像解析時の学習例を示す。ビデオカメラ画像で行っている方法と同様に、撮影画像中の手前側路面部分を関心領域（ROI）に指定し、ROI領域内にポットホールがある場合、ROI領域内のポットホール部分を赤囲い部分のように指定し、検出すべき異常画像を意味する赤ラベルを付ける（図-2）。ポットホールなし画像には異常がない画像を意味する緑ラベルを付ける（図-3）。その後、深層学習を実行すると、機械がポットホール指定部分の検出方法を学習させる。

表-2 モデル構築作業前段階における事前検討状況

	学習データ	作成した構築モデル	検証データ	目視判別結果	本検討の対象
既存モデル	ビデオカメラ画像にて学習	ビデオカメラ画像による処理モデルを構築	ビデオカメラ画像（別画像）による検証	適切に検出できる	
CASE 1 （事前検討作業）	ビデオカメラ画像にて学習	ビデオカメラ画像による処理モデルを構築	検証用にドライブレコーダーで撮影した画像を使用	検出精度が低下する可能性あり	→今回の検討対象から外した
CASE 2 （事前検討作業）	ドライブレコーダー画像にて学習	ドライブレコーダー画像による処理モデルを構築	検証用にドライブレコーダーで撮影した画像を使用	適切に検出できると判断	→本検討の対象とした



図-2 画像解析時の学習例（ポットホールあり画像）




図-3 画像解析時の学習例（ポットホールなし画像）

表-3 使用画像及び処理モデル構築時の学習条件

使用画像	ドライブレコーダーによる路面撮影画像（水平方向画像、5m間隔で切り出し、トリミング等の前処理なし）
画像サイズ (Pixel Size)	1920 × 1080
ROI領域	撮影画像中の手前側路面部分（縦方向：延長5m、横方向：1車線分2.75m＋路肩＋中央線が入る範囲）
ROI領域のサイズ (Pixel Size)	700 × 140
特徴のサイズ (Feature Size)	20 pixel
チャンネル数 (色)	3 (RGBカラー)
繰り返し学習の回数 (Count Epochs)	50回

表-4 学習データに対するポットホール検出割合

機械の判定 人間の判定	ポットホールなし	ポットホールあり	合計
ポットホールなし	58件 (100%)	0件 (0%)	58件
ポットホールあり	0件 (0%)	71件 (100%)	71件

表-3に使用画像及び処理モデル構築時の学習条件を示す。学習条件はビデオカメラを使用した場合とほぼ同一であるが、ビデオカメラを使用した場合と異なる点は、ROI領域のサイズと特徴のサイズとなる。ROI領域のサイズがドライブレコーダーの視野が広がった分小さくなり、かつポットホールの映り込みも小さくなる。ポットホールを機械に学習させる時のポットホールの設定領域とモデル構築後のポットホールの検出領域がほぼ一致するようパラメータ設定の試行錯誤を行い、処理モデルを構築した。これにより、ポットホールの検出解析時に使用する特徴のサイズを20pixelに設定した。また、学習用データがRGBカラーなのでチャンネル数は3、繰り返し学習の回数は50回として、ポットホール検出モデルを構築した。

表-4に学習データに対するポットホール検出割合を示す。これは、処理モデルを構築後の処理モデルを学習データに適用してポットホール部分を検出させた結果と、人間が判定した結果の対応関係を示している。学習データ内のポットホールは100%検出できており、指定したポットホール範囲との合致度が高い処理モデルであると判断される。

4. 処理モデルの検証

学習データとは別の、未知のデータである検証データに対する検出程度を評価検証した。

表-5に機械による解析と人間の目視の判定結果の整合を示す。人間がポットホールありと判定し、機械もポットホールありと判定した場合（真陽性）、及び人間がポットホールなしと判定し、機械もポットホールなしと判定した場合（真陰性）の2つの対角上のセルが機械と人間の判定がマッチした正検出のケースとなり、正しい検出が行われたと判断されたことを意味している。

表-6に機械がポットホール画像と判断する上位閾値を0.5とした場合の検証結果の一例を示す。上位閾値とは、機械がポットホール画像だと判断する際のスコアの閾値設定である。ポットホールがあり検出できている（正検出、真陽性）割合は86%であり、真陽性の判断は良くできていると評価される。また、ポットホールがないものをないと正しく判定（正検出、真陰性）している割合は84%であり、真陰性の判断は概ね良くできていると評価される。

図-4、図-5、図-6に検証データを解析処理にかけて得られた結果の画像例を示す。図-4は正検出の例である。赤色で強く反応している部分がポットホール部分であり、正しく検出できていることが分かる。図-5は誤検出の例である。路肩水濡れ部をポットホールと誤検出している

表-5 機械による解析と人間の目視の判定結果の整合

機械の判定 人間の判定	ポットホールなし	ポットホールあり
ポットホールなし	正検出、真陰性	誤検出、偽陽性
ポットホールあり	検出漏れ、偽陰性	正検出、真陽性

表-6 解析と目視の判定結果整合 マトリクス表

機械の判定 人間の判定	ポットホールなし (スコア0.5未満)	ポットホールあり (スコア0.5以上)	合計
ポットホールなし	118件 (84%)	17件 (16%)	135件
ポットホールあり	9件 (14%)	56件 (86%)	65件



図-4 正検出の例(真陽性、ポットホールを検出できている)



図-5 誤検出の例(偽陽性、路肩部水濡れをポットホールと誤認)



図-6 検出漏れの例(偽陰性、ポットホールを見落とし)




図-7 上位スコア閾値ごとのポットホール画像検出率、整合率

傾向が見て取れる。図-6は検出漏れの例である。ポットホールを見落としている検出漏れが生じていることが分かる。

図-7に上位スコア閾値ごとのポットホール画像検出率、整合率を示す。上位閾値スコアが0.5の時、人間による判定との整合率は77%程度であり、一定程度ポットホールの検出ができています。また、ポットホール画像検出率は約86%程度と比較的高い値を示し、検出されたポットホールの誤判定は比較的小さいモデルであると言える。

本検討で用いたドライブレコーダー画像は、比較的広い範囲を水平に近い画角で撮影した画像となっていることから、過年度に行ったビデオカメラ画像を使用した場合と比較して、前方路面のROI領域が小さくなり、機械がポットホールの特徴を捉えにくい状況があった可能性がある。また、撮影時の天候の影響によっては、使用する

る画像の明るさが低くなり、検出対象路面の色合いが暗めになることもあり、これによってもポットホールの検出の精度が低下する可能性がある。検出精度向上のためには、学習パラメータのチューニング、欠陥領域の学習のさせ方などの改善の余地があるほか、撮影するカメラの画質の向上、画角や明度の調整など、撮影面での改善の余地もあると考えられる。

5. ポットホール検出情報の活用方法の検討

ポットホールの検出処理モデルにより得られる検出情報の活用を検討した。図-8に処理モデル構築後のポットホール検出情報活用の検討手順を示す。処理モデル構築後に、画像解析により得られる検出情報から、(1) ポットホール個数の集計、(2) ポットホールの縦断・横断位置の算定、(3) ポットホール位置による分類方法、(4) ポットホール面積の推定の検討を行ったので、これらの検討内容や結果の一例を以下に示す。

(1) ポットホール個数の集計

各画像のポットホール個数の集計処理の結果の一例を図-9に示す。解析処理に用いた画像は、隣接する画像同士が重複しない画像を用いており、画像は5m間隔としている。これによって、ポットホール個数は、解析処理




図-8 処理モデル構築後のポットホール検出情報活用の検討手順




図-9 各画像のポットホール個数の把握結果の一例

で得られた画像内のポットホール検出数として集計可能である。この例の場合、各画像のポットホール個数を始点側から順にしてあるが（例えば1枚目のポットホール個数は1個と検出）、これを全枚数集計することで、解析区間全体のポットホールの個数を集計することができる。

(2) ポットホールの縦断・横断位置の算定方法

ポットホールの縦断・横断位置の算定方法を図-10に示す。ポットホールの発生位置として、画像解析で使用する各画像のROI領域（ピクセル： $a \times b$ ）内に、ポットホールの検出位置（画像解析では画像左上から右方向をx軸正方向、下方向をy軸正方向としている）が画像解析値として示される。ここから図-10下に示す実延長を求める式によって図に示す X_i と Y_i が得られる。ここで、 x_i 、 y_i ：ポットホール領域中心座標のピクセル値、 a ：ROI領域の横の総ピクセル値、 b ：ROI領域の縦の総ピクセル値、 θ ：外側線(中央線)と横断線の角度、 W ：ROI領域内の横断方向の長さ(m)、 L ：ROI領域の縦断方向の長さ(m)、 X_i 、 Y_i ：検出したポットホールのROI領域左下（外側線手前側）からの横断位置(m)、縦断位置(m)とし、延長 L (m)間隔の画像200枚を使用している。これを各画像に対してそれぞれ検出されたポットホール位置に対し、図-10の赤枠に示す計算式により、各画像の縦断・横断位置を求めることができる。これにより、始点からの縦断位置と外側線からの横断位置について算定することが




図-10 ポットホールの縦断・横断位置の算定方法

表-7 ポットホール縦断・横断位置の算出結果の一例

a	700
b	140
W	2.75 (m)
L	5 (m)
θ	45°

x_i	203.1	X_i	0.483 (m)
y_i	16.5	Y_i	4.411 (m)

できる。

表-7にポットホール縦断・横断位置の算出結果の一例を示す。例えば、ある画像の $a=700$ 、 $b=140$ 、 $W=2.75$ (m)、 $L=5$ (m)、 $\theta=45^\circ$ の条件下における解析結果として、 $x_i=203.1$ 、 $y_i=16.5$ の値が得られた場合、 X_i 、 Y_i は、図-10の赤枠に示す計算式により、それぞれ $X_i=0.483$ (m)、 $Y_i=4.411$ (m)と算出される。

(3) ポットホール位置による分類

ポットホール位置による分類結果の一例を図-11に示す。図-10により特定したポットホールの縦断・横断位置から、始点からの縦断位置を100mごと、横断位置をOWP(Outer Wheel Path,外側タイヤ通過位置)、BWP(Between Wheel Path,非タイヤ通過位置)、IWP (Inner Wheel Path,内側タイヤ通過位置)に分けて分類した例である。これによってポットホールが多数発生している箇所を把握することができる。例えば、始点からの縦断位置から、始点側から200m～300m内のポットホール個数が数量として最も多く、次いで、600m～700m、700m～800mの縦断位置の辺りも多く分布していることがわかる。また横断位置の分類から、OWPの個数が多く、外側タイヤ通過位置側にポットホールが多く見られることがわかる。




図-11 ポットホール位置による分類結果の一例




図-12 ポットホール面積の推定方法

(4) ポットホール面積の推定

ポットホール面積の推定方法を図-12に示す。ポットホール領域中心座標ピクセル値、ROI領域の縦・横の値、ROI領域内の道路の幅員と延長から、図-12の赤枠に示す計算式によって、ポットホールの概ねの面積を求めることができる。これによって、始点からの縦断位置に対応する各ポットホールの面積を把握できる。

表-8にポットホール面積の算出結果の一例を示す。例えば、ある画像において、 $a=700$ 、 $b=140$ 、 $W=2.75(\text{m})$ 、 $L=5(\text{m})$ 、 $\theta=45^\circ$ の条件下における解析結果として、 $A_i=383.3$ の値が得られた場合、ポットホール面積は、図-12の赤枠に示す計算式により、 $0.128(\text{m}^2)$ と算出される。

表-8 ポットホール面積の算出結果の一例

a	700
b	140
W	2.75 (m)
L	5 (m)
θ	45°
y_i	16.5

A_i	383.3
-------	-------

ポットホール面積	$0.128(\text{m}^2)$
----------	---------------------




図-13 ポットホール面積の推定結果の一例




図-14 ポットホール1個当たりの平均面積推定結果の一例

図-13 にポットホール面積の推定結果の一例、図-14 にポットホール1個当たりの平均面積推定結果の一例を示す。ここでは、それぞれ 100m ごとに集計した数値で示す。なお、ポットホール個数だけではなく、ポットホール面積の分布やポットホール1個あたりの面積の分布も把握することができる。

以上のように、ポットホールの検出処理により得られる検出情報を活用することで、ポットホールの個数、位置、面積などを算定および推定することができ、ポットホールの発生状況を定量的に把握できることが示された。

6. まとめ

本検討による成果を以下に示す。

- (1) ドライブレコーダーにて取得した画像を用いて、深層学習により一定程度のポットホール検出能力を有する処理モデルを作成することができた。
- (2) 深層学習により得られるポットホールの検出情報を活用して、ポットホール個数の集計、ポットホールの縦断・横断位置の算定、ポットホール位置の分類、ポットホール面積の推定が可能であることを確認した。

7. 今後の展開・展望

撮影方法や学習方法には改善の余地があると考えられ、これらを改善することで、ポットホールの検出精度は高まる可能性がある。また、ドライブレコーダーの性能が向上すれば取得できる画像の画質も向上していくと考えられることから、これを併せて処理モデルを改良することにより、ポットホールの検出精度の向上が期待される。

今後は、ポットホール損傷の見落としや過検出を少なくするためのポットホールの検出精度の向上に取り組み、舗装損傷の進行度合の把握、ポットホールの検出手法の構築に向けて、引き続き検討を進めていく予定である。

参考文献

- 1) 国土交通省道路局 舗装点検要領 (平成 28 年 10 月)
- 2) 丸山記美雄, 大浦正樹, 木村孝司: 深層学習によるポットホール判別技術に関する基礎的検討, 第 61 回(平成 29 年度)北海道開発技術研究発表会