

(2) 深度推定を用いたガードレール画像の 点検有効領域の抽出に関する検討

伊藤 航¹・内堀 大輔²・櫻田 洋介³・荒武 淳⁴

¹正会員 NTT アクセスサービスシステム研究所 (〒305-0805 茨城県つくば市花畑 1-7-1)
E-mail: wataru.itou.pt@hco.ntt.co.jp

²正会員 NTT アクセスサービスシステム研究所 (〒305-0805 茨城県つくば市花畑 1-7-1)
E-mail: daisuke.uchibori.tn@hco.ntt.co.jp

³非会員 NTT アクセスサービスシステム研究所 (〒305-0805 茨城県つくば市花畑 1-7-1)
E-mail: yosuke.sakurada.fc@hco.ntt.co.jp

⁴非会員 NTT アクセスサービスシステム研究所 (〒305-0805 茨城県つくば市花畑 1-7-1)
E-mail: astushi.aratake.hf@hco.ntt.co.jp

車載カメラにより取得したガードレール画像を対象に、錆を判定可能な領域を抽出する方法として画像の深度推定の有効性を検討した。単眼車載カメラにより取得した 4400 枚のガードレール画像に対して深度推定を行い、画像深度と画像中のガードレール幅の関係性を分析し、一定の相関性を確認した。画像深度が一定値より小さい画像領域を点検対象範囲から除外することにより、ガードレール幅が一定以上の大きさに写っている画像領域のみを抽出できることを確認した。画像深度のしきい値の最適化により、錆の判定が可能な一定以上のガードレール幅を有する画像領域の抽出と錆判定が困難な一定以下のガードレール幅の画像領域の除去を 89%の精度で行うことができた。本結果より、深度推定によりガードレールの点検有効範囲を効果的に抽出可能なことが示唆された。

Key Words: on-vehicle camera image, monocular depth estimation, image processing, guard rail

1. はじめに

日本における道路、橋梁、トンネル等の社会インフラは高度経済成長期以降で集中的に整備されたため、昨今、インフラの老朽化が急速に進行し、安全な維持管理が求められている。維持管理の上で点検業務は施設状態を正しく把握し、修繕や更新を判断するために必要不可欠な工程であるが、施設管理者は膨大な施設の点検で発生する費用負担や、点検に携わる技術者の減少といった問題を抱えている。これらの問題に対し、国土交通省ではドローン、画像認識、劣化予測等の新技術を活用した点検の効率化を検討している¹⁾。

社会インフラの中で数量が多い道路施設に対して、車両を用いた点検を効率化する手法が複数提案されている。Chun²⁾、Ramalingam³⁾、全ら⁴⁾は車載カメラ等によって取得した路面画像から画像認識を用いてひび割れを検出する手法を提案している。橋爪ら⁵⁾、浅田ら⁶⁾は路面性状測定車両によって取得したデータからポットホール

発生のリスク評価、ひび割れ検出手法を提案している。これらの既往研究^{2)~6)}は車両により検査対象の画像やデータを効率的に取得、解析することにより点検の効率化を実現している。一方で、道路施設の中でもガードレールや標識のような設備は路面と比較して、車両により取得した画像やデータを点検に用いることが難しいと考えられる。例えば車載カメラによってこれらの設備を撮影した場合、取得画像中に検査対象の設備の大きさを一様に写すことは難しい。前述の既往研究^{2)~6)}は路面を対象としているため車両と路面の距離を一定に保ち、画像やデータを取得することができるが、ガードレールや標識を車両から撮影しようとした場合、走行車線、道路線形、設備の設置位置により車両とガードレールや標識との撮影距離を一定に保てないため、画像中に常に一定の大きさや構図で写し続けることが難しい。また、ガードレールを車載カメラによって効率的に撮影しようとした場合、道路に沿って延びていくガードレールのできるだけ長い距離を撮影する必要があるが、カメラから遠方にあるガ

ードレールの範囲は取得画像において小さく写ってしまう。この範囲は、ガードレールに生じた錆、破損、変形等の変状が画像から確認できない可能性があり、変状を見落としてしまうことから点検に有効な画像領域として扱うことが難しいという問題が想定される。

この問題に対して、取得画像の遠方領域を自動的に認識し、点検範囲から除外する手法が有効であると考えられる。既往研究において、単眼カメラ画像から画像深度を推定する手法が提案されている⁷⁾。この手法を用いて車載カメラの取得画像から遠方領域を認識することができれば点検に有効な範囲を効率的に決定することが可能であると考えられる。

そこで、本論では単眼車載カメラにより取得したガードレール画像に着眼し、深度推定モデルを適用することによって、ガードレールが一定以上の大きさで写っている画素領域の選択が効果的に行えるか検討を行う。

2. 画像データセット

ガードレールの画像は図-1に示す車両天井部の2か所に搭載した単眼デジタルカメラにより取得した。カメラ1は車両の進行方向に対して45度、水平から10度下向きに設置されており、沿道のガードレールが取得画像の中央付近に写るように調整している。カメラ2は進行方向に対して135度、水平から10度下向きに設置されており、同様に沿道のガードレールが取得画像の中央付近に写るように調整している。車両の進行方向に対して、カメラ1は前方のガードレール、カメラ2は後方のガードレールの画像を取得する。取得画像は解像度5120 pixel × 5120 pixelでカラー画像である。車両を時速40 km以下で走行し、2m間隔で静止画像を取得した。約20万枚取得した画像の中から、ガードレールが写る4400枚の画像を選定した。さらに、取得画像を512 pixel × 512 pixelに縮小処理を行い、4400枚の画像それぞれについて、ガードレールの画素に対して1、非ガードレールの画素に対して0の情報を付与するアノテーション画像を作成した。

3. 検証条件

(1) ガードレールの大きさと画像深度の定義

取得画像におけるガードレールの大きさと対応する深度は図-2を用いて説明する。図-2(a)は車載カメラによる取得画像、(b)はアノテーション画像、(c)は単眼深度推定モデルを用いた深度マップのうち、ガードレールの画素領域のみの推定結果を示したものである。単眼深度推定モデルには、Ranftl⁷⁾らが提案するモデルと学習データセ



図-1 撮影に使用した車両

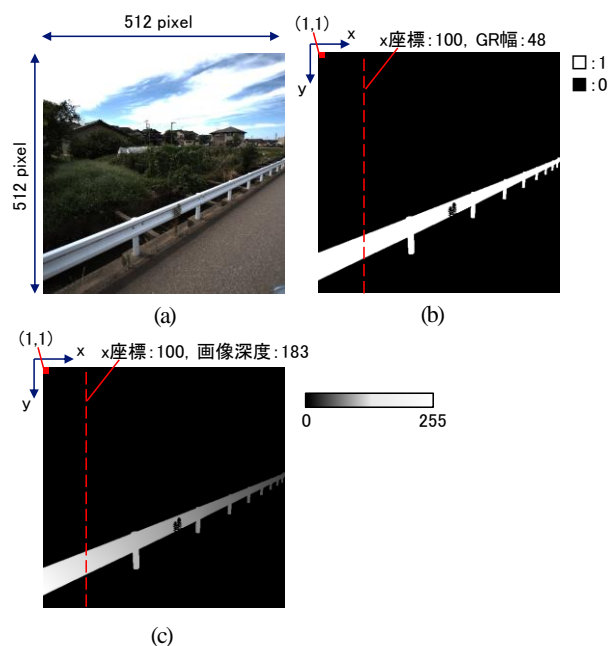


図-2 画像例：(a)車載カメラによるガードレールの撮影画像、(b)アノテーション画像、(c)深度マップ

ットを用いた。このモデルは、単眼の画像から相対的な逆深度を画素単位で計算することが可能な深層学習モデルであり、モデルの学習には屋内外の景色、人、道路、車両等といった様々な画像が用いられるため、沿道のガードレールが写った画像にも有効であると判断した。図-2(c)はガードレールの領域の各画素に0~255の値が入力されている。ここで、0に近い画素は遠方を表し、255に近い画素は近傍を表す。ガードレールは波状断面のビームと支柱により構成されている。本論におけるガードレールの大きさは、画像中のy方向のガードレール画素のカウント数で定義する。(b)において左上の画素の座標を(1,1)と定義し、y方向に1が入力されている画素数をカウントして、カウント数を各x座標におけるガードレール幅(以下、GR幅)とする。例えば、図-2(b)における赤破線の部分はx座標が100でありGR幅が48である。(a)の画像ではGR幅はx座標が大きくなることに従って、

ガードレールが遠方に写るため GR 幅は小さくなる。次に、画像深度の定義について説明する。(b)で定義した GR 幅に対応する深度を(c)から算出する。(b)と同様に(c)の左上の画素の座標を(1,1)と定義し、ガードレール領域の各画素に入力されている深度値を y 方向で合計する。そして、(c)の各 x 座標における深度値の合計を(b)の対応数する x 座標における GR 幅で割った値を(c)の x 座標におけるガードレールの画像深度として定義する。例えば、図-2(c)における赤破線の部分は x 座標が 100 であり画像深度が 183 である。

(2) 支柱と障害物による外れ値の除去

ガードレールの大きさをビームの垂直方向の幅と定義して、取得画像の y 方向のガードレールの画素をカウントすることによって算出したが、ガードレールには支柱があること、草等の障害物によってビームの一部が隠れてしまうケースが発生する。このような場合は画像中からビームの画素領域のみをカウントできていないことがあるため、支柱と障害物によって GR 幅のカウント数が同一の画像中において極度に变化した場合に、变化した部分的な数値を除外する処理を設けた。極度に变化した GR 幅の除去には Liu ら⁸⁾が提案した異常値除去手法を用いた。この手法は決定木による数値の分類手法であり、一定の集合データに対して外れたデータを分類することが可能であり、本検討では障害物によって隠れてカウント数が小さくなった GR 幅や支柱によりカウント数が大きくなった GR 幅の値を除去可能となる。図-3に障害物や支柱によって GR 幅の値が極度に变化したデータを除去した例を示す。図-3(a)は図-2の画像例を用いて障害物や支柱の影響を除去せずに作成した、各 x 座標における GR 幅と画像深度を散布図である。GR 幅と画像深度には正比例の関係があるが、局所的に外れ値が存在することが確認できる。A は一定間隔で発生する支柱の画像を GR 幅に含めてカウントしている可能性が高いことがわかる。B は図-2(b)のガードレールのビーム中央部が草等の障害物によって隠れていて GR 幅が小さくなったと考えられる。次に、図-3(b)は極度に变化した GR 幅の除去処理を行ったのち作成した、GR 幅と画像深度の散布図である。図-3(b)より部分的に発生している外れ値が除去されていることがわかる。

(3) 点検有効範囲の定義

ガードレールで最も多い変状である錆を取り上げ、取得画像を目視で確認した結果、GR 幅が 20 pixel 以下の場合、錆の発生有無の確認が画像から困難であると判断した。そのため、点検有効範囲は GR 幅は 20 pixel 以上の部分と定義した。

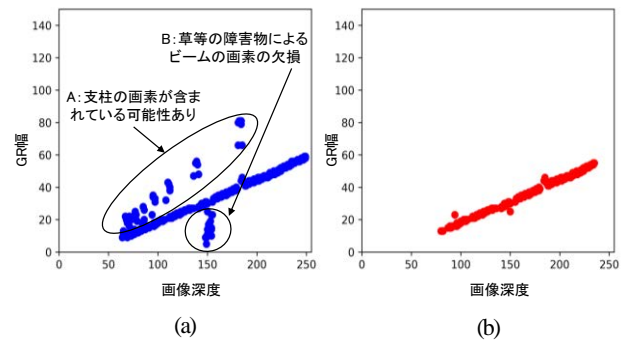


図-3 GR 幅と画像深度の散布図：(a)外れ値の除去前の結果、(b)外れ値の除去後の結果




図-4 画像深度と GR 幅の散布図

4. 検証結果

(1) GR 幅と画像深度の関係と評価指標

画像データセット 4400 枚に対する GR 幅と画像深度の散布図を図-4に示す。全体の傾向として、画像深度が大きくなると GR 幅が大きくなる傾向がわかる。図-4を用いて、ある画像深度を設定することにより GR 幅 20 pixel 以上の画像領域を抽出できるか検討を行う。破線は点検に有効な GR 幅 20 pixel のしきい値を示す。また、実線は画像深度のしきい値であり、直線の左側は画像深度が小さい、つまり取得画像ではガードレールが小さく写っていると判定される領域(点検除外領域)、直線の右側はガードレールが大きく写っていると判定される領域(点検領域)である。破線と実線により 4つの象限に分けることが可能である。図-4の右上の領域は画像深度で分類すると、GR 幅が 20 pixel 以上の画像領域が点検に有効な範囲として正しく抽出される象限である(TPと定義)。右下の領域は画像深度で分類すると、GR 幅が 20 pixel 未満の画像領域が点検に有効な範囲として誤って抽出される象限である(FPと定義)。左上の領域は GR 幅が 20 pixel 以上の画像領域が点検には有効でない範囲として誤って除外される象限である(FNと定義)。最後に、左下の GR 幅は 20 pixel 未満の画像領域が点検に有効ではな

い範囲として正しく除外される象限である (TN と定義) . 本定義に基づき, 画像深度のしきい値を変更した際の各象限に分類される GR 幅の関係性を評価する. 評価指標として, 以下(1)~(3)に示す Accuracy, Recall, Specificity を用いる.

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

$$Specificity = \frac{TN}{FP + TN} \quad (3)$$

(2) 画像深度のしきい値による GR 幅の分類結果

画像深度のしきい値を 0~255 の領域で変化させた際の各評価指標値を図-5に示す. 画像深度のしきい値が73 のとき Accuracy が 0.89 で最大になることがわかった. これは, 点検に有効な GR 幅 20pixel 以上の画像領域と, 点検に有効ではない 20 pixel 未満の画像領域を 89% という高精度で分類可能なしきい値が存在することを示している. しきい値 73 の時の Recall は 0.93 であり, 約 7% の GR 幅 20 pixel 以上の画像領域が点検に有効ではない領域として分類されてしまうことを示している. 同様のしきい値において, Specificity は 0.69 である. これは, GR 幅が 20 pixel 未満の画像領域を点検に有効ではない領域として 69% 削除することが可能であることを示している. 今回のケースでは画像深度しきい値を 73 に設定し, 画像中を点検領域と点検除外領域に分類することによって, 約 7% の GR 幅 20 pixel 以上の画像領域を点検領域から削除してしまうことになるが, GR 幅が 20 pixel 未満の画像領域の 69% を点検除外領域として分類できることがわかった.

5. まとめ

本論では単眼車載カメラにより取得したガードレール画像に対して深度推定モデルを適用することによって, ガードレールが一定以上の大きさで写っている画素領域の抽出が効果的に行えるか検討を行った. その結果, 今回のケースでは深度しきい値を 73 に設定し, 画像中の点検領域と点検除外領域に分類することによって, 約 7% の GR 幅 20 pixel 以上の画像領域を点検領域から除外してしまうことになるが, GR 幅が 20 pixel 未満の画像領域の 69% を点検除外領域として分類できることがわかった. よって, 上記の結果から深度推定を用いることにより, 一定幅以上のガードレールが写っている画像領域を効果的に抽出可能なことがわかった.




図-5 画像深度のしきい値の変化に対する評価指標値

参考文献

- 1) 国土交通省総合政策局: インフラ長寿命化基本計画, https://www.cas.go.jp/jp/seisaku/infra_roukyuuka/pdf/houbun.pdf, (最終閲覧日: 2022年6月7日) .
- 2) Pang-jo Chun, Tatsuro Yamane, and Yukino Tsuzuki: Automatic Detection of Cracks in Asphalt Pavement Using Deep Learning to Overcome Weaknesses in Images and GIS Visualization, *Applied Sciences*, Vol. 11, issue3, 2021.
- 3) Balakrishnan Ramalingam, Abdullah Aamir Hayat et al.: Deep Learning Based Pavement Inspection Using Self-Reconfigurable Robot, *Sensors*, Vol.21, issue8, 2021.
- 4) 全邦釘, 井後 敦史, 南免羅 裕治, 黒木 航汰, 大窪 和明: 車載カメラにより撮影された舗装画像からのディープラーニングによるひび割れ率評価, 土木学会論文集(E1), Vol. 73, No. 3, pp. I_97-I_105, 2017.
- 5) 橋爪謙治, 橋本和明, 全邦釘, 中畑和之, 石田哲也: 排水性舗装におけるポットホール発生リスクに関する定量分析, 土木学会論文集(E1), Vol. 72, No. 3, p. I_115-I_123, 2016.
- 6) 浅田 拓海, 川村 和将, 石田 篤徳, 亀山 修一: Convolutional Neural Network を用いたひび割れ・パッチングの高精度検出手法の開発, 土木学会論文集(E1), Vol. 74, No. 3, pp. I_131-I_139, 2018.
- 7) Rene Ranfil, Katrin Lasinger, David Hafner, Konrad Schindler and, Vladen Koltun: Towards Robust Monocular Depth Estimation: Mixing Datasets for Zero-shot Cross-dataset Transfer, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 44, pp. 1623-1637, 2022.
- 8) Fei Tony Liu, Kai Ming Ting, Zhi-Hua Zhou: Isolation Forest, *Eighth IEEE International Conference on Data Mining*, pp. 413-422, 2008.