

(8) 単眼カメラによる道路空間深度推定と 舗装ひび割れ率計算

佐藤 剛¹・前田 紘弥²・檜山 武浩³・関本 義秀⁴

¹ 非会員 東京大学大学院 工学系研究科社会基盤学専攻 (〒153-8505 東京都目黒区駒場 4-6-1)
E-mail: gosato@iis.u-tokyo.ac.jp

² 正会員 東京大学特任研究員 生産技術研究所 (〒153-8505 東京都目黒区駒場 4-6-1)
E-mail: maedahi@iis.u-tokyo.ac.jp

³ 非会員 東京大学助教 生産技術研究所 (〒153-8505 東京都目黒区駒場 4-6-1)
E-mail: ksym@iis.u-tokyo.ac.jp

⁴ 正会員 東京大学教授 空間情報科学研究センター (〒153-8505 東京都目黒区駒場 4-6-1)
E-mail: sekimoto@csis.u-tokyo.ac.jp

舗装ひび割れ率は MMS とよばれる特殊車両により計測される路面性状値である。高価な MMS の使用を避け、車載カメラを用いて舗装ひび割れ率計算を行うためには画像内における検査領域を指定する必要がある。この際カメラと物体の距離(深度)が必要となる。深度推定については近年深層学習を用いたモデルが提案されている。ところが、既存モデルの出力は単位を持たない相対値であるためそのまま舗装ひび割れ率計算に使うことは難しい。本研究では海外で撮影された動画によって訓練した深度推定モデルのパラメータを埼玉県内の道路動画により補正した。続いて加速度センサ情報を用いることで深度を m 単位で出力するモデルを作成した。その上で道路画像のうち推定深度が 30m 以内の部分を実動抽出し舗装ひび割れ率計算を行い、3 段階評価において 80% の正解率を得た。

Key Words: in-vehicle video, deep learning, depth estimation, road damage, crack ratio

1. はじめに

舗装ひび割れ率とは舗装ひび割れの面積を検査面積で割った値であり、MMS とよばれる特殊車両に搭載されたラインスキャナー撮影画像から目視によりひび割れを検出することで計測される。MMS は高価であるため、MMS を用いない舗装ひび割れ率計算手法を検討することで道路維持管理費用の削減を目指すことができる。

車載カメラを用いた舗装ひび割れ率計算手法として、画像内の 1 車線分の範囲を抽出しその領域内で計算を行う手法が提案されている。既存の領域決定手法ではカメラの位置・傾きを固定することで奥行き方向の検査領域を決定しているが、カメラ位置が未知である場合、奥行き方向の検査領域を決定するためにはカメラと物体の距離(深度)が必要となる。

近年単眼カメラと物体の距離(深度)を深層学習を用いて推定する深度推定モデルが提案されている。このモデルを利用すればカメラ位置が未知であっても検査領域

を決定することができる。ところが、既存モデルの出力は単位を持たない相対値であるためそのまま舗装ひび割れ率計算に使うことは難しい。加えて、既存モデルは海外の車載動画によって訓練されており、日本国内での利用時に精度が担保されない。そこで本論文では、日本の道路画像に合わせて補正されたパラメータを持ち、かつ m 単位の深度を出力する深度推定モデルを作成した上で、舗装ひび割れ率計算領域の自動抽出を実施した。

はじめに既存の深度推定モデルのパラメータを埼玉県内の道路を撮影した動画により補正し、相対深度判定精度が改善することを確認した。その上で、加速度センサから求めたカメラ傾斜角に基づく推定値に画像中央部の深度が一致するように相対深度推定値を定数倍し、m 単位の深度である絶対深度を取得する手法を開発した。

作成した深度推定モデルを用いて、スマートフォン撮影画像のうちカメラからの距離が 30m 以内と推定された部分を自動抽出し舗装ひび割れ率計算を実施した。計算結果を 3 段階評価した結果、80% の正解率を得た。

2. 関連研究

(1) 深層学習による深度推定モデル

本項では車載単眼画像を用いた深度推定モデルに関連する既存研究について述べる。はじめに深層学習を利用した研究として Zhou らの研究¹⁾を紹介した上で、カメラパラメータ未知でも訓練が可能である研究として Gordon らの研究²⁾について述べる。

一般に動画の隣接フレームには共通物体が映る。フレーム N と $N+1$ を考えると、フレーム間のカメラの動きは回転行列 R と移動ベクトル t の組合せで表現できる。 R , t に加え画像深度 D , カメラ行列 K が与えられればフレーム $N+1$ はフレーム N を用いて表現できる。予測されたフレーム $N+1$ と正しいフレーム $N+1$ を比較することで再現損失が計算できる。Zhou らの研究ではこの再現損失を最小化するようにモデルを訓練する。

Zhou らの研究では訓練画像の K は既知とし、単画像から深度 D を予測する深度推定ニューラルネットワークと、2つの隣接画像の組から回転行列 R と移動ベクトル t を予測するカメラ運動推定ニューラルネットワークの2つのニューラルネットワークを、動画を用いて同時に訓練する。Gordon らの研究ではカメラ運動推定ニューラルネットワークでカメラ行列 K の予測も行うことでカメラパラメータ未知でも訓練を可能にしている。Gordon らのモデルの構造を図-1に示す。本研究では深度推定に Gordon らのモデルを用いた。

Gordon らの研究では深度推定精度評価指標として、予測値と正解値の差の絶対値を正解値で割った値の平均である平均相対誤差が用いられている。Gordon らの研究において出力される深度は単位を持たない相対値であるため、平均相対誤差の計算にあたっては予測値と正解値の中央値が一致するように予測値が定数倍される。本論文ではこの定数を定数倍誤差補正定数と呼ぶこととする。

Gordon らの研究では KITTI データセット³⁾が訓練・評価に用いられている。KITTI データセットにはドイツの道路動画と LiDAR 測定深度の組が含まれている。

土木分野においては地物の深度を相対値ではなく m 単

位を持つ絶対値として求めることが必要であり、Gordon らのモデルの相対値出力を直接利用することは難しい。加えて、Gordon らのモデルはドイツの車載動画によって訓練されており、日本国内での利用時に精度が担保されない。そこで本研究では、Gordon らのモデルの内部パラメータを埼玉県内の道路動画により補正し、加速度センサ情報を用いることで深度相対値を m 単位に変換することでこれらの課題を解決することを目指した。

(2) 舗装ひび割れ率推定

本項では車載カメラを用いた舗装ひび割れ率推定に関連する既存研究について述べる。はじめにラインスキャナー画像を用いずに舗装ひび割れ率計算を行った研究として全らの研究⁴⁾について述べる。続いて、カメラを車両内に固定し、撮影した画像のうち1車線領域内に含まれる部分のみを抽出して舗装ひび割れ率を計算した研究として浅田らの研究⁵⁾について述べる。

全らの研究においては MMS の屋根上に設置したカメラで撮影した路面画像を 36 分割し、分割した画像を深層学習によりひび割れを含むものと含まないものに分類することでひび割れ率を計算している。ここで、ひび割れ率は分割された小画像のうち、ひび割れを含むと判定されたものの割合を求めることで計算される。

浅田らの研究では車両前方 5~10m の範囲が映るように市販の一眼レフデジタルカメラを三脚を用いて車両内に固定している。ここからハフ変換と呼ばれる直線検出アルゴリズムにより画像内の車線領域を抽出した後、アフィン変換と呼ばれるアルゴリズムを適用することで車載カメラ撮影画像を上空から撮影したオルソ画像に相当する画像に変換する。最後にオルソ画像に相当する画像を縦横に等分割することで定義通りの舗装ひび割れ率計算を行う。舗装ひび割れは画像の 2 値変換で検出する。

浅田らの手法は MMS を必要としないという利点を持つが、カメラ位置・傾きの固定が必要であるという課題がある。本研究ではカメラ位置が未知であっても、深度推定に基づいて舗装ひび割れ率計算領域を決定することでこの課題を解決することを目指した。




図-1 Gordon らの深度推定モデルの構造

3. 実験の方法

(1) 相対深度推定

2020年7月16日、四輪自動車のフロントガラスにステレオカメラを取り付け、埼玉県狭山市と川越市にまたがる 5km 区間の往復撮影を行った。往復により計 2 本の動画を撮影した理由は、1 本を評価用動画、1 本を学習用動画としたためである。

今回用いるステレオカメラの出力はグレースケール

であるが、Gordonらのモデルはカラー画像で訓練・評価されている。そこでKITTIデータセットのカラー画像をグレースケールに変換した上で訓練を行い、モデルを準備した。続いてこのモデルに学習用動画から作成した連続画像群を追加学習させ、KITTIデータセットに基づいて訓練されたモデルの内部パラメータを日本の道路動画に合わせて補正した。パラメータ補正前後のモデルそれぞれについて、評価用動画に含まれる全画像を用いて平均相対誤差を計算した。深度正解データはステレオカメラ推定深度とし、モデルが出力する相対深度の絶対深度への変換は正解データを用いて行った。

(2) 絶対深度推定

動画撮影中のカメラ方向加速度平均値を a とすると、カメラの水平面からの傾き θ は重力加速度 g を用いて $\arcsin(|a|/g)$ と表される。カメラ設置高 h を用いると、画像中央の絶対深度 D_{center} を $h/\sin \theta$ と推定できる。よって、相対深度を正解深度と比較するにあたり、定数倍誤差補正定数を D_{center} と推定画像深度の画像中央に対応する成分の比とすれば、正解データを使うことなく相対深度を絶対深度に変換できる。この考え方に従い、(1)で得られた相対深度を絶対深度に変換し、平均相対誤差を計算した。深度正解データはステレオカメラ推定深度とした。

(3) 舗装ひび割れ率推定

2020年11月12日、四輪自動車のダッシュボードにスマートフォンを取り付け、(1)で撮影した道路のうちひび割れ率の変化が大きいと予想される3km区間について動画を撮影した。続いて、撮影した画像に対して図-2のようにひび割れ率計算用台形領域を生成した。

上辺は、(2)で作成した絶対深度推定モデルを用い、画像を垂直に2等分する線分上の深度を画像上端から順に求めることにより、深度30mとなる画像内横直線を求め設定した。浅田らの手法における値に相当する10mよりも深度を大きくした理由は、本論文ではダッシュボード上にスマートフォンを設置したため、カメラ設置高 h




図-2 舗装ひび割れ率計算用台形領域生成例

やカメラの水平面からの傾き θ が浅田らの手法に比べて小さく、深度10mでは画像内の深度計算領域が小さくなり道路損傷がほとんど写らなくなったためである。

左辺と右辺は浅田らのひび割れ率推定法を参考に、ハフ変換による区画線検出に基づき設定した。下辺は深層学習による物体領域検出法であるMask RCNNを用いて画像内からボンネット領域を抽出し、ボンネット上端と判定された位置に横直線を引くことで設定した。

作成したひび割れ率計算用台形領域は縦方向・横方向にそれぞれ10分割し、分割された小画像のうち、ひび割れを含むと判定されたものの割合を求めることで舗装ひび割れ率を計算した。

計算したひび割れ率は朝日航洋計測正解値と100m区間別に比較したほか、ひび割れ率0%以上20%未満を診断区分Ⅰ、20%以上40%未満を診断区分Ⅱ、40%以上を診断区分Ⅲとする3段階評価による比較を実施した。

なお、本項の手法を評価するにあたり、舗装ひび割れ検出時に誤差が発生すると、ひび割れ率計算の誤差の原因が本項で提案した舗装ひび割れ率計算用台形生成にあるのか、あるいは舗装ひび割れ検出にあるのかを評価することができない。そのため、舗装ひび割れラベルについては道路画像の目視により手動で設定した。

4. 結果

(1) 相対深度推定

パラメータ補正前後のモデルをそれぞれ「補正前モデル」「補正後モデル」とし、平均相対誤差を計算した値を表-1に示した。具体的な深度推定例として、図-3(a)の画像をステレオカメラで深度推定した結果を図-3(b)、「補正前モデル」で深度推定した結果を図-3(c)、「補正後モデル」で深度推定した結果を図-3(d)に示した。

(2) 絶対深度推定

加速度センサを用いて定数倍補正を実施し絶対深度を出力するモデルを「加速度センサ利用モデル」、相対深度推定モデルの出力をそのまま絶対深度とするモデルを「定数倍誤差未補正モデル」として、平均相対誤差を計算した値を表-2に示した。定数倍誤差補正の実施により平均相対誤差は0.680から0.403へと約40%減少した。

(3) 舗装ひび割れ率推定

舗装ひび割れ率正解値と本手法によるひび割れ率計算結果を100m区間別のグラフとして図-4に示した。表-3に舗装ひび割れ率の3段階区分に基づく本手法の結果を示した。正解区間数は24、不正解区間数は6であったため、正解率は80%であった。




図-3 入力画像と深度推定結果例

(a)入力画像 (b)ステレオカメラ深度推定結果(単位:m)

(c)パラメータ補正前モデル推定結果(相対値) (d)パラメータ補正後モデル推定結果(相対値)

表-1 埼玉県道路動画による深度推定モデル補正結果

	平均相対誤差
補正前モデル	0.280
補正後モデル	0.226

表-2 加速度センサによる定数倍誤差補正結果

	平均相対誤差
定数倍誤差未補正モデル	0.680
加速度センサ利用モデル	0.403




図-4 100m 区間別ひび割れ率計算結果

表-3 3段階区分による舗装ひび割れ率評価結果

解析 正解	診断区 分Ⅰ	診断区 分Ⅱ	診断区 分Ⅲ
診断区分Ⅰ	14	4	0
診断区分Ⅱ	1	7	1
診断区分Ⅲ	0	0	3

5. 考察

表-1における平均相対誤差の減少から、ドイツの動画で学習させたモデルのパラメータを日本の動画を用いて

補正することの有効性が示された。図-3(c)に比べ図-3(d)では車両がより鮮明に浮かび上がっており、定性的にも精度向上が示された。

表-2の通り、定数倍誤差補正を加速度センサで行ったモデルについて、定数倍誤差補正を行わないモデルに比べ平均相対誤差が減少したことから、加速度センサを用いた定数倍誤差補正の有効性が示された。

表-3の通り、舗装ひび割れ率の3段階区分において本手法の正解率が80%となったことから、本手法による舗装ひび割れ率計算領域生成の有効性が示された。

6. まとめ

本研究では車載単眼カメラを用いた深度推定・舗装ひび割れ率計算実験を行い、精度評価を実施した。今後は加速度センサを用いない絶対深度推定の実施や車線検出精度の向上を目指すことが重要であると考えられる。

参考文献

- 1) Zhou, T., Brown, M., Snavely, N. and Lowe, D.: Unsupervised learning of depth and ego-motion from video, *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.1851-1858, 2017.
- 2) Gordon, A., Li, H., Jonschkowski, A. and Angelova, A.: Depth from videos in the wild: Unsupervised monocular depth learning from unknown cameras., *Proc. of the IEEE Conference on Computer Vision*, pp.8977-8986, 2019.
- 3) Andreas, G. and Philip, L.: Vision meets Robotics: The KITTI Dataset, *The International Journal of Robotics Research*, Vol.32, No.11, pp.1231-1237, 2013.
- 4) 全邦釘, 井後淳史, 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(舗装工学), Vol.73, No.3, pp.I-97-I105, 2017.
- 5) 浅田拓海, 亀山修一, 川端伸一郎, 佐々木克典.: 走行車両から撮影した路面画像を用いた舗装のひび割れ評価手法の開発, 土木学会論文集 E1(舗装工学), Vol.70, No.3, pp.I-9-I-16, 2014.