

画像と LiDAR 点群の統合による 橋梁部材同定と損傷スケールの推定

佐々木 拓海¹・板倉 健太²・全 邦釘³

¹ 非会員 東京大学大学院 工学系研究科 博士前期課程 (〒113-8656 東京都文京区本郷 7 丁目 3-1)
E-mail: takumi.sasaki.2512@gmail.com

² 非会員 ImVisionLabs 株式会社 (〒113-8485 東京都文京区本郷 7-3-1 東京大学南研究棟アントレプレナ
ーラボ)
E-mail: kentai@imvisionlabs.com

³ 正会員 東京大学大学院工学系研究科総合研究機構 (〒113-8656 東京都文京区本郷 7 丁目 3-1)
E-mail: chun@g.ecc.u-tokyo.ac.jp (Corresponding Author)

本研究では、老朽化する橋梁の維持管理業務の効率化を目的に、点群データと画像を統合解析し、ひび割れ検出と損傷情報の抽出を行う手法を提案した。DeepLabv3+を用いたセマンティックセグメンテーションにより、画像上のひび割れと橋梁部材を検出し、Segment Anything Model (SAM) を併用して精度向上を試みた。さらに、画像解析の結果を点群と対応付け、点群におけるスケール情報を活用することで画像から検出したひび割れの長さを推定した。

Key Words: Deep Learning, Crack Segmentation, Segment Anything Model, Sensor Fusion Point Cloud

1. はじめに

日本では橋梁の老朽化が進み、2032 年には建設後 50 年を経過する橋梁が約 59 %に達すると予測されている¹⁾。しかし、維持管理のための予算や技術者が不足し²⁾、従来の点検手法では対応が困難になっている。また、現行の橋梁定期点検では、点検結果の記録がテキストや写真に依存し、情報の欠損や主観的な判断の影響を受けやすい。そこで、精度の高い維持管理のためには、網羅的かつ客観的な記録手法が求められている^{3,4)}。この課題を解決するため、近年、点群技術の活用が注目されている。点群データは、LiDARや地上型レーザースキャナを用いて 3 次元的に橋梁の形状を取得でき、従来の点検より客観的なデータ記録が可能である。国土交通省も点群技術を活用した点検支援技術の導入を推進し、各自治体でもオープンデータ化が進められているなど^{5,6)}、データドリブンでの効率的な維持管理のための環境の整備が進められる⁷⁾。しかし、点群データの処理には計算コストがかかり、損傷の特定や解析の自動化が十分に進んでいない⁸⁾。さらに、点群データは点の集合体であるため、点同士の関係性や構造的情報を直接的に表現することが難しいといった課題もある⁹⁾。これらの課題を克服し、実

用的な維持管理手法を確立するには、点群データと画像解析を統合し、損傷情報の自動抽出や診断技術を発展させる必要がある。

これらの背景から、点群データを活用して診断に応用するような試みが近年盛んにおこなわれている。田中ら¹⁰⁾は、事前に取得した Digital-Mapping データと点群を照らし合わせ、点群上での面を識別し、3 次元モデルを生成する手法を提案した。稲富ら¹¹⁾は、点群を特定の部材に分割するセグメンテーションタスクを行うため、点群を画像化したうえで画像上でセマンティックセグメンテーションを施し、点群上でのセグメンテーションを行う手法を提案した。また、点群上から損傷を抽出するため、関ら¹²⁾は複数の点群データを重ね合わせ、その差分からうきや欠損といった損傷を検出する手法を提案した。既往研究においては、橋梁の外観を 3 次元モデルとして点群で保持するのみならず、点群データを処理することにより、情報抽出や損傷箇所の特定を行う手法が示されている。しかし、点群にはその解像度の粗さからひび割れの検出が容易でない¹³⁾ことなどから、橋梁点検において重要であるひび割れの検出や点群データを活用した長さ情報の定量的な評価に関する研究は、依然として十分ではない。

そこで本研究では、点群取得時に得られるデータと画像情報を統合的に活用することにより、ひび割れの検出と長さ情報の抽出を試みる。具体的には、点群のみでは検出が困難なひび割れを画像から抽出し、その情報を点群データと連携させることで、点群上でひび割れを検知することを目指す。また、画像単体では取得が困難なスケール情報を点群から取得し、これを画像解析結果と結びつけることで、ひび割れの長さを推定する。このような手法により、土木技術者が従来の近接目視に依存して行っていたひび割れの発見と診断を自動化することが可能となる。これにより、橋梁の維持管理における点検および記録作業の効率化が図られるだけでなく、点検技術者による誤診断リスクの低減が期待される。

2. 研究手法

(1) 概要

本研究では、点群と画像を同時に取得可能な計測ツールとして Matterport Pro3 (Matterport, Inc., USA) (以下、Matterport と呼ぶ) を使用した。Matterport はレーザーパルスを観測対象に照射し、その反射光を受け取るまでの時間を基に物体までの距離を計測するリモートセンシング技術である LiDAR 技術を採用しており、高精度かつ高密度な 3 次元点群データの取得が可能である。レーザーの波長は 904 nm、視野角は水平 360 度・垂直 295 度、計測距離は 0.5~100 m で、1 秒あたり 10 万点、1 スキャンで 150 万点を取得できる。計測時には三脚に設置した Matterport を 90 度ずつ回転させ、1 地点で上下左右前後 6 方向の画像と点群を同時取得し、複数地点からの撮影を繰り返すことで橋梁全体のデータを網羅的に取得する。出力されるデータには E57 形式の色付き点群、各地点の ply 形式点群、6 方向の画像、姿勢情報 (クオータニオン) が含まれ、これらはセマンティックセグメンテーションによる部材検出や、ひび割れ長さの推定といった解析に利用される。

本研究においては、まず Matterport で取得された画像に対して、セマンティックセグメンテーションによるひび割れの検出と部材推定を行う。部材推定ではさらに Segment Anything Model を活用し、より高い精度での部材推定を目指す。これらの結果から、必要な部材上でのひび割れを選定する。また、カメラキャリブレーションによって得られたパラメータをもとに、点群の点と画像の画素の対応関係を求め、画像上のひび割れが点群上でどの位置に存在するかを特定する。最終的に点群上でのスケール情報を活用して該当するひび割れの長さを推定する。

(2) セマンティックセグメンテーション

セマンティックセグメンテーションは、画像内の各画素に対して特定のクラスラベルを割り当てる画像解析手法であり、物体の領域を精密に識別することが可能である。この技術は構造物の部材分類や損傷検出など、土木分野における画像処理にも広く応用されている。本研究では、このセマンティックセグメンテーションに用いるモデルとして、精度と汎用性の高い DeepLabv3+ を採用した。DeepLabv3+ は、空間的な特徴を保持しつつ広域な文脈情報を捉えることができる構造を有しており、特にセグメンテーションタスクにおいて優れた性能を発揮する。本研究では、PyTorch (バージョン 2.3.0) を用いて実装し、CUDA および cuDNN と併用することで計算効率を向上させた。学習には、画素ごとの分類精度と領域全体の一貫性を同時に評価できる DiceBCE 損失関数を採用し、最適化には Adam アルゴリズムを用いた。また、学習の最大エポック数を 100 に設定し、10 エポック以上損失の改善が見られない場合に早期終了することで、過学習の防止を図った。エンコーダ部分には、軽量かつ性能の高い ResNet18 をバックボーンとして用い、ImageNet で事前学習された重みを初期値として活用した。このセグメンテーションモデルは、ひび割れ検出および部材の推定という二つの目的に応じて活用される。

ひび割れ検出モデルの学習にあたり、Eric ら¹⁴⁾が作成したコンクリートひび割れ損傷検出用のデータセットである Concrete Crack Conglomerate Dataset¹⁵⁾と Labeled Cracks in the Wild (LCW) Dataset¹⁶⁾を活用する。また、部材推定モデルの学習においては、茨城県つくばみらい市および福島県石川郡平田村の小規模橋梁を Matterport で撮影し、得られた画像に対してアノテーションを施して学習データを作成した。また、Google Map の Google Street View から見つけることができる橋梁のスクリーンショット、Matterport で撮影した橋梁をバーチャルツアーでみられる機能をもとに橋梁を見たスクリーンショット、デジタル道路地図等を基盤として各種データを紐付けるデータプラットフォームである xRoad から得られる橋梁点検の画像、ひび割れ検出でも活用した Labeled Cracks in the Wild (LCW) Dataset から画像を取得し、アノテーションを施したうえで学習データセットに加えた。部材推定のアノテーションにおいては画像から判別が可能と考えられる以下の通り 9 つの部材に分けることを試みた。点群に対して直接セマンティックセグメンテーションを施し、部材を推定する試みもある¹⁷⁾が、本研究では高解像度の画像が得られることに着目して画像に対してセマンティックセグメンテーションを施すものとする。

表-1 部材検出で付与したラベルの説明

部材箇所	ラベル名	概要
上部構造	floor_upper	橋梁正面. 舗装などが該当する.
	belongings	橋梁の付属物と見なせる部分. 地覆や高欄, 橋梁添加架管などが該当する.
下部構造	girder_steel	鋼桁.
	main_concrete	橋梁下部構造で主に荷重を支える役割を担う部分.
	bearing	支承.
	pier	橋台, 橋脚.
	floor_under	橋梁下部構造で, 上記以外のもの.
背景	background_road	道以外の背景箇所. 道.

(3) Segment Anything Model

SAM (Segment Anything Model) (Meta Platforms, Inc., USA) ¹⁸⁾は、汎用的なセグメンテーション基盤モデルであり、追加学習を行うことなく、入力画像と点やボックスを指定するような簡単なプロンプトを入力することで、任意のオブジェクトを自動的に抽出できる点が特徴である。SAMは、11万枚の画像と11億のマスクからなる大規模データセットにより学習されており、多様な画像に対して汎用的な性能を有する。セグメンテーションタスクにおいては、精度の高い結果を得るために高品質な学習データの整備が不可欠であるが、その作成には大きな労力とコストがかかる点が課題である ¹⁹⁾。本研究では、橋梁部材の検出精度を向上させるために独自の学習データを作成するとともに、十分なデータ量が確保できない場面を想定し、補助的手法としてSAMを併用する。具体的には、セマンティックセグメンテーションによって部材推定を行った後に、各部材に該当すると推定された画素の一部をランダムに選定し、それらの画素をSAMの入力として設定した画素が含まれるオブジェクトを部材推定の結果として採用する。これにより、限定的な



図-1 SAM使用のイメージ

撮影した画像に対して、検出したいオブジェクト内外の点を指定することで、該当部材を推定する。

学習データでも部材検出の精度向上を図ることを目的とする。

(4) 部材推定結果によるひび割れのフィルタリング

ひび割れ検出モデルを適用する画像が学習データよりもさらに遠方から撮影され、多くのオブジェクトを含む画像であることからひび割れの誤検出が生じることが想定された。こうした誤検出の結果がノイズとして推定結果に影響を与える可能性がある。そこで、本研究では、橋梁に関連する部材の情報を活用し、検出対象を必要な範囲に限定することで、これらの課題を解決することを目指す。具体的には、床版、コンクリート桁、鋼桁、舗装、付属物、支承、橋脚および橋台に関連する情報を抽出することを目的とし、これら以外の部材や不要な領域については除外する。たとえば、鋼桁はその材質上ひび割れが発生しないため、鋼桁と推定された部材上で検出されたひび割れは誤検出であると判断できる。このように、部材ごとの特性を考慮することで、対象範囲を限定し、適切なフィルタリングを行う。また、部材の情報を活用することで、ひび割れの発生状況を部材ごとに把握することも可能である。たとえば、床版上のひび割れを検出し、その長さを推定することで、床版のひび割れ状況を定量的に評価することができる。このような処理は、橋梁点検における診断精度の向上に寄与すると考えられる。

(5) センサーフュージョン

本研究では、Matterport 内の LiDAR センサーとカメラを用いてセンサーフュージョンを行い、画像解析結果と点群の座標情報を相互に対応付ける。Matterport による LiDAR 点群の取得では、各点の座標が Matterport 独自の xyz座標系で記録される。この座標系をまずカメラ座標系に変換する。カメラ座標系では、光源中心を原点とし、z 軸を光軸方向、x 軸および y 軸をそれぞれ画像の横方向および縦方向に平行とする。いずれも直交する 3次元座標系であり、Matterport座標系からカメラ座標系への変換は、回転と平行移動を表すベクトルである外部パラメータによって表現される。さらに、カメラ座標を画像座標へ変換するためには、内部パラメータが必要となる。カメラの光学中心と画像の投影中心は一致せず、両者の間には焦点距離 f を持つ投影面が存在する。カメラ座標系の z 軸に直交するこの投影面において、カメラ座標と画像座標の関係は相似性に基づいて定義される。この幾何学的関係により、カメラ座標から画像座標への変換は行列演算により行うことができ、内部パラメータ行列と外部パラメータ行列の積を用いることで、世界座標上の点を画像座標へ射影することが可能となる。これらの座標変換処理を通じて、画像上で抽出されたひび割れや部

材ラベルと、点群データとを空間的に対応させることが可能となり、点群に基づく構造物の損傷情報の高精度な推定が実現される。本研究ではこの手法を活用し、点群上の各点に画像由来の情報を付与する統合的解析を行う。

このためにはカメラの特徴ごとに定まる内部パラメータとカメラと点群の座標系の位置関係を示す外部パラメータを求める必要がある。まずは、この推定を行うためにカメラキャリブレーションを実施する。内部パラメータの推定には、MATLAB (MathWorks, USA) のカメラキャリブレーションアプリを用い、チェッカーボード画像から画像座標とカメラ座標の対応を基に算出した。Matterport は 6 方向に撮影を行うが、前後左右と上下で異なるカメラが用いられるため、それぞれ個別に内部パラメータを求めた。内部パラメータの推定には、MATLAB のカメラキャリブレーションアプリを使用し、白黒の正方形が交互に配置されたチェッカーボードを撮影した画像とチェッカーボードの正方形のサイズを入力として用いた。外部パラメータは、チェッカーボードの点群と対応する画像をもとに、MATLAB を活用して推定した。ここで求められた内部パラメータと外部パラメータを用いることで、式(1)から点群上の点の座標を画像上での座標に変換することができる^{20,21)}。ここで内部パラメータは各座標方向の焦点距離 f_x, f_y と主点の座標 c_x, c_y を用いて、外部パラメータは回転を表す r を用いた回転行列とカメラの位置を表す t を用いた並進ベクトルにより表される。

$$s \begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \begin{pmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} r_{11} & r_{12} & r_{13} & t_1 \\ r_{21} & r_{22} & r_{23} & t_2 \\ r_{31} & r_{32} & r_{33} & t_3 \end{pmatrix} \begin{pmatrix} X_w \\ Y_w \\ Z_w \\ 1 \end{pmatrix} \quad (1)$$

さらに、点群スキャン時における Matterport の向きは毎回わずかに異なるため、同一地点を測定しても、得られる点群の座標系はスキャンごとに異なる基準に基づいて記録される。この姿勢の違いを補正し、全てのスキャンを統一された座標系で扱うためには、Matterport で記録される姿勢情報を活用した補正が必要である。Matterport のデータ取得時に記録される姿勢情報であるクォータニオンは、物体の 3 次元空間における回転を表現する手法であり、これを回転行列に変換することで、点群データへの回転補正が可能となる。本研究では、クォータニオン成分 w, x, y, z を用いて構成される式(2)の回転行列 R を適用し、各スキャンに含まれる点群に逆回転を施す。これにより、点群の座標系をスキャン時の姿勢に依存しない統一された状態に変換することができる。

$$R = \begin{pmatrix} w^2 + x^2 - y^2 - z^2 & 2(xy - wz) & 2(xz + wy) \\ 2(xy + wz) & w^2 + y^2 - x^2 - z^2 & 2(yz - wx) \\ 2(xz - wz) & 2(yz + wx) & w^2 + z^2 - x^2 - y^2 \end{pmatrix} \quad (2)$$

これにより、点群の各点が画像上のどの画素と対応しているかを正確に特定することが可能となる。以上の 2 段階、すなわち①クォータニオンを用いた点群座標の姿



図2 変換式を活用して画像に点群を重ねた結果

勢補正、②座標変換による画像座標への射影、を行う式(2)を通じて、スキャンごとの差異を排除しつつ、統一的かつ一貫性のある点群と画像の対応付けが実現される。

(6) ひび割れ長さの推定

本研究では、ひび割れ長さの推定を行う。ひび割れの長さを「ひび割れ領域内の任意の 2 点間で最大となるユークリッド距離」と定義し、これを推定する手法を採用した。なお、ひび割れ幅は診断上重要な情報であるが、Matterport による計測誤差が 1m あたり $\pm 2\text{mm}$ であり²²⁾、通常の撮影距離が 1m 以上となることから、 10^{-1}mm オーダーの精度を要するひび割れ幅の測定には適していないものとして、本研究でひび割れに関連して抽出する情報はひび割れ長さとした。

センサーフュージョンの結果から、点群のひび割れに対応する点を画像上に投影した際の座標に変換することができている。この変換された座標と画素を MATLAB を活用して最近傍法によりひび割れ画素に最も近い点群の点を 1 対 1 で対応させる。これは一つの画素に対して複数の点に対応するものとして推定を行うと、距離計算において計算量が大幅に増加するため、1 対 1 の対応関係を求めている。これらの処理の結果、ひび割れと判定された画素に対応する点群座標が得られる。連続するひび割れと判定された画素に対応する点のすべての組についてユークリッド距離を計算することでひび割れの最大距離を推定し、これをひび割れの長さとする。

また、画像内に複数のひび割れが存在する場合には、各ひび割れに識別番号を付与し、それぞれ独立に長さを算出する。ひび割れ画素同士が隣接している場合は、同一のひび割れとみなし、連続領域として一括して処理する。以上の手法により、ひび割れごとの長さを定量的に推定する。

3. 結果と考察

(1) ひび割れ検出

本研究では、ひび割れ検出モデルの性能を評価するた

表2 ひび割れ検出モデルのパフォーマンススコア

Dice Score	Accuracy	Precision	Recall	Specification
0.4985	0.9856	0.5518	0.4545	0.9941

めに、テストデータに対する適合率を採用した。精度を評価する指標としては、Dice Score, Accuracy, Precision, Recall, Specificityの5つを用いている。これらの評価指標を用いて、先述のセマンティックセグメンテーション手法を基に学習を行ったモデルの性能を測定した。テストデータを用いて予測を行った結果を表2に示している。本研究では、DeepLabv3+を使用したひび割れ検出モデルを適用した。このモデルは推定結果としてlogitと呼ばれるスコアを出力する。logitスコアは実数値をとり、正の値の場合はひび割れに該当する可能性が高いことを示し、負の値の場合はひび割れに該当する可能性が低いことを示す。本研究では、このlogitスコアが正の値を示す画素をひび割れと判定し、性能評価を行った。本研究ではConcrete Crack Conglomerate DatasetとLabeled Cracks in the Wild Datasetの2種のデータセットを用いたが、これらのデータセットのみを学習を行ったモデルではRecallがそれぞれ70.7%、18.77%であったことが報告されている¹⁴⁾。この違いはデータセットの画像がコンクリートに近接しているか、遠方からの画像であるかに由来した差となっている。これらの結果に対して本研究で学習したモデルのRecallスコアである45.45%はこれらの中間的な値となった。また、Dice Scoreは0.4985となっている。従来のひび割れ検出アルゴリズム^{23,24)}に対して相対的に精度が低くなっているがこれはDeepLabv3+を活用していることやコンクリートから離れた位置から撮影し、ひび割れが明瞭に映らないような検出難易度の高い画像を用いていることによるものと考えられる。

また、具体的なモデルの性能を検証するため、実際に画像を適用した結果について考察する。画像にはっきりと映る明確なひび割れについては良好に検出することができた。一方で実際のひび割れ幅に対してやや過大にひび割れ幅を検出していることも確認される。また、コン




図3 ひび割れ検出モデルの適用結果



図4 Matterport 画像へのモデル適用事例

クリートに近接しない画像に対するひび割れ検出では画像から明瞭に確認できないひび割れ箇所について一部ひび割れの検出漏れがあることもわかった。

Matterportで撮影された画像に対して本モデルを適用した結果について考察する。Matterportで撮影される画像のサイズはひび割れ検出モデルよりも大きいので、一度撮影された画像を分割したのちに再度結合して復元している。検出されたひび割れ箇所は、白色のマスクで表示されている。表面が様なコンクリート表面でのひび割れや顕著なひび割れについては適切に検出される一方でひび割れかどうか不明瞭な箇所については検出されない傾向にあることが確認できる。また、コンクリートの色むらや部材間の影、直線的な部材境界箇所についてひび割れでない箇所が誤検出される傾向にあることも確認できた。

以上の結果から、Matterport画像におけるひび割れ検出モデルの適用では、顕著なひび割れの検出が可能であるものの、微細な箇所では検出漏れが発生する傾向がある。また、様なコンクリートが広がる橋梁下面のような箇所では検出漏れは少ないものの、色むらや影などの影響で誤検出が生じることがわかった。さらに、背景や画像分割によるコンテキストの欠如が誤検出を増加させる要因となっていると考えられる。

(2) 部材検出

本研究では、部材検出の精度評価において、テストデータに対する適合率を基本指標とし、さらにDice Score, Accuracy, Precision, Recall, Specificityの5指標を併用して、モデル性能を多角的に評価した。これらの指標は、全体的な検出精度に加え、各部材ラベル(全9種)ごとの性能を個別に定量化する目的で用いられる。部材検出にはDeepLabv3+を使用し、推定結果として得られるlogitスコアは各画素に対する部材の確からしさを示す実数値であるが、SAMとの連携を前提とした本研究では、対象画素の明確な選定が必要となる。そのため、logitスコアを0~1の範囲に正規化するためにsigmoid関数を適用し、一定の閾値以上のスコアを持つ画素を部材に該当すると判断した。これにより、SAMへの適切な入力が可能となり、補完的な部材検出処理の精度向上を図った。ここでは各部材に対してsigmoid関数での閾値を0.5, 0.8,

表-3 ラベルごとの部材検出モデルスコア

ラベル	Dice Score	Accuracy	Precision	Recall	Specification
floor_upper	0.3839	0.9264	0.6574	0.2711	0.9870
belongings	0.2477	0.9561	0.3096	0.2064	0.9833
girder_steel	0.6681	0.9737	0.6133	0.7336	0.9827
main_concrete	0.6805	0.9383	0.7314	0.6364	0.9731
bearing	0.4004	0.9510	0.4160	0.3858	0.9762
pier	0.0353	0.9943	0.0278	0.0482	0.9964
floor_under	0.5418	0.9746	0.7816	0.4146	0.9956
background	0.8736	0.8540	0.9217	0.8303	0.8908
road	0.3237	0.9490	0.4297	0.2596	0.9830

0.95, SAM の活用の有無と活用する場合は入力時に指定する画素数を SAM の活用無し, 10 点, 30 点の 9 つのパターンについて精度評価を行った. その結果各部材に対してもっとも Dice Score の値が高いパターンの精度について検討する.

部材検出については, セマンティックセグメンテーションで高い精度を示す DeepLabv3+を用い, 9 つの部材ラベルを設定して推定を行った. トレーニングデータ中に多く含まれる background については高い精度で検出が可能であった. また, 橋梁上面, 鋼桁, 主桁, 橋脚といった主要な部材についても一定の精度が得られた. 一方で, その他の部材については, 他のラベルとの類似性が高いことや学習データにおける割合が低いことなどの理由から精度が低下したと考えられる.

また, 部材検出精度の向上を目的として SAM を併用した. セマンティックセグメンテーションでは, 画素ごとの特徴に依存しているため, 対象オブジェクトの一部しか検出できないケースが見られるが, SAM を適用することで, 対象オブジェクト全体を自然な形で抽出でき, 検出範囲の拡張に寄与することが確認された. 一方で, セグメンテーションによる誤検出が存在する場合, SAM がそれを拡張してしまい, 精度が低下する場合もある. 特に誤検出画素が多い場合には, SAM の適用が逆効果となる可能性がある. 以上のことから, SAM の適用効果はセマンティックセグメンテーションの結果や誤検出の状況に依存するが, その特徴を理解したうえで適切に活用することで, 実務的な点検業務や維持管理の場面で有用性を発揮する可能性が高いといえる.

本研究では, 点群に部材情報を付与する方法論の提示に加え, 部材情報を用いたフィルタリングによるひび割れ検出精度の向上も目指している. 具体的には, Matterport で取得したデータに対して, 単純にひび割れ検出を適用した場合と, 部材情報を活用してひび割れ損傷を検知したい部材上のひび割れのみを抽出する処理を組み合わせた場合を比較した.

ひび割れ検出のみを適用した場合には, 電線など本来




図-5 Matterport 撮影画像への SAM 適用事例



図-6 部材情報を活用したひび割れフィルタリング

はひび割れと無関係な部分に大規模なひび割れ損傷があると誤って推定されている例が確認された. 一方で, 部材検出の結果を統合し, ひび割れ検出結果を部材情報でフィルタリングすることで, このような誤検出が事前に除去されていることが分かった. このフィルタリング処理により, ひび割れ検出の精度が向上し, 無関係な領域に対する誤検出を抑えることが可能となった.

さらに, 橋梁上に検出されたひび割れについては, 部材情報と統合した処理を適用しても必要なひび割れ検出情報が保持されており, 適切な処理が行われていることが確認された. これにより, 部材情報を活用したひび割れ検出手法が, 必要十分な精度で損傷検知を実現できる有効なアプローチであることが示唆された.

(3) ひび割れ長さ推定

本研究では, ひび割れの長さ推定手法の有効性を検証するため, 東京大学構内のコンクリート壁を対象に実験を実施した. 複数のひび割れが明瞭に観測でき, かつ実測による比較が可能であったため, 橋梁ではなくコンクリート壁を対象とした. 対象としたひび割れは, 画像内に全体が収まり, 複数の撮影点から観測可能なものに限定し, 境界が曖昧であった 1 箇所を除く 13 箇所のひび割れについて長さの推定を行った. コンクリート壁に対して垂直方向に 1.5 m 離れた地点から画像からひび割れを検出, ひび割れ長さの推定を行った.

推定結果は現地でクラックスケールを用いて手動で実

表4 ひび割れの実測長さと推定値

	推定値	実測値	誤差
1	10.4 cm	11.2 cm	7.7 %
2	9.1 cm	9.8 cm	7.7 %
3	9.6 cm	9.3 cm	-3.1 %
4	8.4 cm	7.7 cm	-8.3 %
5	8.2 cm	8.6 cm	4.9 %
6	6.4 cm	7.1 cm	10.9 %
7	6.2 cm	6.8 cm	9.7 %
8	5.1 cm	5.8 cm	13.7 %
9	3.3 cm	3.6 cm	9.1 %
10	4.8 cm	6.5 cm	35.4 %
11	2.5 cm	2.1 cm	-16.0 %
12	2.5 cm	2.0 cm	-20.0 %
13	2.1 cm	2.5 cm	19.0 %

測した値と比較する。その結果、誤差はいずれも2cm以下であった。特に幅 0.15 mm 以上のひび割れに対しては、高い精度での長さ推定が可能であることが確認された。一方、ひび割れが短く細い場合には、検出漏れや輪郭の不明瞭さにより誤差の割合が大きくなる傾向が見られた。この結果は、ひび割れ検出精度が長さ推定の精度に大きく影響することを示しており、画像解析の改善が今後の課題である。

また、撮影地点や方向の違いが推定結果に与える影響についても検討を行った。特定のひび割れ（実測値 8.6 cm）に対して、Matterport の設置位置や向きを変えて撮影を行い、得られた画像からひび割れを検出して推定を実施した。その結果、同一地点内で撮影方向のみを変えた場合には、推定値の誤差は最大でも 5%以内に収まり、姿勢補正処理の有効性が確認された。一方、異なる地点からの撮影では、推定誤差にばらつきが見られた。特に、地点Dでは誤差が大きいが、これは撮影条件やカメラの角度、光の影響などにより、ひび割れが画像上に明瞭に映らず、ひび割れの全体が画像解析によって検出されなかったことに起因する。ひび割れ損傷の長さを適切に推

表5 撮影箇所ごとの推定値と誤差

地点	方向	高さ	推定値	誤差
A	a	1.8 m	8.2 cm	4.90 %
A	b	1.8 m	8.4 cm	2.40 %
A	c	1.8 m	8.4 cm	2.40 %
B	d	1.8 m	9.1 cm	11.0 %
C	e	1.3 m	8.4 cm	2.40 %
D	f	1.3 m	5.7 cm	30.5 %

定するためには、現状のモデルではひび割れに近接して撮影する必要があることが示唆された。

以上の結果から、本研究で提案した手法は、画像上に明確に表れたひび割れについて高精度な長さ推定が可能であることが確認された。測定誤差の多くは 10 %以内に収まり、全体の誤差も 30 %以下程度に抑えられていた。また、Matterport の特性である複数視点からの撮影を活用することで、外れ値を排除し、より信頼性の高い推定が可能となる点も実務上有用であると考えられる。今後は、より微細な損傷への対応と、検出精度のさらなる向上が課題である。

4. まとめ

本研究では、Matterport で取得した点群と画像を対応付けることで、橋梁のひび割れ長さを推定する手法を提案した。画像解析にはDeepLabv3+を用い、カメラキャリブレーションによって点群と画素の正確な対応付けを実現した。ひび割れ検出においては DeepLabv3+を用いて Matterport 画像にも対応可能なひび割れ検出モデルを構築した。精度は最新モデルに劣るものの、距離のある画像にも対応可能な汎用性を有し、実用性が高い。特に床版やコンクリート桁では検出精度が高く、有効性が確認された。部材検出には DeepLabv3+を用いて9つのラベルを推定し、主要部材では一定の精度を達成した。精度向上には SAM の活用が有効な場合も多かったが、背景や鋼桁などでは効果が限定的であった。今後は対象部材に応じた適切な活用法の検討が必要である。ひび割れ長さの推定については多くのケースで誤差は 10 %以内に収まり、1.5 m 程度の距離から幅 0.15 mm のひび割れも検出可能であり、画像上で検出されたひび割れと点群を連携させ、スケール情報に基づいて距離を算出することで、ひび割れの長さを高精度に推定する手法を提示した。今後の課題としては、より精度の高い画像解析モデルや学習データの再構築、重複検出の排除、検出結果を点群に統合して一元管理する仕組みの導入が挙げられる。さらに、本手法はひび割れ以外の損傷評価への応用も可能であり、より汎用的な橋梁管理技術としての発展が期待される。




図-7 撮影箇所概要

参考文献

- 1) 国土交通省：老朽化の現状・老朽化対策の課題，
<https://www.mlit.go.jp/road/content/001574275.pdf>
(Retrieved on March 31, 2025)
- 2) 国土交通省：老朽化対策の本格実施について，
<https://www.mlit.go.jp/common/001027125.pdf>
(Retrieved on March 31, 2025)
- 3) Hattori, K., Oki, K., Sugita, A., Sugiyama, T., and Chun, P.J. : Deep learning-based corrosion inspection of long-span bridges with BIM integration, *Heliyon*, Vol.10, No.15, 2024.
- 4) Yamane, T., Chun, P.J., and Honda, R. : Detecting and localizing damage based on image recognition and structure from motion, and reflecting it in a 3D bridge model, *Structure and Infrastructure Engineering*, Vol.20, No.4, 594-606, 2024.
- 5) 杉本直也，：デジタルツインによる未来の「まち」づくり ～VIRTUAL SHIZUOKA 構想～，AI・データサイエンス論文集，4 巻 2 号，pp.97-101, 2023.
- 6) 東京都：東京都デジタルツイン実現プロジェクト，：
<https://info.tokyo-digitaltwin.metro.tokyo.lg.jp/>
(Retrieved on March 31, 2025)
- 7) Abe, M., Sugisaki, K., and Chun, P.J. : Artificial intelligence in infrastructure management, *Intelligence, Informatics and Infrastructure*, Vol.5, No.2, pp.95-105, 2024.
- 8) 日高菜緒：点群データ処理アルゴリズムの総括および土木分野での活用事例と展望，AI・データサイエンス論文集，4 巻 3 号，pp.301-109, 2023.
- 9) 中村健二，今井龍一，塚田義典，梅原喜政，田中成典：点群データを用いたプロダクトモデルの実装に関する研究ー Semantic Point Cloud Data ー，AI・データサイエンス論文集，3 巻 J2 号，pp.870-878, 2022.
- 10) 田中成典，今井龍一，中村健二，川野浩平：点群座標データを用いた 3 次元モデルの生成に関する研究，*知能と情報*，23 巻 4 号，pp.572-590, 2011.
- 11) 稲富翔伍，全邦釘：点群の画像化とディープラーニングを用いた橋梁点群のセグメンテーション，AI・データサイエンス論文集，2 巻 J2 号，pp.418-427, 2021.
- 12) 関和彦，山口愛加，窪田諭：3 次元点群データを用いた道路橋の損傷抽出とヒートマップ表示，*土木学会論文集*，Vol.79, No.10, pp.1-10, 2023.
- 13) 板倉健太，林拓哉，上脇優人，全邦釘：セマンティックセグメンテーションやセンサーフュージョンを利用した橋梁の構造情報の推定のための点群処理手法の開発，AI・データサイエンス論文集，5 巻 3 号，pp.10-21, 2024.
- 14) Bianchi,E., and Hebdon,M. : Development of Extendable Open-Source Structural Inspection Datasets, *Journal of Computing in Civil Engineering*, Vol.36, No.6, 2022.
- 15) Bianchi,E., and Hebdon,M. : Concrete Crack Conglomerate Dataset, University Libraries, Virginia Tech, 2021.
- 16) Bianchi,E., and Hebdon,M. : Labeled Cracks in the Wild (LCW) Dataset, University Libraries, Virginia Tech, 2021.
- 17) Lin, C., Abe, S., Zheng, S., Li, X., and Chun,P.J. : A structure - oriented loss function for automated semantic segmentation of bridge point clouds, *Computer - Aided Civil and Infrastructure Engineering*, V.40, No.6, pp.801-816, 2025.
- 18) Kirillov, A., Mintun, E., Ravi, N., Mao,H., Rolland,C., Gustafson, L., Xiao, T., Whitehead, S., Berg, A.C., Lo, W.Y., Dollár, P. , and Girshick, R. : Segment Anything arXiv:2304.02643v1, 2023.
- 19) Izumi, S., and Chun, P. J. : Low-cost training data creation for crack detection using an attention mechanism in deep learning models. *Intelligence , Informatics and Infrastructure*, Vol.5, No.1 , pp.124-134, 2024.
- 20) 板倉健太，林拓哉，上脇優人，全邦釘：LiDAR とカメラのセンサーフュージョンによる点群からのノイズ除去，AI・データサイエンス論文集，5 巻 3 号，pp.757-768, 2024.
- 21) 板倉健太，林拓哉，斎藤嘉人，全邦釘：センサーフュージョンを利用した 3 次元点群からの錆の検出，*Jxiv*, doi: <https://doi.org/10.51094/jxiv.1160>
- 22) Matterport.Inc., : Matterport Pro3 技術仕様 <https://support.matterport.com/s/article/Pro3-Technical-Specifications?language=ja> (Retrieved on March 31, 2025)
- 23) Chun, P. J., and Kikuta,T. : Self - training with Bayesian neural networks and spatial priors for unsupervised domain adaptation in crack segmentation, *Computer - Aided Civil and Infrastructure Engineering*, Vol.39, No.17, pp.2642-2661, 2025.
- 24) Deng, L., Yuan, H., Long, L., Chun, P.J., Chen, W., and Chu, H. : Cascade refinement extraction network with active boundary loss for segmentation of concrete cracks from high-resolution images. *Automation in Construction*, Vol. 162, 105410, 2024.