

橋梁の3次元点群を利用した構造情報の計算

板倉 健太¹・林 拓哉¹・Chao Lin²・上脇 優人¹・全 邦釘³

¹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

²非会員 東京大学大学院工学系研究科総合研究機構 (〒113-8485 東京都文京区本郷 7-3-1)

E-mail: chao-lin@g.ecc.u-tokyo.ac.jp

³正会員 東京大学大学院工学系研究科総合研究機構 (〒113-8485 東京都文京区本郷 7-3-1)

E-mail: chun@g.ecc.u-tokyo.ac.jp (Corresponding Author)

本研究では、Matterport Pro3 で計測された橋梁の点群データを使用し、橋梁の構造情報を自動的に計算する手法を検討した。欄干や床版、主桁の寸法を計算し、その精度を評価した。点群は事前にアノテーションされており、その情報も利用しながら処理を行った。欄干の長さは、点群を上から見た視点の2次元画像に投影し、画像処理技術で推定した。RMSEは0.28 mであり、5 cm程度の誤差が生じる可能性が示唆された。床版の長さや幅員は、主成分分析や楕円フィッティングを比較し、RMSEはそれぞれ0.10 mおよび0.50 mであった。さらに、主桁の交点検出も行ったが、データの欠損部分では交点の位置推定が難しかった。今後は、より高精度な推定を目指し、深層学習などを用いた点群の自動分類との組み合わせによる検証が望まれる。

Key Words: Automatic measurement, Bridge, Image processing, LiDAR, Point cloud processing

1. はじめに

近年、3次元点群データの利用が建築、土木、そして産業界全般において急速に拡大している¹⁾。3次元点群データは、BIM (Building Information Modeling) や CIM (Construction Information Modeling) などの3次元モデルの作成においても重要な役割を果たしている。特に、3次元点群データは、従来の2次元図面や写真測量のデータに比べ、空間情報をより詳細かつ高精度に取得できる点で優れている。3次元点群データの取得方法は多数存在する。SfM-MVS (Structure from Motion and Multi-View Stereo) は複数の画像に共通して写っている対象の対応関係をもとに、その対象の3次元点群を生成する技術である。UAV (Unmanned Aerial Vehicle) に搭載したカメラの画像だけでなく、地上にて画像を撮影し対象を3次元化することも可能である²⁾。近年では、スマートフォンで3次元点群を取得できるアプリケーションも登場しており、3次元計測を手軽に行うことができるようになった。さらに、NeRF (Neural Radiance Fields)³⁾ や 3D Gaussian Splatting⁴⁾ といった、従来の方法とは異なる手法も近年急速に発展している。これらは従来の3次元計測技術ではなく、新しい視点合成を目的としているが、高精度な3次元表現を2次

元画像から生成できることから、3次元計測にも寄与する可能性があると考えられる。しかし、地上計測では測距可能な範囲が比較的小さく、かつ高精度に距離を取得できないという課題がある。LiDAR (Light Detection and Ranging) は、レーザーを対象まで照射し、対象に反射して返ってくるまでの時間から対象の3次元構造を取得する技術である。LiDARは短時間で広範囲を高精度にカバーすることが可能であるため、建築物やインフラ構造物の寸法情報を効率的かつ正確に取得する手段として、活用が注目されている。

LiDARを用いた点群データの計測は、短時間で広範囲を高精度にカバーすることが可能である。しかし、ノイズの存在や解析対象以外の物体がデータに含まれるなどの問題が存在するため、取得された点群データをそのまま利用することは難しく、多くの場合、データの前処理が必要である。例えば、BIMの作成では、計測された点群をBIMに変換するのは多大な労力を伴うため、事前に点群を自動分類することで労力を削減することが試みられている⁵⁾。橋梁やトンネルなどのインフラ設備に対する点群データの解析では、構造物の寸法や形状を自動的に抽出し、モデル化する技術が求められる。

既往の研究として点群を画像化し、深層学習を用

いることで橋梁の点群をセグメンテーションする手法が挙げられる¹⁰⁾。その他にも、主成分分析などを利用した橋脚と床版の分類¹¹⁾やスーパーボクセルおよびグローバルグラフを利用した橋脚と床版の分類¹²⁾など、ルールベースによる分類も報告されている。さらに、近年発展している点群データに対する深層学習の研究は点群の自動処理の可能性を高めている。特に PointNet¹³⁾やそれを発展させた PointNet++¹⁴⁾、PointCNN¹⁵⁾、DGCNN (Dynamic Graph CNN)¹⁶⁾など、3次元点群データを直接処理する深層学習モデルが注目されている。PointNet は、点群データを個々の点の集合として扱い、全体的な幾何学的特徴を捉える。一方、PointCNNやDGCNNは、点群データの局所的な構造を考慮し、より精度の高い物体認識や分類を行うことができる。辻井らは、部材等の局所形状を特徴量として畳み込む深層学習手法を提案した¹⁾。また、点群データを直接的に処理する方法だけでなく、画像とのセンサーフュージョンにより、対象物の認識をした例も知られている^{17),18)}。これらの研究では、地上型レーザースキャナにより取得された点群に加え、その時にレーザースキャナに内蔵されたカメラで撮影された画像を組み合わせることで、点群のノイズ除去を行ったり、画像で認識した橋梁の情報を利用し、有効幅員や橋長などの情報を推定したりしている。画像をもとに橋梁の部材の認識を行うことで点群のみでは難しいような高度な解析も可能になることが報告されている。さらにセンサーフュージョンの際に、画像を用いて、より高度な分析を行うことで、点群のみを対象とした分析よりも詳細な解析ができる可能性がある。Stable Diffusionやドメイン適応を利用することで、コンクリート壁の画像のひび割れセグメンテーションを高精度に行うことができることを示した研究が知られている¹⁹⁾。メモリの観点などから扱うことの難しい高解像度の画像に対しても効率よくひび割れの検出を行う方法も提案されている^{20),21)}。また、Hattori ら (2024)²²⁾は橋梁点検車を用いて橋梁の桁下面の画像を撮影し、画像解析技術を活用することで、腐食箇所的位置や面積を自動計測する手法を開発した。このように画像を対象としたひび割れなどの損傷の部位の特定の方法も盛んに研究されており、センサーフュージョンと合わせることで、高精度な点群でのひび割れ検出が可能になる可能性がある。また、LiDARではなく、SfMを利用し損傷の3次元的位置を特定した研究も知られている²³⁾。この研究では、ディープラーニングを用いて各損傷を検出し、SfMを用いて局所的な位置情報を取得し、その位置情報を橋梁全体の3次元データに統合した。これらのように3次元点群を対象とした点群分類の手法は進歩しており、3次元空間内の物体を分類・認識する精度も日々発展している。これらの解析は、構造物の自動解析において重要な役割を果たす可能性がある。こ

のような先行研究やそれを利用した手法により、点群データから例えば、欄干、床版、主桁などの橋梁構造物の特定部材を認識できた場合、次のステップとして、それらの寸法や位置情報が自動的に抽出されることが望ましい。

そこで、本研究では、分類情報が付与された橋梁の点群データを対象に、欄干の長さ、床版の長さおよび幅員、床版から主桁までの距離などの橋梁構造物の基本的な寸法情報を自動的に計算する手法を検討する。LiDARで取得した橋梁の点群データに対して、手動で付与された分類情報を基に各構造部材を識別し、それぞれの寸法情報を自動的に抽出する。その後、抽出された寸法情報の精度を手動計測値と比較することで、点群解析技術の有効性を検証する。

2. 実験データと方法

(1) LiDAR を利用した橋梁の3次元計測

本研究で利用した実験データは2023年12月に福島県石川郡平田村にて取得された。3次元点群の計測には、Matterport Pro3 (Matterport, Inc., USA) を使用した (以下 Matterport とする)。Matterport の視野角 (Field of View) は水平方向に 360 度、垂直方向に 295 度である。レーザービームの波長は 904 nm であり、精度は 10 m 離れた点において ±20 mm である。毎秒最大 10 万点のスキャンを行うことができる。また、計測の開始や終了は Matterport のスマートフォン用のアプリケーションを利用して設定した。計測された点群は LAS 形式に変換され、本研究の解析に利用された。LAS の XYZ 座標を保存するときの Scale 値は 1 mm とした。また、ここで利用する点群はジオリファレンスされておらず、ローカル座標を有する。本研究で利用した橋梁の情報を以下の表-1 に示す。

(2) 点群データについて

a) アノテーション

本研究で使用するデータは、事前にクラスの情報を手動でラベリング (アノテーション) されたものを用いる。表-2 で示す分類情報を付与するために手動によるアノテ

表-1 本研究で利用した橋梁の情報

名称	橋長 (m)	幅員 (m)	橋梁形式
Bridge1	5	4.6	プレテン PC 桁橋
Bridge2	8	5	RC 床版橋
Bridge3	11	9.4	RC 床版橋
Bridge4	14	6.6	H 形鋼桁
Bridge5	15	8.2	T 桁橋

表-2 点群を手動分類した際のクラス番号とその名称

クラス番号	クラス名
0	橋台
1	主桁
2	床板
3	欄干
4	その他

ーションを 5 つの橋梁のデータに対して行った。3 次元点群の点ごとに分類の情報が付与される。分類のクラスごとに番号を付与する。この番号は、LAS ファイルの Classification フィールドに格納される。アノテーション済みのデータの一例を図-1 に示す。[a]は 3 次元点群を色表示した時の様子である。また、[b]は表-1 に従って分類情報を付与された点群を分類ごとに色分けして示している。

b) 推定する構造情報の真値の計測

対象とする橋梁構造の寸法情報の真値を取得するため、表-1 で示した点群データを用いて各構造要素の長さや構造間の距離を計測した。ただし Bridge4 には、欄干が含まれておらず、欄干に関する解析は Bridge4 では行われなかった。手動による計測には、主として PotreeDesktop を使用した。Potree は大規模な点群データを表示・操作するためのオープンソースの WebGL ベースのレンダラーである²⁴⁾。またローカル環境で利用可能な PotreeDesktop も存在する²⁵⁾。このソフトウェアを用いて、

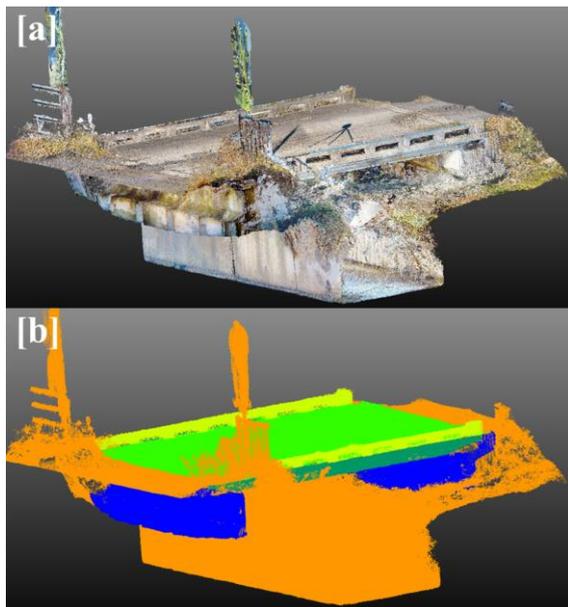


図-1 点群を手動分類した点群の例。[a]はオリジナルの点群、[b]は手動分類した結果であり、分類ごとに色分けされている。

欄干の長さや有効幅員、橋長などの計測対象の真値を手動で取得した。

床版と主桁の距離については、各橋梁データセット (Bridge1~Bridge5) において、ランダムに 3 地点を主桁上の選択し、手動で床版までの距離を計測した。5 つのサンプルに対して同様の操作を繰り返し、合計 15 点の計測結果を得た。図-2 は、PotreeDesktop を使用して手動で寸法情報を計測している様子である。図-2 [a]は欄干の長さ、図-2 [b]は有効幅員および橋長、図-2 [c]は主桁から床版までの距離を示している。これらの寸法情報の評価には、絶対誤差および複数サンプルに対する RMSE (Root Mean Squared Error)を用いた。

(3) 解析手法

a) 欄干の長さの算出

欄干の長さを算出するために、第一に、点群のセグメンテーションを行い、点群データを複数のクラスターに分割した。クラスターリングは、近い点同士を同じクラスターに割り当てる方法で行い、その際のクラスターリング間隔は 5 cm とした。その後、欄干に該当する最も多くの点数を有する 2 つのクラスターを選択した。次に、選択された各クラスターに対して、点群を上から見た視点の 2 次元の画像に変換した。2 次元画像への投影のために、XY 座標に関して 5 cm の間隔で点を区切り、点群から画像に変換する処理を行った。そして、5 cm の間隔で区切った領域に点が存在すれば、その領域が真となるように配列を作成した。この処理を各領域に対して繰り返すこと

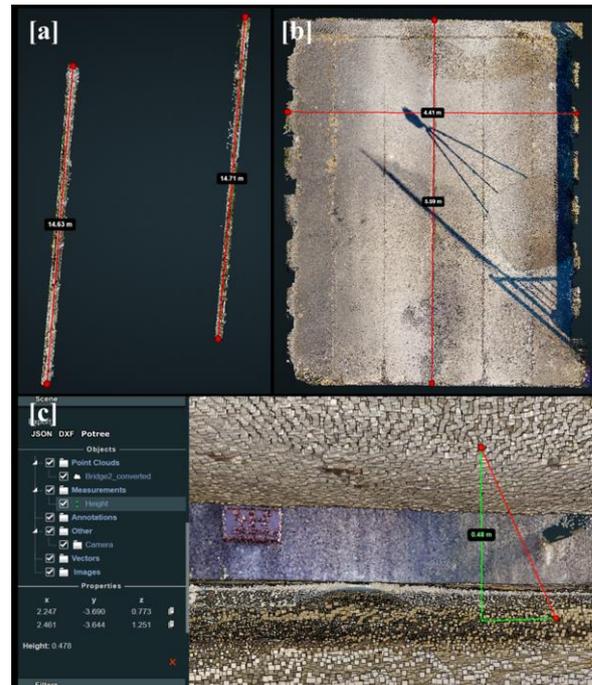


図-2 PotreeDesktop を使用して手動で推定する橋梁の寸法情報を計測している様子

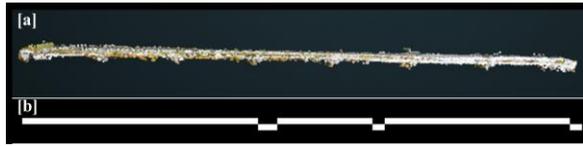


図-3 欄干の長さを推定するために、点群を上方から見た視点からの画像に投影した様子

で点群を上から見た視点の画像に変換することができる。続いて、生成した画像に対して Louisa らの方法²⁰⁾を用いて細線化処理を実施した。細線化とは、2値画像の白画素領域、すなわち対象物が存在する領域を幅1ピクセルにする処理である。これにより、画像中の構造物の形状が単純化され、より精度の高い距離測定が可能となる。図-3 [a]は点群を上方から見たときの様子を示しており、図-3 [b]はこの画像に対して細線化処理を行った結果を示している。その後、細線化された画像から最も距離が遠いピクセルのペアを検索し、このペアに対応する欄干の長さを算出した。最後に、これらのピクセルに対応する点群の XYZ 座標を取得し、実際の長さを計算した。この一連の手法により、欄干の正確な長さを測定することを試みた。

b) 欄干の長さの算出

有効幅員と橋長を計測するために、まず各ファイルから点群データを読み込み、「床版」を示すクラスに属する点のみを抽出した。図-4 [a]は、床版のみを抽出した点群データの様子を示している。次に、図-4 [b]のように点群データを上から見た視点に変換し、2通りの手法で有効幅員と橋長の計算を試みた。点群を画像に変換する方法は、2.3.1で述べたものと同様である。

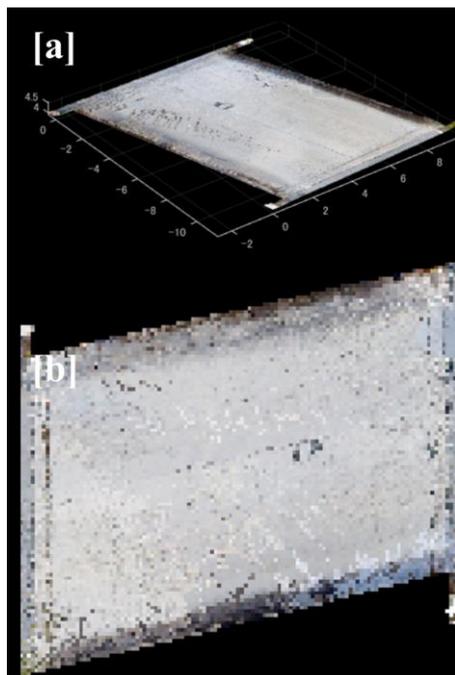


図-4 橋梁の点群から床版の点群を抽出した様子

1つ目の手法では、図-4 [b]の画像に対して楕円フィッティングを行った。フィッティングによって得られた楕円の長軸および短軸と、床版の領域との交点を求め、その交点間の距離を計算することで、有効幅員と橋長を算出した。具体的には、楕円の中心から長軸および短軸の方向に隣接するピクセルに向かって領域を拡大する処理を、領域が画像中の床版の領域外に達するまで行った。そして、領域外に達する直前の位置を交点とみなし、有効幅員や橋長の算出に利用した。

2つ目の手法として、欄干の向きを利用した方法を実施した。多くの場合、床版とともに欄干が計測されているため、欄干の向きを基に床版の長さを計算する方法を採用した。この手法では、探索する方向を欄干と平行な方向、およびそれに直交する方向とし、欄干の向きの特定には主成分分析 (Principal Component Analysis: PCA) を利用した。具体的には、欄干の XY 座標を入力として、第一主成分と第二主成分のベクトルを求め、これらのベクトルがそれぞれ欄干の向きと、それに直交する向きを表すものとして扱った。この2つの手法を用いることで、有効幅員と橋長の計測を行った。

主成分分析においては、欄干の各点の XY 座標を行ベクトル $p_i = [x_i, y_i]$ として定義し、これらの座標からなるデータ行列 X を次のように表す。

$$X = \begin{bmatrix} x_1 & y_1 \\ x_2 & y_2 \\ \vdots & \vdots \\ x_n & y_n \end{bmatrix} \quad (1)$$

次に、データ行列 X をセンタリングするために、各成分 x_i および y_i からそれぞれの平均 \bar{x} および \bar{y} を引く。このセンタリング処理を行った後のデータ行列 X_c は次のように表される。

$$X_c = \begin{bmatrix} x_1 - \bar{x} & y_1 - \bar{y} \\ x_2 - \bar{x} & y_2 - \bar{y} \\ \vdots & \vdots \\ x_n - \bar{x} & y_n - \bar{y} \end{bmatrix} \quad (2)$$

センタリングされたデータ行列 X_c から共分散行列 C を

計算する.

$$C = \frac{1}{n} X_c^T X_c \quad (3)$$

その後、 C の固有値と固有ベクトルを求めることで主成分が得られる. 具体的には、次の固有値問題を解くことでそれらの解が求まる.

$$C v_k = \lambda_k v_k \quad (4)$$

ここで、 λ_k は固有値、 v_k は対応する固有ベクトルである. 最も大きな固有値に対応する固有ベクトル v_1 が欄干の向きを示す第一主成分に相当し、次に大きな固有値に対応する固有ベクトル v_2 がこれに直交する方向を示す第二主成分となる. ここで得た主成分をもとに欄干の向きを特定し、その向きと図4[b]の投影画像を利用して、1つ目の手法と同様の手法で交点を求め、有効幅員や橋長を求めた.

c) 欄干間の長さの計測

欄干間の長さの計測のために、まず点群ファイルを読み込み、欄干に対応する分類情報を持つ点群のみを抽出した. 抽出した点群に対して、距離に基づいたセグメンテーションを実施し、各クラスタにラベルを付与した. クラスタリングの際には、5cmの距離をもとにクラスタを形成した. このクラスタリングの方法は、2.3.1と同様である. 図5のように欄干の候補のクラスタを2つ求めた. 各クラスタに対しては、まず点群から重心を計算し、続いてクラスタ間の距離を計算した. 最初のクラスタともう片方のクラスタとの間で距離を計算し、最も短い距離を求めた. この最短距離を欄干間の距離として検証を行った.

d) 主桁における床版からの距離の計測について

主桁における床版からの距離の計測において、まず床版に該当する点のみを抽出し、その点群に対して平面フィッティングを実行した. 図6にフィッティングの様子を示す. 床版から見た際の主桁との距離を正確に計算するために、RANSAC (Random Sample Consensus) ²⁾を利用した.

RANSAC では、初めに点群データからランダムにサンプル点を選び、そのサンプル点に基づいてモデルへのフィッティングを行う. ここでは、モデルとして3次元平面を仮定する. この仮定された平面モデルに対して、点群全体から一定の距離範囲内に収まる点 (インライア: inlier) を選定する. 本研究では、ランダムに生成された平面から 10 cm 以内の距離にある点をインライアと定義した. RANSAC の利点は、外れ値やノイズの影響を最小限に抑えつつ、データに最も適した平面モデルを効率的に見つけることができる点にある. このプロセス

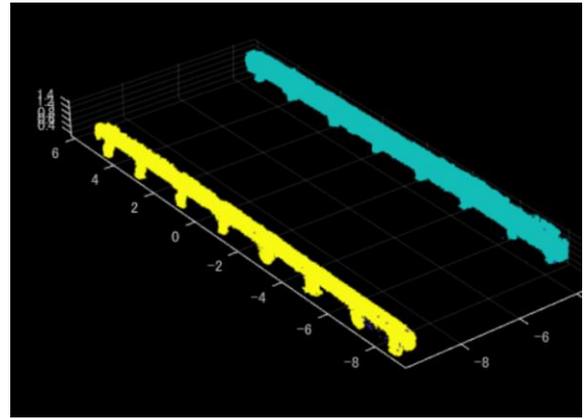


図5 欄干間の長さを求めるために欄干のクラスタを抽出した時の様子

を複数回繰り返し、インライアの数が増える平面を最適な平面として採用した.

次に、主桁に関する処理を行い、主桁に対応する点群を抽出した. この抽出された主桁の各点に対して、先ほど計算した床版の平面方程式を用いて、床版との距離を算出した.

RANSAC により求めた平面の方程式と点と平面の距離を計算する際に使用する計算式は以下のとおりである.

$$ax + by + cz + d = 0 \quad (5)$$

ここで、 a , b , c は平面の法線ベクトルの成分で d は平面が原点からどれだけ離れているかを示す定数である. 主桁の点 (x_0, y_0, z_0) と、平面 $ax + by + cz + d = 0$ の間の距離 D は次の式で計算できる.

$$D = \frac{|ax_0 + by_0 + cz_0 + d|}{\sqrt{a^2 + b^2 + c^2}} \quad (6)$$

算出した距離に基づいて、主桁の点群を床版の上, 中, 下に位置するものに分類し、下側の点群のみを取り出した. 対象の点が平面の上下どちらに位置するかについては、式(6)の値を利用して求めた.

計測した主桁の各点の床版からの距離を出力する際には、主桁に対応する点のみを結果として LAS 形式で保存した.

e) 主桁における床版からの距離の計測について主桁の交点の抽出

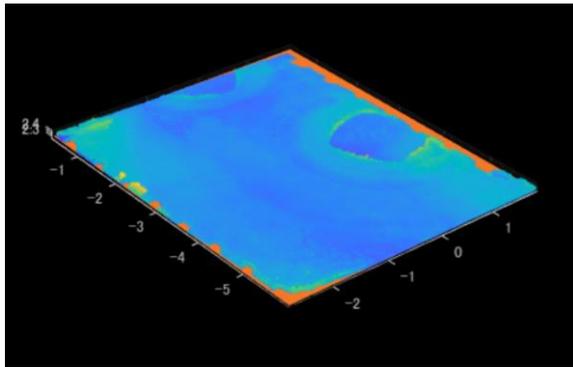


図-6 床板の点群に平面フィッティングを行い、床板を平面としてモデル化した様子。得られたモデルをオレンジ色で示している。

床版および主桁に対応する点群を読み込む。次に、RANSAC法を用いた平面フィッティングを行い、さらに床版の平面から0.5m以上、鉛直下向きに存在する主桁の点群を抽出する。この処理は2.3.d節で用いた手法と同様である。抽出された点群に対してはノイズ除去処理を施し、さらに詳細なデータクリーニングを実施する。ノイズ除去の際には、各点の近傍に存在する点の数およびノイズとして除去するか否かを判断するための閾値を設定する必要がある。近傍点の数は、ノイズ除去に利用する局所的な特徴を計算するために必要である。各点についてこの数だけ近傍点を探索し、その局所的な平均距離や密度を計算する。また、もう一つの閾値は、全ての点の両隣との平均距離の平均からの差異を示す。例えばこの値を1に設定した場合を説明する。対象の点とその

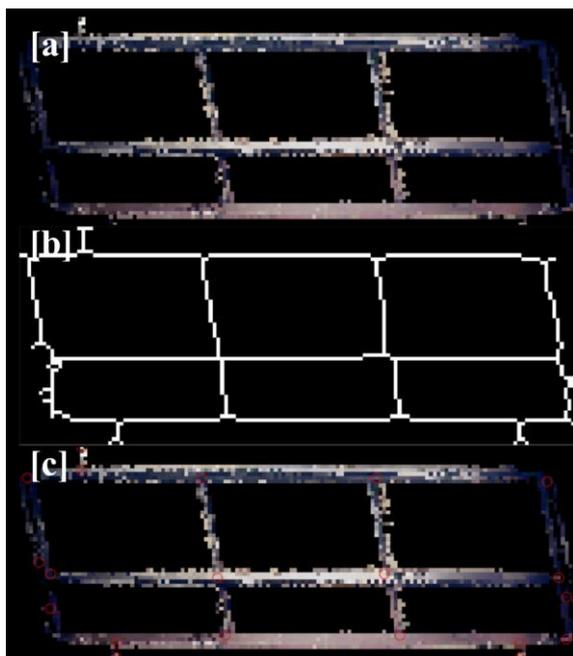


図-7 主桁の点群を投影し、画像化した時の様子 [a]。 [b] は細線化した時の結果を示す。

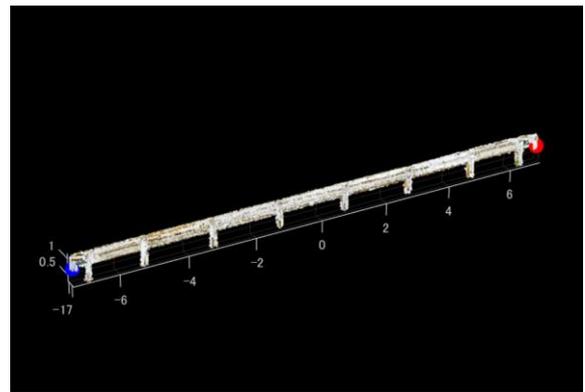


図-8 欄干の長さを計算するために自動的に選択された2点を可視化した時の様子。

表-3 欄干の長さを推定した結果。手で計測した長さを真値とし、本手法にて自動的に推定した値を推定値として示している。

名称	真値 [m]	推定値 [m]	絶対誤差 [m]
Bridge1_1	5.32	5.01	0.31
Bridge1_2	4.63	4.32	0.31
Bridge3_1	11.13	11.07	0.06
Bridge3_2	11.10	11.06	0.04
Bridge4_1	14.27	14.17	0.10
Bridge4_2	14.30	13.99	0.31
Bridge5_1	14.63	14.11	0.52
Bridge5_2	14.71	14.40	0.31

近傍点との平均距離を求めた際に、全点で計算した値の平均の1標準偏差を超える場合、その点を外れ値として扱う。近傍点の数を大きく設定すると、より多くの近傍点を考慮するため、平滑化された結果が得られるが、計算量が増加する。また、距離の閾値を0.5標準偏差などに小さく設定すると、正常点と認識される範囲が狭まり、ノイズ点が増える可能性がある。

ノイズ除去の後、上から見た視点の画像を生成し、図-7 [a]のような結果を得た。さらに画像処理技術を用いて分岐点の検出を行う。点群を画像に変換するために、2.3.aで述べた手法を利用した。また画像への変換を行ったのちに、細線化を行い、図-7 [b]のような結果を得た。細線化後に各ピクセルから伸びる点の数に基づいて分岐点を検出する。細線化処理を行うと、画像中の構造が幅1ピクセルの線として表現される。この状態では、各ピクセルからどの方向に線が伸びているかを解析することが可能である。具体的には、各ピクセルの8近傍（上下左右および斜め方向の8つの隣接ピクセル）を調べ、そ

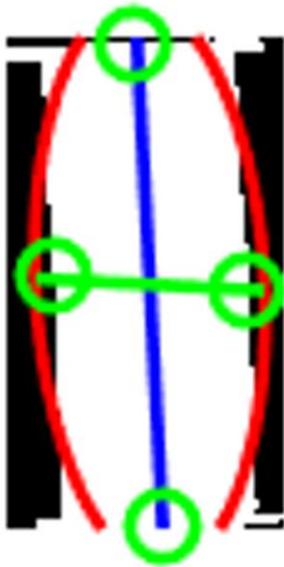


図9 点群を投影した画像に対して楕円フィッティングを行い、有効幅員や橋長を求めた様子

のピクセルに接続する線の本数をカウントする。もし、あるピクセルに接続する線が3本以上であれば、そのピクセルは分岐点であると判定される。つまり、分岐点では、3本以上の線が集まり、交差している構造を持つことが特徴である。この手法を用いることで、構造物の交差点や分岐点を自動的に検出することができる。

3. 結果と考察

(1) 欄干の長さの計測について

図8に橋梁の欄干の点群データから自動的に長さを計算した際の様子を示す。この解析では、赤および青の球が欄干の両端点を示しており、これらの点を基に欄干の全長が計算された。この端点の選定は、欄干の長さを正確に算出するための重要なステップであり、端点が適切な位置にあることで、欄干全体の長さが正確に反映されていることがわかる。手動により計測した値と本研究での点群解析により算出した結果をまとめた結果を表3に示す。今回の解析では、手動による計測結果と比較することで、点群データを用いた自動解析の精度を検証した。その結果、全体のRMSEは0.28mであった。解析の精度を向上させるためには、端点を求めるために画像化するときの1ピクセル当たりの距離を調整する必要がある。

具体的には、1ピクセル当たりの距離を小さくすることで、画像の解像度を高め、より正確な端点の位置の特定が可能になると考えられる。ただし、今回の誤差評価は、元の点群データから手動で計測した長さとの比較に基づいており、現地での実測値と比較した場合には、より精度の高い結果が得られる可能性がある。

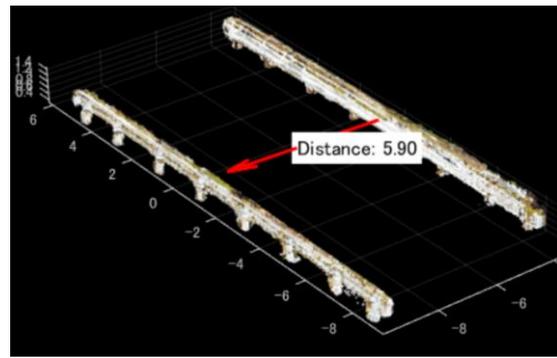


図-10 欄干間の距離を推定した様子

(2) 床版の長さおよび幅員の算出

手動により求めた真値と点群解析により算出した結果をまとめた結果を表4および表5に示す。楕円フィッティングを用いて床版の長さや幅員の方向を探索した場合（手法1とする）では、床版の長さにおけるRMSEは0.34m、幅員におけるRMSEは0.85mであった。一方、主成分分析を用いて同様の方向を探索した場合（手法2とする）では、床版の長さにおけるRMSEは0.10m、幅員におけるRMSEは0.50mであった。ただし、Bridge2に関しては欄干が存在しなかったため、手法2を利用することができなかった。

表4 橋長を推定した時の結果。手動で計測した長さを真値とし、本手法にて自動的に推定した値を推定値として示している。

名称	真値 [m]	手法1による推定値 [m]	手法2による推定値 [m]
Bridge1	5.59	5.55	5.53
Bridge2	9.75	9.76	計測不可
Bridge3	12.18	12.82	12.12
Bridge4	14.89	15.10	15.04
Bridge5	17.10	17.46	17.00

表5 有効幅員を推定した時の結果。手動で計測した長さを真値とし、本手法にて自動的に推定した値を推定値として示している。

名称	真値 [m]	手法1による推定値 [m]	手法2による推定値 [m]
Bridge1	4.41	4.43	4.42
Bridge2	3.78	3.62	計測不可
Bridge3	8.20	10.07	9.16
Bridge4	5.58	5.48	5.43
Bridge5	7.25	7.01	7.03

Bridge1, 2 および 4 では、高精度に床版の長さおよび幅員の算出が可能であった。Bridge2 の楕円フィッティング結果を図-9 に示す。点群を画像に投影した際に床版が長方形のような形状を示し、楕円フィッティングがうまく適用できていることがわかる。一方、Bridge3 および 5 では、点群を画像に投影した際に床版が平行四辺形のような形状になったが、楕円フィッティングが適切に行われたため、絶対誤差が 0.41 m 程度であったと考えられる。

また、今回は 3 次元データを直接扱うのではなく、2 次元の画像に投影してから処理を行った。このことは、計算の効率化や特定の解析を行いやすくすることにつながる。3 次元データでは、空間的な配置や関係を考慮する必要があるため、解析が複雑になることが多い。一方、2 次元の画像に投影することで、視覚的にも直感的に理解しやすいデータに変換され、解析が容易になることがある。たとえば、物体の輪郭抽出や特徴点検出などは、2 次元画像で行う方が直感的で、既存の画像処理手法が適用しやすくなる。また、2 次元画像処理の分野には、豊富なアルゴリズムとツールが存在する。3 次元点群を 2 次元画像に投影することで、これらの既存技術そのまま利用することができ、効率的な処理が可能となる。特に、機械学習やディープラーニングを用いた物体検出や分類においては、2 次元画像の方がトレーニングデータも豊富であり、モデルの構築における選択肢が多い傾向がある。さらに、全ての点を 3 次元空間で扱うよりも、2 次元の画像に投影してから処理することで計算量を大幅に削減できる。このように本手法では、3 次元的な処理のために、画像への投影を行うことで、有効幅員や橋長といった値を求めた。

本手法では、点群を 2 次元の平面に投影して画像化し、橋の有効幅員や橋長を算出した^{17,18)}。一方、先行研究では、画像と点群のセンサーフュージョンを用いて、画像から構造情報を取得するための重要な箇所を特定し、その座標を 3 次元点群上の座標に変換して寸法情報を求め

表-6 欄干間の距離を推定した時の結果。手動で計測した長さを真値とし、本手法にて自動的に推定した値を推定値として示している。

名称	真値 [m]	推定値 [m]	絶対誤差 [m]
Bridge1	4.41	4.25	0.16
Bridge2	3.78	計測不可	計測不可
Bridge3	8.20	8.52	0.32
Bridge4	5.58	5.90	0.32
Bridge5	7.25	7.55	0.30

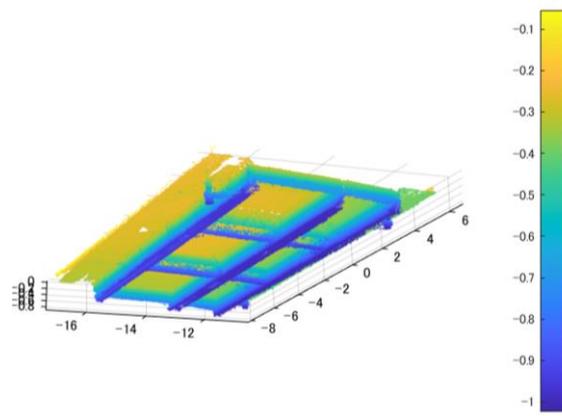


図-11 主桁における床版からの距離を計算した様子

ている。カメラが内蔵され位置が固定されている地上型レーザーสキャナのような場合、センサーフュージョンにより複数のセンサー情報を統合することで、高精度な推定が可能となる。また、点群のみでは判別が難しい情報も、他のセンサー情報を活用することで識別可能となる場合がある。ただし、SLAM (Simultaneous Localization and Mapping) のようなアルゴリズムを利用して移動しながら点群を計測し高密度な点群を生成する際には、画像との情報統合が難しくなることがあり、そのような場合には本手法のように、点群やその投影画像を用いた情報抽出が有効であると考えられる。

(3) 欄干間の距離の算出

手動による欄干間の距離の計測値と点群解析によって算出した結果をまとめた表-6 に示す。Bridge1~5 から計算した全体の RMSE は 0.283 m であり、手動での計測と比較しても高い精度が得られていることがわかる。Bridge2 で幅員を算出できなかった理由は、欄干が存在しなかったためである。そのため欄干が存在しない場合には、別の手法を検討する必要がある。

Bridge1 における欄干からもう片方の端までの距離を求めた際の様子を図-10 に示す。赤い矢印で示された距離が、点群データから自動的に算出された幅員であり、この計測によって幅員が 5.90 m であることが確認できる。このように、欄干が存在する場合には、点群解析により幅員を正確に算出することが可能である。

(4) 主桁における床版からの距離の計測について

主桁における床版からの距離の計測に関する解析結果を図-11 に示す。各点の色は床版からの距離を表しており、色の変化が距離の違いを反映している。具体的には、色が黄色に近いほど床版からの距離が小さく、青色に近いほど距離が大きいことを示している。この図は、主桁に沿って床版からの距離がどのように変化しているかを視覚的に示しており、主桁の構造的な健全性や変形の有

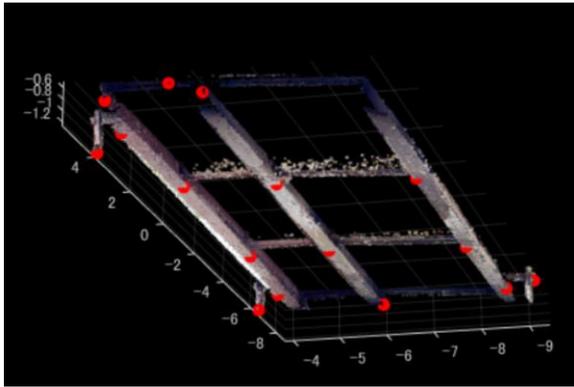


図-12 PotreeDesktop を使用して手動で推定する橋梁の寸法情報を計測している様子

無を評価する上で有用なデータとなりうる。本手法では RANSAC を用いて床版の平面フィッティングを実施し、最適な平面を特定した。この平面を基に、各主桁の点群に対して床版からの垂直距離を計算し、その結果を各点に格納した。RANSAC による平面検出では、インライアを決定する際の平面までの距離の閾値が重要な役割を果たす。閾値を大きく設定すると、床版のより多くの部分を検出することができるが、その結果、床版の厚みが過大評価される可能性がある。このような場合、床版が不当に厚くなるため、主桁までの距離が過小評価されるリスクが生じる。したがって、インライアを判断するためのパラメータ設定には慎重な調整が求められる。本手法による計測結果と手動による計測結果を比較したところ、RMSE は 0.010 m であり、高精度に床版からの距離を推定できることが確認された。

(5) 点群解析による主桁の交点の検出

図-5 はカメラキャリブレーションをしているときの様子を示す。チェッカーボード中のパターンが自動的に検出されていることがわかる。この画像以外に関しても、自動的にチェッカーボードの角を検出することができた。

図-12 に点群解析によって検出された主桁の交点の結果を示す。この解析では、主桁と床版の交差部分を自動的に検出し、赤いマーカーで示された位置が交点として認識されていることが確認できる。しかし、図の右上部分に見られるように、交点部分の点群が欠損している場合には、交点の正確な検出が難しくなるという課題が浮き彫りとなっている。点群が欠損している領域では、交点を正確に推定することが困難であり、結果として誤検出や未検出が発生する可能性がある。この問題を解決するための一つのアプローチとして、梁ごとにモデル化を行い、欠損した部分を補完することが考えられる。具体的には、既知の構造物の形状や寸法に基づいて、欠損した点群を補完し、交点の位置を推定することが可能である。先行研究では、LiDAR 点群を 2 次元画像に投影し、

投影された画像を基に樹木かそれ以外かを判定している。樹木と判定された場合には、その点群のみを抽出し、MMS (Mobile Mapping System) で取得された市街地の点群から街路樹を自動検出している²⁹⁾。本研究でも同様に 3 次元点群の XYZ 情報と投影画像の情報を組み合わせることが有効であることが示された。

また、機械学習やデータ補完技術を活用して、欠損した点群データを補完することで、交点の検出精度を向上させることも一つの方向性として検討できる。このように、欠損点群に対処するための技術を導入することで、より正確で信頼性の高い交点検出が実現できると考えられる。今後の研究では、このような欠損の影響を最小限に抑えるためのモデル化技術や補完技術の開発が重要となり、交点検出の精度向上につながることを期待される。主桁の交点検出において、今回の研究では投影した画像に対して細線化を行い、交点の検出を実施している。しかし、先行研究では、3 次元点群をボクセルに変換し、同様の方法で分岐点を検出するアプローチも存在する²⁹⁾。LiDAR 点群データから自動的に木の構造パラメータを推定するために、ボクセル化された点群に対して分岐点を検出する手法が提案されている。今回は投影した状態でも分岐点が把握できたが、より空間的に複雑な位置関係を有する場合は、このような 3 次元的な処理が必要となる。

4. まとめ

本研究では、点群データを利用した橋梁の構造情報の計算アルゴリズムの検討を行った。分類情報が付与された橋梁の点群に対して、欄干、床版、主桁の寸法情報や主桁の交点の求め方について検討を行った。

使用したデータは、事前にアノテーションされた 5 つの橋梁の点群ファイルであり、これらを基に構造情報の計算を行った。欄干の長さの算出には、点群を 2 次元の画像に投影し、画像処理技術を利用して長さの推定を行った。手動による計測結果と点群解析による結果を比較したところ、RMSE は 0.28 m となり、投影時の 1 ピクセル当たりの距離や真値の取り方により、5 cm 程度の誤差が生じる可能性が示された。床版の長さおよび幅員の算出に関しては、欄干の情報を利用した主成分分析と楕円フィッティングを用いたアプローチを比較した。欄干の点群や主成分分析を利用した場合、床版の長さの RMSE は 0.10 m、幅員の RMSE は 0.50 m であり、高精度な推定が可能であった。一方で、楕円フィッティングを用いる場合、投影時の形状に影響を受けることが課題として残った。欄干間の距離の算出においては、RMSE が 0.28 m となった。欄干間の距離を幅員と見なすことができる場合には、この情報を利用することが望ましいが、真値の

取り方によって結果が変動する可能性がある。主桁における床版からの距離の計測では、RANSAC法を用いた平面フィッティングと点と平面の距離の公式を活用することで、RMSEは0.01mと非常に高精度な結果が得られた。ただし、床版の平面がRANSACにより正確に検出されることが前提となる。主桁の交点の検出においては、点群解析を通じて交点の座標位置を計算したが、点群の欠損がある場合には交点の推定が難しくなることが判明した。特に、投影された画像から交点を検出する方法では、Z方向における交点の座標に誤差が生じやすいことが課題として残る。これらの結果を踏まえ、今後は現地で取った値を真値としてさらに解析を進め、より高精度な構造情報の推定を目指す必要がある。また、本研究では、手動にて分類済みの対象をもとに構造情報の計算を行った。深層学習モデルなどを利用して自動的に分類を行った場合には、誤分類も発生する。このような誤分類を含んだ状態であってもうまく計算を行うことができるかを今後の研究において検討することが望まれる。また、今後、多数のユーザが使えるようにすることを踏まえると例えば既往の研究で報告されたようなソフトウェア化³⁰⁾が望ましい。

謝辞：本稿は、JSPS 科研費 JP21H01417 の助成を受けた研究で行われた結果を含みます。また、内閣府総合科学技術・イノベーション会議の戦略的イノベーション創造プログラム (SIP) 第3期「スマートインフラマネジメントシステムの構築」JPJ012187 (研究推進法人:土木研究所) で実施されている研究も含みます。これらに謝意を表します。

参考文献

- 1) 辻井純平, 合田哲朗, 中野雅章: 土木構造物の点群解析に向けた局所形状の畳み込みを伴う深層学習手法の適用, AI・データサイエンス論文集, 4巻3号, pp. 442-450, 2023.
- 2) 米山睦美, 高見澤拓哉, 眞部達也, 田尻大介: 鉄筋結束マシンに取り付けたカメラ動画から生成した点群による配筋検査への実用性検証, AI・データサイエンス論文集, 5巻1号, pp. 239-244, 2024.
- 3) 藤原圭哉, 佐藤誠, 山下千智, 黒田直樹, 亀田敏弘: 3Dデータと河床変動解析を活用した河川分野におけるデジタルツインの実現に向けての提案, AI・データサイエンス論文集, 5巻1号, pp. 126-133, 2024.
- 4) 山下淳子, 木村沙智, 川村日成: 3次元点群データを活用したインフラ構造物の維持管理. 精密工学会誌, Vol. 85, No. 3, pp. 228-231, 2019.
- 5) Itakura, K., Hosoi, F.: Estimation of tree structure parameters from video frames with removal of blurred images using machine learning. *J. Agri. Meteorol.*, No. 74, Vol. 4, 154-161, 2018.
- 6) Kamiwaki, Y., Fukuda, S.: A machine learning-assisted

- three-dimensional image analysis for weight estimation of radish, *Horticult.*, Vol.10, No.2, 2024.
- 7) Mildenhall, B., Srinivasan, P. P., Tancik, M., Barron, J. T., Ramamoorthi, R., Ng, R.: Nerf: Representing scenes as neural radiance fields for view synthesis, *Commun. ACM*, Vol. 65, No. 1, pp. 99-106, 2021.
- 8) Kerbl, B., Kopanas, G., Leimkühler, T., Drettakis, G.: 3D Gaussian splatting for real-time radiance field rendering, *ACM Trans. Graph.*, Vol. 42, No. 4, pp. 139-1, 2023.
- 9) Romero-Jarén, R., Arranz, J. J.: Automatic segmentation and classification of BIM elements from point clouds, *Autom. Constr.*, Vol. 124, pp. 103576, 2021.
- 10) 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, Vol. 2, No. 2, pp. 418-427, 2021.
- 11) Lu, R., Brilakis, I., Middleton, C. R.: Detection of structural components in point clouds of existing RC bridges, *Comput.-Aided Civ. Infrastruct. Eng.*, Vol. 34, No. 3, pp. 191-212, 2019.
- 12) Pan, Y., Dong, Y., Wang, D., Chen, A., Ye, Z.: Three-dimensional reconstruction of structural surface model of heritage bridges using UAV-based photogrammetric point clouds, *Remote Sens.*, Vol. 11, No. 10, pp. 1204, 2019.
- 13) Qi, C. R., Su, H., Mo, K., Guibas, L. J.: PointNet: Deep learning on point sets for 3D classification and segmentation, *CVPR*, pp. 652-660, 2017.
- 14) Qi, C. R., Yi, L., Su, H., Guibas, L. J.: PointNet++: Deep hierarchical feature learning on point sets in a metric space, *NeurIPS*, Vol. 30, 2017.
- 15) Li, Y., Bu, R., Sun, M., Wu, W., Di, X., Chen, B.: PointCNN: Convolution on X-transformed points, *Adv. Neural Inf. Process. Syst.*, Vol. 31, 2018.
- 16) Phan, A. V., Le Nguyen, M., Nguyen, Y. L. H., Bui, L. T.: DGCNN: A convolutional neural network over large-scale labeled graphs, *Neural Networks*, Vol. 108, pp. 533-543, 2018.
- 17) 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, 土木学会 AI・データサイエンス論文集, 受理済み.
- 18) 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, 土木学会 AI・データサイエンス論文集, 受理済み.
- 19) Chun, P. J., Kikuta, T.: Self-training with Bayesian neural networks and spatial priors for unsupervised domain adaptation in crack segmentation, *Comput.-Aided Civ. Infrastruct. Eng.*, 2024.
- 20) Deng, L., Yuan, H., Long, L., Chun, P. J., Chen, W., Chu, H.: Cascade refinement extraction network with active boundary loss for segmentation of concrete cracks from high-resolution images, *Autom. Constr.*, Vol. 162, pp. 105410, 2024.
- 21) Chu, H., and Chun, P. J.: Fine-grained crack segmentation for high-resolution images via a multiscale cascaded network. *Comput. Aided Civ. Infra. Eng.*, Vol. 39, No.4, pp. 575-594, 2024.
- 22) Hattori, K., Oki, K., Sugita, A., Sugiyama, T., Chun, P. J.:

- Deep learning-based corrosion inspection of long-span bridges with BIM integration, *Heliyon*, 2024.
- 23) Yamane, T., Chun, P. J., Honda, R.: Detecting and localising damage based on image recognition and structure from motion, and reflecting it in a 3D bridge model, *Struct. Infrastruct. Eng.*, Vol. 20, No. 4, pp. 594-606, 2024.
 - 24) Schütz, M., Ohrhallinger, S., Wimmer, M.: Fast out-of-core octree generation for massive point clouds, *Comput. Graph. Forum*, Vol. 39, No. 7, pp. 155-167, 2020.
 - 25) github, potree Desktop:
<https://github.com/potree/PotreeDesktop>
 (最終アクセス日 2024年8月28日)
 - 26) Lam, L., Lee, S.-W., Suen, C. Y.: Thinning methodologies—a comprehensive survey, *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol. 14, No. 9, pp. 869-885, 1992.
 - 27) Fischler, M. A., Bolles, R. C.: Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography, *Commun. ACM*, Vol. 24, No. 6, pp. 381-395, 1981.
 - 28) Itakura, K., and Hosoi, F.: Three-dimensional tree monitoring in urban cities using automatic tree detection method with mobile LiDAR data, *AI Data Sci.*, Vol. 2, Issue 2, pp. 1-10, 2021.
 - 29) Itakura, K., Miyatani, S., and Hosoi, F.: Estimating tree structural parameters via automatic tree segmentation from LiDAR point cloud data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, Vol. 15, pp. 555-564, 2021.
 - 30) Chun, P. J., Chu, H., Shitara, K., Yamane, T., Maemura, Y.: Implementation of explanatory texts output for bridge damage in a bridge inspection web system, *Adv. Eng. Softw.*, Vol. 195, pp. 103706, 2024.

Calculation of structural information of bridges using 3D point clouds

Kenta ITAKURA, Takuya HAYASHI, Chao LIN, Yuto KAMIWAKI and Pang-jo CHUN

In this study, we examined a method to automatically calculate the structural information of bridges using point cloud data measured with the Matterport Pro3. We calculated the dimensions of railings, decks, and main girders and evaluated their accuracy. The point clouds were pre-annotated, and this information was utilized during processing. The length of the railings was estimated by projecting the point cloud onto a 2D image from a top-down view and using image processing techniques. The RMSE was 0.289 m, suggesting a possible error of about 5cm. The length and width of the deck were compared using principal component analysis and ellipse fitting, with RMSEs of 0.10 m and 0.50 m, respectively. Additionally, we attempted to detect the intersections of the main girders, but estimating the position of intersections was difficult in areas with missing data. Future work should aim for more accurate estimation by combining the method with automatic point cloud classification using deep learning.