

講演 3. 人工知能を活用した自動車検査業務における不正改造車の自動検知手法の提案

環境研究部

尾崎 信利

新国 哲也

1. はじめに

自動車検査業務は、依然として検査官の技量に依存している部分が多く、今後の労働人口の減少に対応するためにも、さらなる効率化が求められている。こうした背景から、交通安全環境研究所では検査業務のDX (Digital Transformation) 化に資する研究に取り組んでいる。その一環として本研究は、従来、検査官が目視で行っていた不正改造による車両形状の異常検知を、人工知能によって自動化することを目的とする。この異常検知には、車両の3次元形状データを用いるが、一般に自動車のような大型の物体の3次元形状を精度よく計測するには、長時間の計測¹⁾や大規模な計測装置等が必要である。また、既存の3次元形状の異常検知手法の多くは高精度で計測されたデータを前提としている²⁾。一方、自動車検査では効率求められるため、長時間の計測ができず、計測ノイズのない3次元形状の計測は困難である。そこで本報では、ノイズを含む3次元形状データから車両の形状異常を検知する手法を提案する。また、自動車検査場での車両の異常検知を模した計測実験によって、提案手法の有効性を検証した結果を報告する。

2. 車両の3次元形状の計測実験

2. 1. 実験車両と計測データ

計測実験に使用した車両を図1に示す。図1(a)のように何も改造を施していない車両を正常状態とし、図1(b)–(f)のように不正改造を模して車両の各部位にアクリル板を貼り付けた車両を異常状態とした。各状態の車両を次節の方法でそれぞれ図1に示す回数だけ繰り返し計測した。これにより、車両形状の計測データを正常状態で合計50件、異常状態で合計40件取得した。この正常状態の車両の計測データ50件から無作為抽出した数件(具体的な件数は後述)を学習データとし、残りの計測データを検証データとして、提案手法で異常を検知できるか検証した。



(a)正常状態 (50回計測)



(b)異常状態Ⅰ (5回計測)



(c)異常状態Ⅱ (5回計測)



(d)異常状態Ⅲ (10回計測)



(e)異常状態Ⅳ (10回計測)



(f)異常状態Ⅴ (10回計測)

図1 計測実験に用いた車両

2. 2. 車両形状の計測方法

計測実験の概要を図2に示す。検査場での計測を想定し、通路を10 km/h程度で自走する車両を、通路の両脇に2台ずつ設置した深度カメラによって連続撮影した。深度カメラにはIntel RealSense Depth Camera D435f (Intel Corporation 製)を使用した。これにより4つの深度カメラから走行車両のカラー画像と深度マップ(カメラからの撮影物までの距離データ)が動画形式で得られる。この動画形式の計測データを基に図3に示す方法によって車両の3次元形状を再構成した。なお、再構成に必要な深度カメラの

内部パラメータ及び路面に対する深度カメラの各位置は事前の校正実験で求め、車両の移動軌跡はカラー画像の特徴点追跡によって求めた²⁾。図3の下部に示す3次元点群は、1つの計測データに含まれる全ての深度マップを用いて、実際に再構成した結果の一例である。図3から車両の概形は確認できる一方で、結果に計測ノイズが多分に含まれており、車両の形状異常と計測ノイズを区別して判断することが難しいことがわかる。




図2 計測実験の様子




図3 3次元点群の再構成処理と再構成された3次元点群の例

3. 計測ノイズに対応した3次元形状の異常検知

前述のように検査場で計測ノイズの少ない車両の3次元形状を計測することは困難である。そこで本報では計測ノイズを考慮し、マハラノビス距離³⁾を用いた車両形状の異常検知手法を提案する。提案手法の概要を図4、5に示す。まず、検証データに含まれる(動画形式の)計測データの1つから、無作為抽出した L_f 枚の深度マップを基に、図3の方法によって車両形状の3次元点群データを取得する。本報では4つの深度カメラからそれぞれ $L_f = 30$ 枚ずつ、深度マップを無作為抽出した。さらに得られた3次元点群をサンプリングし、 L_p 点の点群データを得る。本報では、 $L_p = 32768$ とし、サンプリング手法にはPoisson disk Sampling⁴⁾を用いた。この点群データの生成を繰り返すことで、図4のように1つの計測データから車両の3次元点群データ $T_1, T_2, \dots, T_m$ を複数得る。また同様の処理を学習データに含まれるすべての計測データに対して行ない、複数の点群データ $N_1, N_2, \dots, N_n$ を得る。これらの点群データ $T_1, T_2, \dots, T_m$ と $N_1, N_2, \dots, N_n$ の形




図4 1つの計測データから複数の3次元点群データを再構成する方法




図5 計測ノイズを考慮した車両形状の異常検知手法

状を Point-MAE (Masked Autoencoders) 特徴量^{1), 5)}によって比較する。Point-MAE 特徴量は図 6 のように 3 次元点群に L_e 個の評価点 $\mathbf{p}_j$ を配置し、各評価点 $\mathbf{p}_j$ の周辺の局所的な形状をそれぞれ特徴ベクトルに変換する手法である。本報では評価点 $\mathbf{p}_j$ は点群密度が十分高い領域から Farthest Point Sampling⁶⁾によって選出し、また $L_e = 1024$ とした。Point-MAE 特徴量により、検証データの点群 $T_1, T_2, \dots, T_m$ からそれぞれ得られた特徴ベクトルを $\mathbf{v}_{1j}, \mathbf{v}_{2j}, \dots, \mathbf{v}_{nj}$ とし、学習データの点群 $N_1, N_2, \dots, N_n$ から得られた特徴ベクトルを $\mathbf{v}'_{1j}, \mathbf{v}'_{2j}, \dots, \mathbf{v}'_{nj}$ とする。検証データのある点群 T_i における、ある特徴ベクトル $\mathbf{v}_{ij}$ が特徴ベクトル $\mathbf{v}'_{1j}, \mathbf{v}'_{2j}, \dots, \mathbf{v}'_{nj}$ といずれも近い値であれば評価点 $\mathbf{p}_j$ 周辺の形状が似ていることを意味する。ただし、特徴ベクトルには計測ノイズが含まれている可能性がある。このため次式で計算される、特徴ベクトル $\mathbf{v}'_{1j}, \mathbf{v}'_{2j}, \dots, \mathbf{v}'_{nj}$ の多変量正規分布における $\mathbf{v}_{ij}$ のマハラノビス距離を、特徴ベクトルどうしの異常度として評価する。

$$s_{ij} = \sqrt{(\mathbf{v}_{ij} - \boldsymbol{\mu}'_j)^T \boldsymbol{\Sigma}'_j^{-1} (\mathbf{v}_{ij} - \boldsymbol{\mu}'_j)} \quad (1)$$

ただし、 $\boldsymbol{\mu}'_j, \boldsymbol{\Sigma}'_j$ は $\mathbf{v}'_{1j}, \mathbf{v}'_{2j}, \dots, \mathbf{v}'_{nj}$ の平均ベクトル、共分散行列である。式(1)で計算される s_{ij} が大きいほど点群データ T_i の評価点 $\mathbf{p}_j$ 付近の点群形状が正常状態の車両の形状に似ていない、すなわち形状が異常であることを意味する。以上の処理を各評価点 $\mathbf{p}_j$ 及び点群データ $T_1, T_2, \dots, T_m$ で繰り返し、次式で平均をとった値を評価点 $\mathbf{p}_j$ における検証データの車両形状の異常度 $\bar{s}_j$ として評価する。

$$\bar{s}_j = \frac{1}{m} \sum_{i=1}^m s_{ij} \quad (2)$$

また各検証データに異常箇所が存在するかは、次式で計算される最大異常度 $s_{\max}$ によって評価する。

$$s_{\max} = \max_{1 \leq j \leq L_e} (\bar{s}_j) \quad (3)$$

4. 提案した異常検知手法の検証結果

まず提案手法が車両形状の異常の有無を正しく判別できるかについて検証した。実験で得た正常状態の車両の計測データから 10 件を無作為抽出して学習データとし、提案手法で残りの計測データをそれぞれ解析して得た最大異常度 $s_{\max}$ のヒストグラムを図 6 に示す。なお、1 つあたりの計測データから生成する点

群データの数は $m = 30$ とした。また学習データとしては $n = m \times 10$ 個の点群データを生成した。図 6 より、異常度の分布が正常状態と異常状態 I ~ V ではっきりと分かれており、図 6 において異常度の閾値を 35 とすると 100% の精度で車両の形状異常の有無を判定できることがわかる。ここで、異常検知の結果を評価する指標として、ROC-AUC を導入する。ROC-AUC は異常度のヒストグラムが正常データ（正常状態の車両）と異常データ（異常状態 I ~ V の車両）でどれだけ分離しているかを示す指標であり、完全に分離していない場合は 0.5、図 6 のように完全に分離している場合は 1.0 を示す。この ROC-AUC を用いて、学習データの件数を 3、5、10 件としたとき、提案手法の形状異常の判別精度がどのように変化するかを検証した。各件数において、学習データの無作為抽出と、それに基づく異常検知を 10 回繰り返し、得られた ROC-AUC を図 7 に示す。図 7 より学習データが多くなるほど、ROC-AUC の結果が高い方に収束す




図 6 車両形状の異常の有無を最大異常度 $s_{\max}$ で判別した結果 (学習データ: 10 件)




図 7 学習データの件数と提案手法の異常の判別精度




図 8 ROC-AUC が 0.963 を示すときの最大異常度 $s_{\max}$ のヒストグラム (学習データ: 5 件)

ることが確かめられ、学習データを5件としたときのROC-AUCは最低でも0.96を越えていることがわかる。ROC-AUCの目安として、学習データを5件とし、その解析結果のROC-AUCが0.963であったときのヒストグラムを図8に示す。図8において閾値を45とすれば異常状態I～Vの車両の検出率は100%、正常状態の車両を異常と判定する誤検出率は8.9%となる。以上から、提案手法は学習データが5件あれば実用的な精度で車両形状の異常の有無を判定できると考える。

次に、解析で得られた各評価点 p_j の異常度 s_j を図9に例として示す。図9(a)では異常状態の場合はアクリル板を貼り付けた箇所だけが高くなっており、異常箇所を特定できていることがわかる。一方で図9(b)では異常度 s_j が異常箇所で高くなっているものの、本来、異常でない車両上部でも高くなっていることがわかる。図9(c)には、図9(b)の計測データから図4の方法で再構成した3次元点群の例を示している。図9(c)から車両上面の点群密度が低くなっていることがわかる。このことから、車両上部では点群の分布を詳細に求められなかったことが、図9(b)で誤検出が生じた原因であると考えられる。なお、車両上面の点群密度が低くなった主な理由としては、日中に屋外で計測したため太陽光の影響を受けたことが考えられる。今後は屋内で形状計測を実施する、車両の真上から形状計測ができるよう深度カメラを追加するなどの計測方法の改良により、異常検知精度のさらなる向上を目指す。




図9 車両形状の異常箇所検出結果

5. おわりに

本報では計測ノイズに対応した車両の3次元形状の異常検知手法を提案し、その有効性を実験によって検証した。実験では、通路を自走する車両を、通路の両脇にそれぞれ2台設置した深度カメラで3次元計測し、その計測データを基に提案手法が車両形状の異常を検知できるかを評価した。検証結果として、車両の計測データが数件あれば、車両形状の異常の有無を実用的な精度で判別できることが確認された。一方で、形状の異常箇所の検出については、点群密度が低い場所において形状異常を誤検出する場合もあることがわかった。今後は車両形状の計測方法を改良することにより、異常検知の精度向上を目指す。また実用化に向けて、形状の異常箇所のより詳細な精度検証や様々な車両における提案手法の検証を実施する。

参考文献

- 1) J., Liu, G., Xie, R., Chen, X., Li, J., Wang, Y., Liu, C., Wang and F., Zheng, "Real3d-ad: A dataset of point cloud anomaly detection", Proceedings of the 37th International Conference on Neural Information Processing Systems, pp. 30402–30415, 2023.
- 2) D. Nister, "An efficient solution to the five-point relative pose problem", IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 26, no. 6, pp. 756–770, 2004.
- 3) T., Defard, A., Setkov, A., Loesch and R., Audigier, "Padim: a patch distribution modeling framework for anomaly detection and localization", International Conference on Pattern Recognition, pp. 475–489, 2021.
- 4) R. L. Cook, "Stochastic sampling in computer graphics", ACM Transactions on Graphics (TOG), vol. 5, pp. 51–72, 1986.
- 5) Y., Pang, W., Wang, F., E.H., Tay, W., Liu, Y., Tian, L., Yuan, "Masked autoencoders for point cloud self-supervised learning", European Conference on Computer Vision, pp.604–621, 2022.
- 6) T. F. Gonzalez, "Clustering to minimize the maximum intercluster distance", Theoretical Computer Science, Vol. 38, pp. 293–306, 1985.