

自動車検査における不正改造の自動検知手法 第 1 報
-計測ノイズに対応した 3 次元形状の異常検知-

Research for Automatic Detection of Illegal Modifications in Vehicle Inspection (Part 1) :
Anomaly detection of 3D shapes immune from measurement noise

尾崎 信利[†] 新国 哲也[†]
Nobutoshi Ozaki Tetsuya Niikuni

1. はじめに

近年、自動車検査業務における保安基準が複雑化し検査官への負担が大きくなっている。一方で、自動車検査業務は Digital Transformation 化がほとんど進んでおらず、課題となっている。本研究は、検査業務の Digital Transformation 化を促進するため、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査を AI (Artificial Intelligence) によって自動化することを目指す。異常検知には、車両の 3 次元計測データを用いるが、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、長い計測時間[1]や大規模な計測装置・照明環境等が必要である。このため、効率が求められる検査では計測ノイズのない 3 次元計測が困難である。一方で、既存の 3 次元形状の異常検知技術は十分な時間をかけて精度よく計測されたデータを対象としている場合がほとんどである[1]。そこで、本報では計測ノイズに対応した 3 次元形状の異常検知手法を提案する。本報は第 1 報として、3 次元計測の計測ノイズが正規分布に従うと仮定することで、計測データの異常度をマハラノビス距離[2]で評価した。また、提案手法の有効性を検査場での車両の異常検査を模した計測実験によって検証した。これらの結果を報告する。

2. 車両の 3 次元形状の計測実験

本報ではまず車両の 3 次元形状の計測実験を実施した。車両形状の計測実験の概要を図 1 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の形状を、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。計測実験では走行車両のカラー画像と深度マップが動画データとして得られる。この動画データの各フレームの深度マップを合成することで車両の 3 次元形状を再構成した。なお、深度カメラの内部パラメータ及び 4 台のカメラどうしの位置関係は事前の校正実験で求め、各フレーム撮影時の車両の移動量はカラー画像の特徴点追跡によって求めた[3]。

図 2 に形状計測に使用した車両を示す。図 2-(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 2-(b)のように不正改造を模して車両下部にアクリル板を貼り付けた車両形状を異常状態とした。図 1 の計測を繰り返し、正常状態の車両を 20 回、異常状態の車両を 10 回計測した。本報では正常状態の車両の計測データから 20 件のうち 10 件を抽出して学習データとし、残りの正常状態の車両データ 10 件、異常状態の車両データ 10 件を検証データとして、提案手法で正しく判定できるかを検証する。

[†] 独立行政法人自動車技術総合機構 交通安全環境研究所
National Agency for Automobile and Land Transport Technology,
National Traffic Safety and Environment Laboratory




図 1 車両計測実験の概要



(a) 正常状態の車両 (b) 異常状態の車両
図 2 3 次元形状を計測した車両の概要

3. 計測ノイズに対応した 3 次元点群の異常検知

既存の 3 次元点群の異常検知手法は 3 次元点群に計測ノイズがほとんど含まれていないデータを対象としているが、これは計測に多大な時間を要する[1]。そこで本報では、深度マップに計測ノイズが含まれていることを前提に、図 3 に示すように 1 つの深度マップの動画からフレームを無作為抽出して、複数の 3 次元点群データを再構成する。再構成後には、さらに各点群データで点の無作為抽出をおこない、各点群データの点数を L 個にまで減少させる。本報では $L = 65536$ とした。この処理をすべての学習データでおこない、正常状態の車両の点群データ N_1, N_2, \dots, N_n を複数取得する。取得した点群データは Iterative closest point [4]により互いに位置合わせする。

検証データでも同様に 1 つの動画から複数の点群データ T_1, T_2, \dots, T_m を取得し、そのうちの 1 つを点群データ T_i とする (図 4)。まず点群データ T_i 中の L 個の点から L_p 個を無作為抽出し、これを評価点 p_j とする。本報では $L_p = 2048$ とした。次に検証点群データ T_i における評価点 p_j の周辺の点群形状を Point MAE (Masked Autoencoders) [1, 5] によって特徴ベクトル v_{ij} に変換する。正常車両の点群データ N_1, N_2, \dots, N_n でも、評価点 p_j と同じ座標周辺の点群形状をそれぞれ特徴ベクトルに変換し $v'_{1j}, v'_{2j}, \dots, v'_{nj}$ とする。特徴ベクトル v_{ij} と $v'_{1j}, v'_{2j}, \dots, v'_{nj}$ がいずれも近い値であれば評価点 p_j 周辺の点群形状が似ていることを意味するが、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。

従って特徴ベクトルの類似度は次式のように特徴ベクトル $\mathbf{v}'_{1j}, \mathbf{v}'_{2j}, \dots, \mathbf{v}'_{nj}$ 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。また式(1)の計算には Padim と同様に、特徴ベクトルから 550 次元を無作為抽出したものをを用いた[2]。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ものを検証データの評価点 \mathbf{p}_j における異常スコア \bar{s}_j として評価する。

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




図 3 深度マップから複数の 3 次元点群を再構成する方法




図 4 検証データの各評価点 \mathbf{p}_j の評価方法

4. 車両形状の計測結果と提案した異常検知手法の検証結果

図 5 に深度マップの動画の全フレームを用いて、車両形状を再構成した結果を一例として示す。ただし、図 5 は描画用にダウンサンプリングしたものである。図 5 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、全フレームを用いた点群では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。2 章の方法で得た学習データに基づき、提案手法によ

って検証データを解析した結果を図 6 に示す。なお、図 5 に示すように計測では路面の 3 次元点群も得られたが、解析時には平面検出によって路面は除去した。図 6 のカラーマップより、アクリル板を貼り付けた部分の異常スコアが高くなっており、車両形状の異常部分を正しく検知できていることがわかる。同様にして、全ての検証データの異常スコアを算出し、各データで算出された異常スコアの最大値をヒストグラムで図 7 に示す。図 7 より正常状態と異常状態の車両で、異常スコアの分布がはっきりと分かれていることが見て取れ、提案手法の有効性が確かめられた。




図 5 撮影した深度マップの動画の全フレームを用いてそれぞれ車両形状を再構成した結果




図 6 提案手法による車両形状の異常スコア計算結果




図 7 検証データにおける各データの最大異常スコアのヒストグラム

5. おわりに

本報では計測ノイズに対応した 3 次元点群データの異常検知手法を提案し、検証実験によって車両形状の異常検知に関する有効性を示した。今後は既存技術との比較、考察を行い、本手法の理論的側面について考察を深めるとともに、実用化に向け、さらに実験を含めた検証を行う。

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] 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.
- [3] 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.
- [4] S. Rusinkiewicz and M. Levoy, "Efficient variants of the ICP algorithm", Proceedings Third International Conference on 3-D Digital Imaging and Modeling, pp. 145–152, 2001.
- [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.