

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

尾崎信利 新国哲也
環境研究部

講演内容

1. 研究背景・課題
2. 車両形状の異常検知手法の提案
3. 検証実験
4. 検証結果
5. まとめ

講演内容

1. 研究背景・課題

2. 車両形状の異常検知手法の提案

3. 検証実験

4. 検証結果

5. まとめ

ユーザー車検



検査官による車両の外観検査



- 自動車検査業務は、検査官の技量に依存している部分が残っている
- 労働人口の減少もあり、検査官の人手不足が顕著化しつつある

ユーザー車検



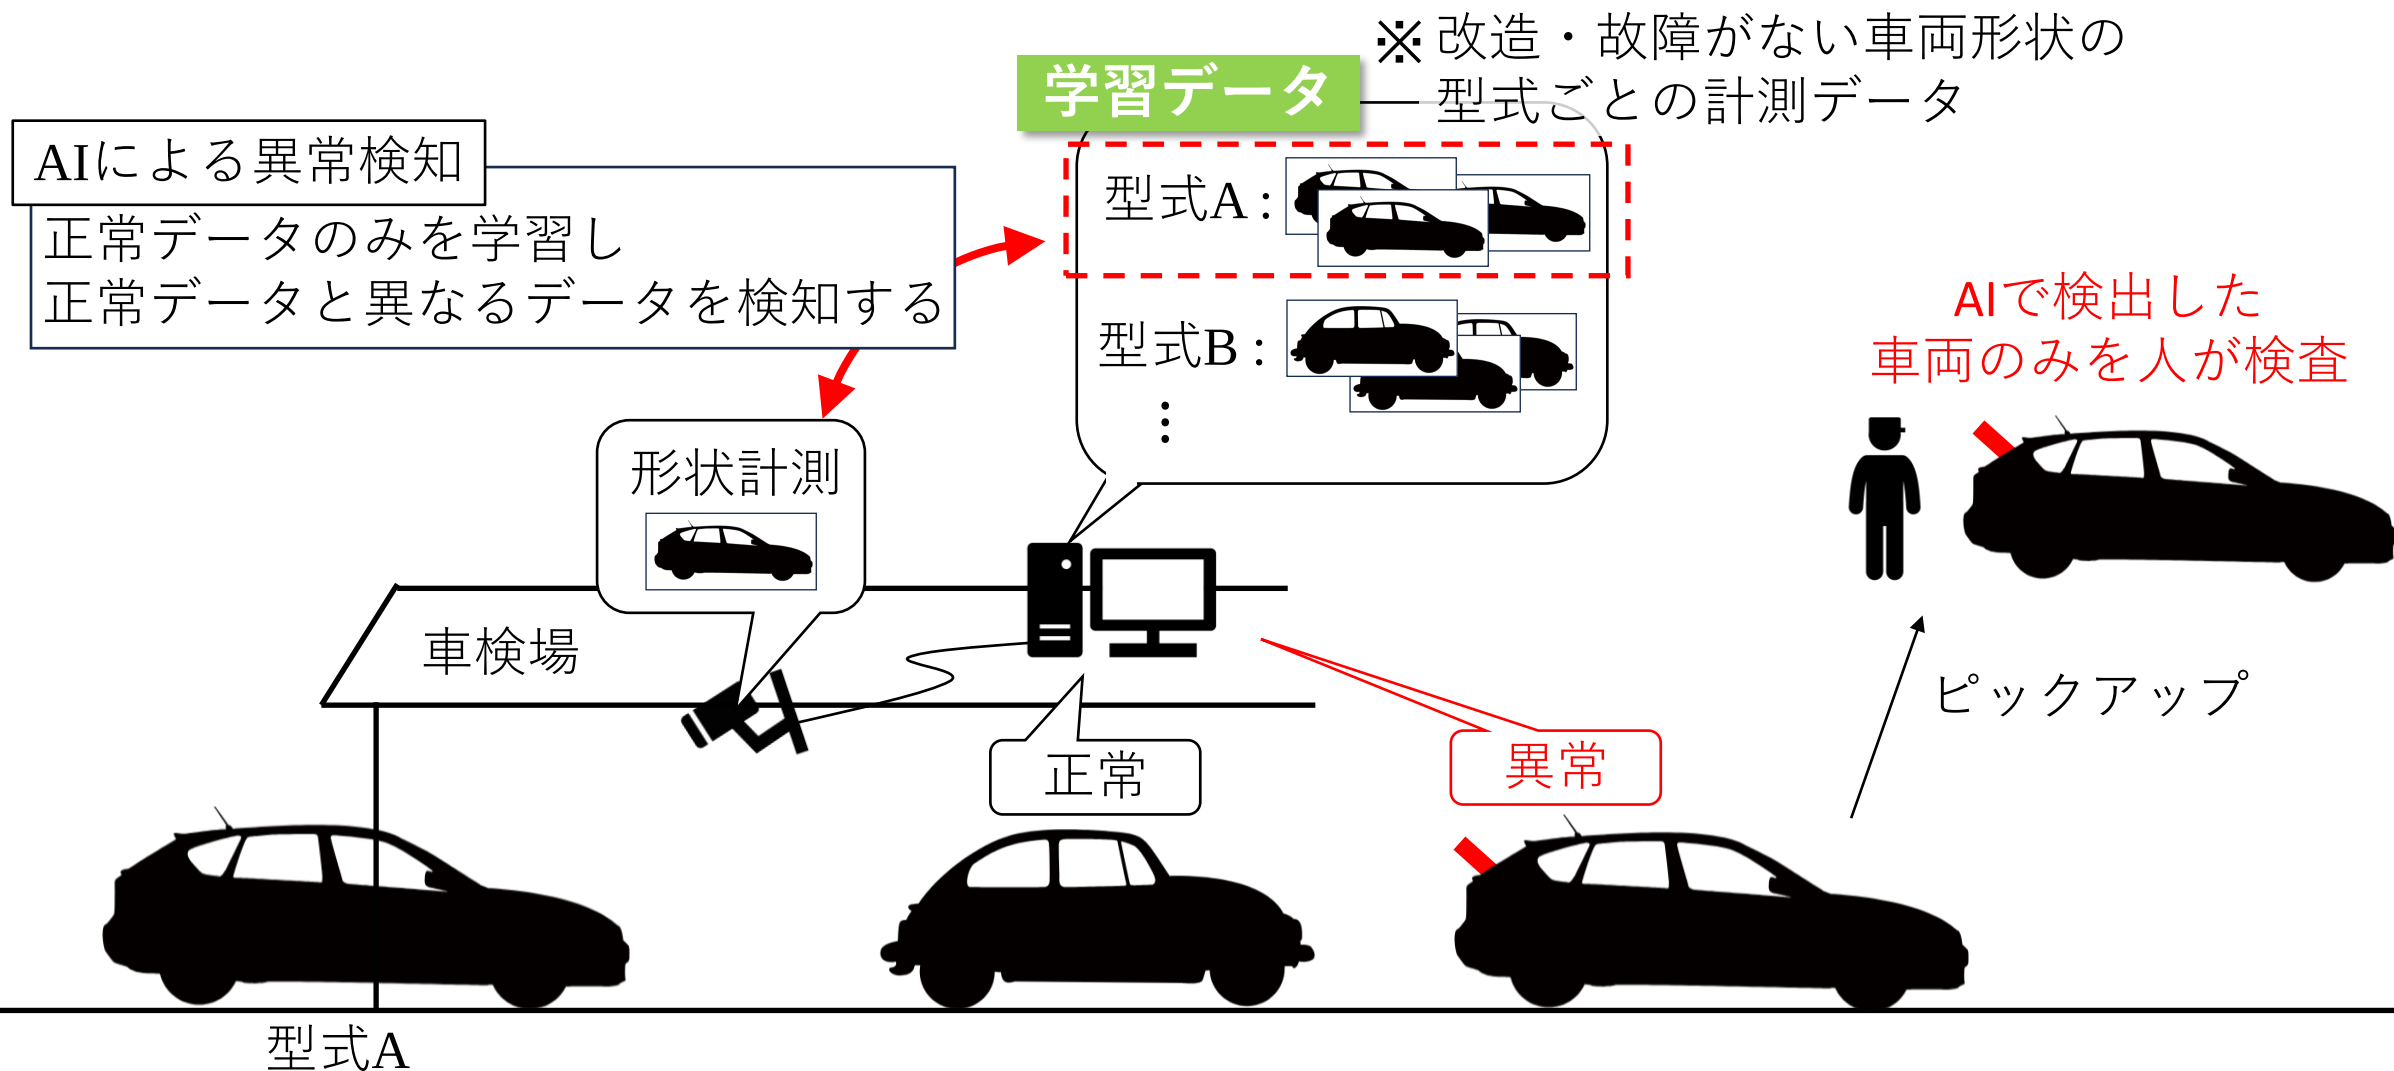
検査官による車両の外観検査




- 従来、検査官が目視で行なっていた不正改造による車両形状の異常検知をAI技術によって自動化することを目的とする
- 本報では車両形状の異常検知に注目する



人工知能を活用した外観検査



研究課題



画像情報のみではボディカラーや背景の差異と車両の形状異常を見分けることが困難

車両形状の異常検知には3次元の計測データを用いる

一般に大型の物体をノイズ無く3次元計測するには長い計測時間や大規模な計測装置が必要

既存の異常検知手法はノイズを前提としていない

**効率が求められる検査場でも利用可能な
ノイズを含んだ3次元の計測データから
車両の形状異常を検知できる方法を提案する**




講演内容

1. 研究背景・課題
- 2. 車両形状の異常検知手法の提案**
3. 検証実験
4. 検証結果
5. まとめ

提案手法 —車両形状の計測方法—

深度カメラ:

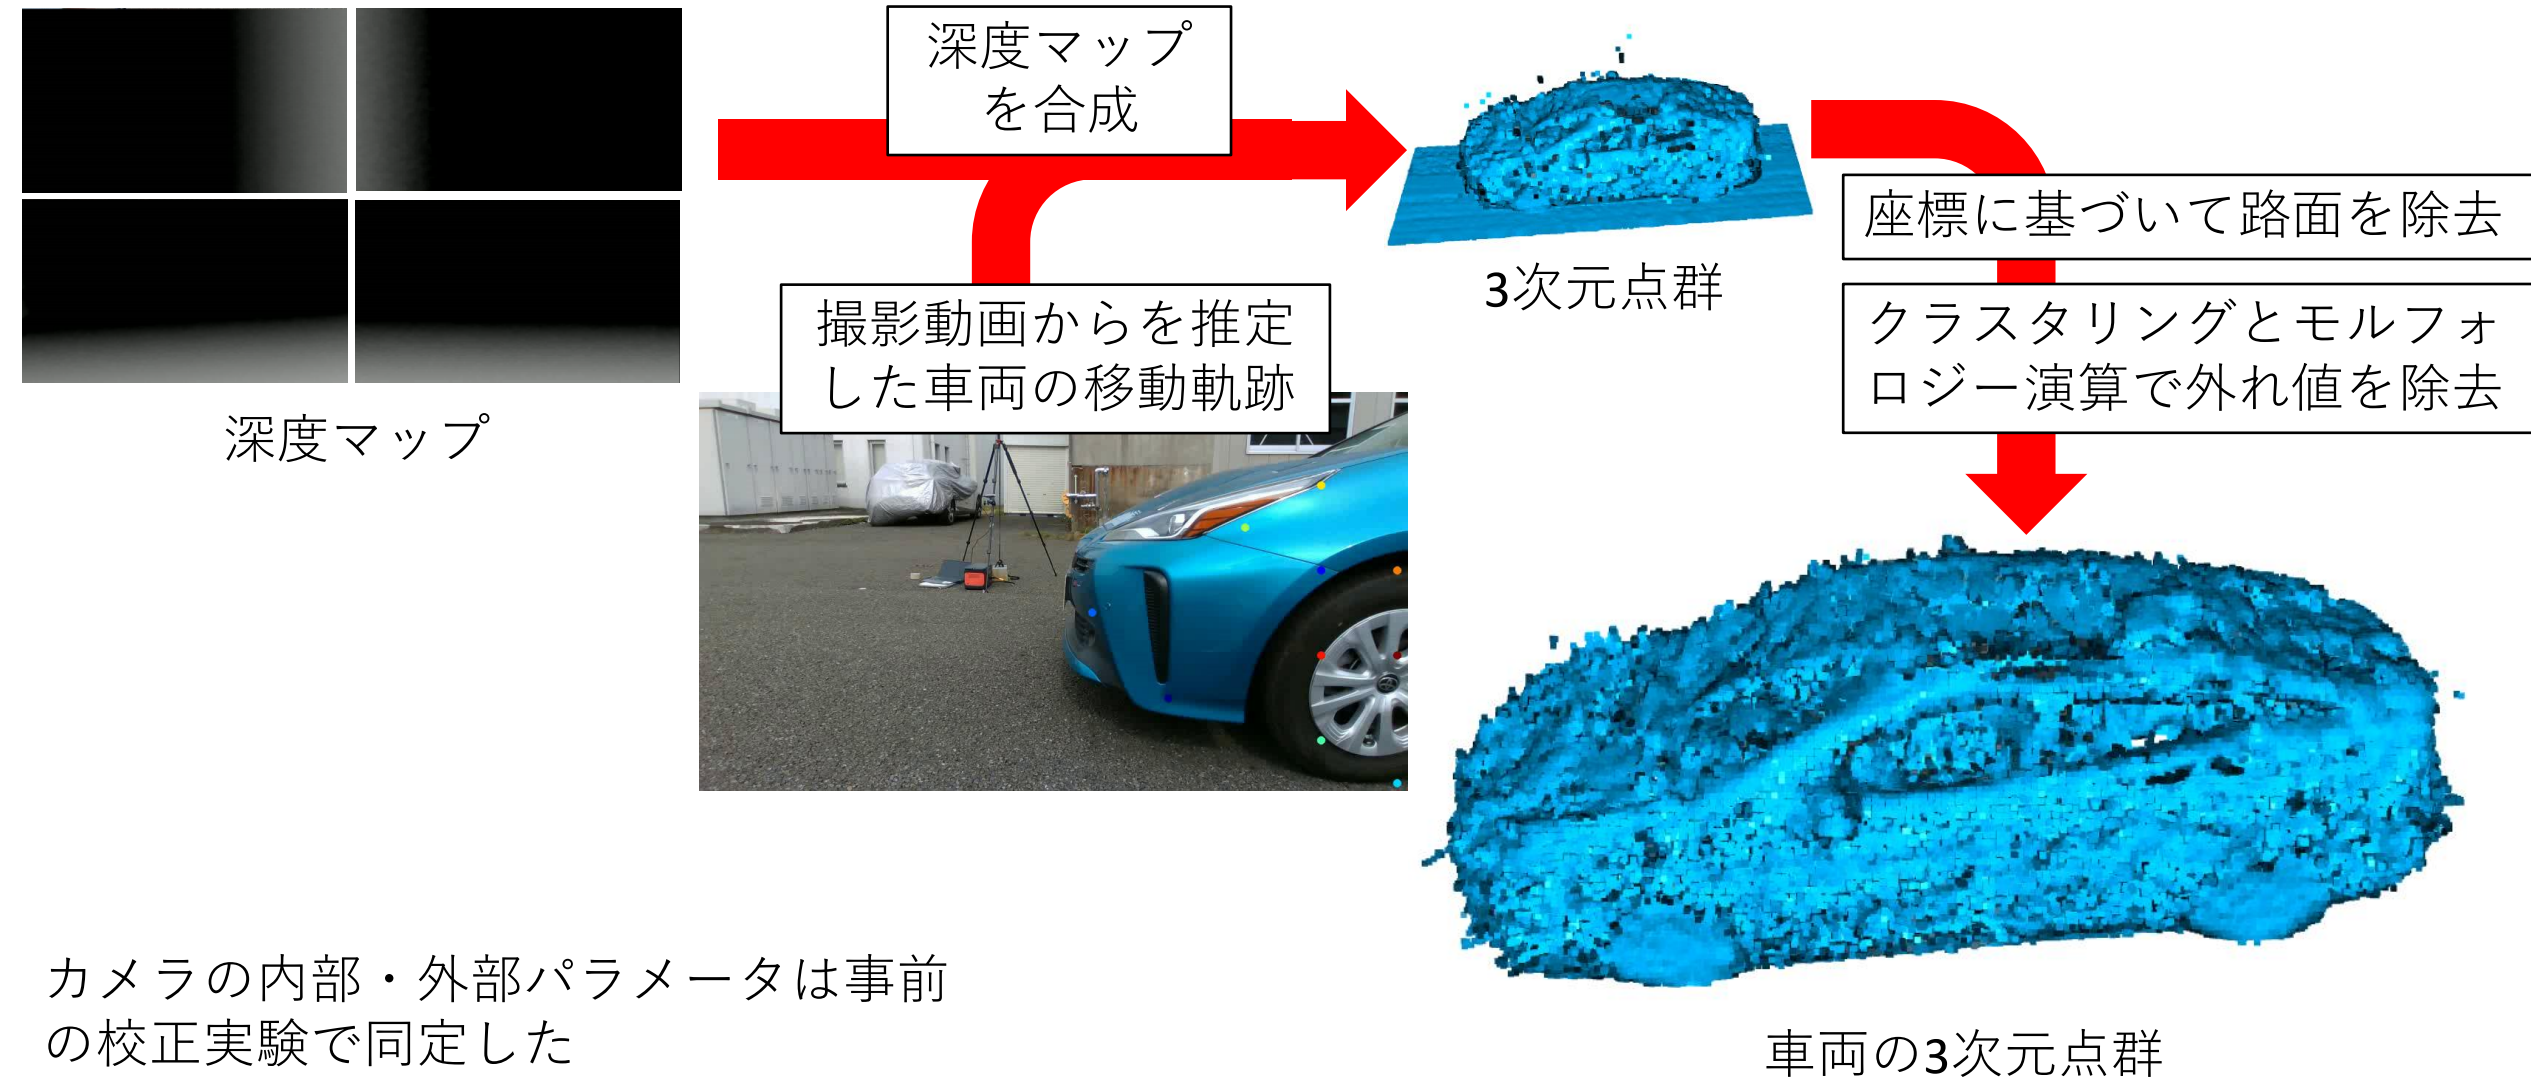
Intel RealSense Depth Camera D435f



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



計測時間：5秒程度

提案手法 —車両の3次元点群の再構成方法—




提案手法 —計測データのサンプリング—


検証する深度マップの動画



フレームを無作為に抽出して点群データを再構成



各点群データの点数が32768個になるようサンプリング




車両の点群 T_1


計測ノイズを除いた真の車両形状（真値）
は高確率でサンプリングされると考える

提案手法 —計測データのサンプリング—

検証する深度マップの動画



フレームを無作為に抽出して点群データを再構成




各点群データの点数が32768個になるようサンプリング



車両の点群 T_1

車両の点群 T_2


車両の点群 T_m




計測ノイズを除いた真の車両形状（真値）
は高確率でサンプリングされると考える

検証対象の計測データから
無作為抽出によって
点群データ $T_1, T_2, \dots, T_m$ を複数取得する


提案手法 —複数の点群データどうしの比較—



提案手法 —複数の点群データどうしの比較—



提案手法 —異常度の計算方法—



講演内容

1. 研究背景・課題
2. 車両形状の異常検知手法の提案
- 3. 検証実験**
4. 検証結果
5. まとめ

検証実験 —計測した車両形状—



正常状態



異常状態I



異常状態II



異常状態III




異常状態IV



異常状態V

検証実験 —課題設定—




講演内容

1. 研究背景・課題
2. 車両形状の異常検知手法の提案
3. 検証実験
- 4. 検証結果**
5. まとめ

検証結果 —異常箇所の有無の判定—


提案手法で得られた最大異常度のヒストグラム（学習データ：10件）



最大異常度が正常状態と異常状態のものではっきりと分離していることがわかる
閾値を35に設定すれば100%の精度で車両形状の異常の有無を判別可能

検証結果 —学習データの必要件数—

学習データを変化させたときの提案手法の異常検知精度



ROC-AUC


異常度のヒストグラムが
正常データと異常データで
どれだけ分離しているかを示す指標
完全に分離していれば1.0
完全に分離していなければ0.5を示す

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回繰り返してROC-AUCの分布を得た

学習データを5件以上にするとROC-AUCは常に0.96以上の値を示した

検証結果 —学習データの必要件数—

ROC-AUC:0.963のときのヒストグラムの例（学習データ：5件）




閾値を45に設定すれば異常状態の車両の検出精度は100%で
正常状態の車両を異常状態とする誤検出率は8.9%

→ 検証実験においては、
学習データが5件以上あれば
提案手法は実用的な異常検知性能を有する


検証結果 —異常箇所の特定制—

学習データ:10件


正常状態の異常値 $\bar{s}_j$




異常状態Ⅰの異常値 $\bar{s}_j$



異常状態Ⅲの異常値 $\bar{s}_j$




異常状態Ⅱの異常値 $\bar{s}_j$




検証結果 —異常箇所の特定制—

異常状態Ⅳの異常値 $\bar{s}_j$



異常状態Ⅴの異常値 $\bar{s}_j$




学習データ:10件


異常箇所は検出できているものの車両上面を誤検出していた

検証結果 —誤検出の原因—

正常状態のサンプリングされた点群データの例



異常状態Vの点群データの例



誤差の原因としては屋外で計測実験をおこなったことで太陽光の影響を受けたことが考えられる

今後は、車両上部を十分撮影できるよう深度カメラを追加する
屋内で計測をおこなうなどの対策により異常検知の精度向上を目指す


まとめ

1. 本報では自動車検査業務における外観検査のAIを用いた自動化を目指し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た
2. 提案手法は検査場での適応を想定した計測方法による検証実験で評価し車両の形状異常の有無については実用的な精度で判別できることを確かめた一方で、異常箇所の特定については車両上面において誤検出が生じる場合があることもわかった
3. 異常箇所の誤検出は、屋外での計測により太陽光の影響を受けることが原因であると考えられる。今後は、車両上部を十分撮影できるよう深度カメラを追加する屋内で計測を実施するなどの改良により、異常箇所の検出精度の向上を目指す


ご清聴ありがとうございました

Point-MAEの優位性

位置ずれに強い
形状の表現力は低い



位置ずれに弱い
形状の表現力は高い



PaDiM


AIを活用した画像の特徴量化（抽象化）
によって、微細な差を許容しながら
異常検知できる



正常





異常



PaDimによる
解析結果

Point-MAE特徴量も同様に形状の表現力と
位置ずれ耐性を両立できると考える

Point-MAEの優位性



Point-MAEで特徴量化
(抽象化)




平面

	A	B	C	D
1	0.898798	0.520211	-0.04287	
2	0.940331	0.994617	0.203338	
3	0.322748	1.190959	0.728419	
4	0.496909	0.339477	0.120708	
5	1.302587	1.337109	0.159573	
6	0.937423	1.727548	0.628435	
7	1.030585	1.018313	0.15685	
8	0.3466	0.635253	0.39168	
9	1.130627	0.569644	-0.16888	
10	1.133198	0.748489	-0.06734	
11	0.167822	0.469893	0.415395	

	A	B	C	D
1	0.22169	0.460656	0.37415	
2	1.072504	1.854742	0.611816	
3	-0.07383	0.810912	0.773384	
4	1.24546	0.628662	-0.21136	
5	0.252604	0.505766	0.379585	
6	-0.0702	0.88836	0.815677	
7	-0.32908	0.932156	1.013552	
8	0.932624	0.715883	0.047549	
9	1.185663	1.092213	0.096131	
10	-0.3437	1.332144	1.254227	
11	0.645469	1.109413	0.46619	


事前学習

データセットの画像を入力し
被写体は何であることを推定する分類問題を学習



異常検知

事前学習したAIモデルをそのまま転用し
別のデータセットの画像の特徴量を抽出する
特徴量どうしをマハラノビス距離で比較



マハラノビス距離で比較

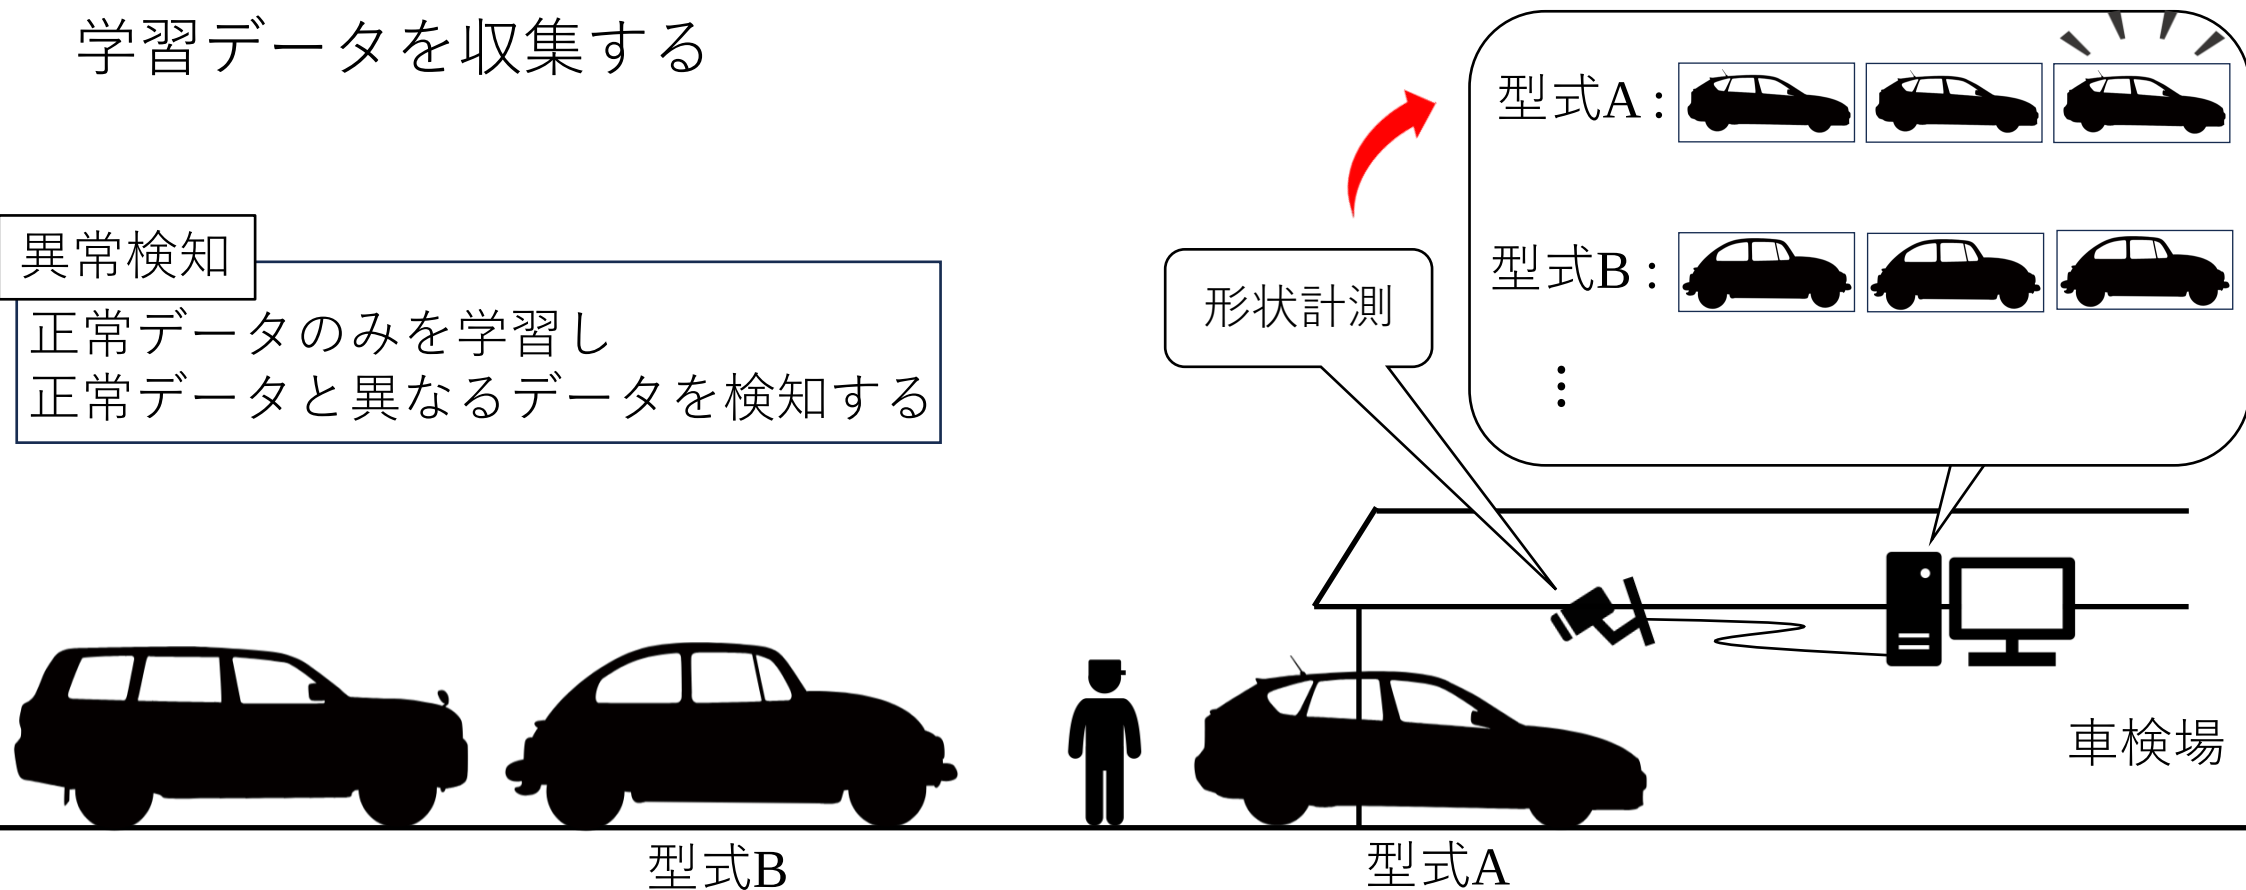
人工知能を活用した外観検査 —学習データの収集方法—

自動車検査業務の中で
学習データを収集する

異常検知

正常データのみを学習し
正常データと異なるデータを検知する

改造・故障ない車両の形状データを
型式ごとに蓄積する



解析時間


解析時間：1分30秒

CPU：13th Gen Intel Core i7-13700F
GPU：NVIDIA GeForce RTX 4070 Ti


計測時間：5秒




3次元再構成：60秒




異常検知：30秒



1. 形状計測




2. その他 検査



3. 総合結果を受け取る

評価点の配置方法



周辺の点群密度が高い（近辺に点群が十分存在する）
点を抽出



