HOKKAIDO UNIVERSITY

| | |
|---|---|
| Title | 鉄道車輪表面欠陥検査におけるレーザー計測とマシンビジョンによるハイブリッド自動検査手法に関する研究 |
| Author(s) | 江本, 剛 |
| Degree Grantor | 北海道大学 |
| Degree Name | 博士(工学) |
| Dissertation Number | 甲第16118号 |
| Issue Date | 2024-09-25 |
| DOI | https://doi.org/10.14943/doctoral.k16118 |
| Doc URL | https://hdl.handle.net/2115/93605 |
| Type | doctoral thesis |
| File Information | Takeshi_Emoto.pdf |

Hokkaido University Collection of Scholarly and Academic Papers : HUSCAP

# 鉄道車輪表面欠陥検査における
# レーザー計測とマシンビジョンによる
# ハイブリッド自動検査手法に関する研究

# A Study on Hybrid Automatic Inspection by Using Laser Measurement and Machine Vision for Railcar's Wheel Surface Defect Detection

2024 年 8 月

江本 剛

Laboratory of Precision metrology and Robotics

Graduate School of Engineering

Hokkaido University

目次

図一覧 ..... iv

表一覧 ..... vi

記号一覧 ..... vii

略語一覧 ..... viii

論文要旨 ..... ix

**第 1 章 序論 ..... 1**

1.1 本研究の背景 ..... 1

1.2 関連研究 ..... 17

1.3 本論文の構成 ..... 28

**第 2 章 レーザー計測とエッジ検出を用いた表面欠陥検出手法 ..... 30**

2.1 計測対象とシステム構成 ..... 30

2.2 表面欠陥を付与した計測用車輪試験片 ..... 39

2.3 レーザープロファイルセンサーによる踏面プロファイル計測 ..... 43

2.4 エッジ検出を用いた画像データからの欠陥検知 ..... 44

2.5 表面欠陥判定用 AI モデルの作成 ..... 48

2.5.1 実車輪の表面欠陥からの AI モデル作成 ..... 50

2.6 計測結果 ..... 56
2.6.1 踏面プロファイル計測結果 ..... 56
2.6.2 エッジ検出による判定結果 ..... 62
2.6.3 実車輪に発生した表面欠陥の AI モデルによる判定結果 ..... 64
2.7 考察 ..... 66
2.7.1 本研究の結果 ..... 66
2.7.2 将来の課題 ..... 67
2.8 結論 ..... 68

**第 3 章 レーザー計測と AI による車両運行に影響を及ぼす表面欠陥検出 ..... 69**

3.1 計測対象とシステム構成 ..... 69
3.2 摩耗を含む表面欠陥を付与した計測用車輪試験片 ..... 73
3.3 レーザープロファイルセンサーによる摩耗を含む踏面プロファイル計測 ..... 77
3.4 摩耗を含む試験体に再現した表面欠陥判定用 AI モデルの作成 ..... 78
3.4.1 摩耗を含む試験用車輪試験片の表面欠陥からの AI モデル作成 ..... 78
3.5 摩耗を含む試験片の計測結果 ..... 89
3.5.1 摩耗を含む踏面プロファイル計測結果 ..... 89

3.5.2 摩耗を含む試験片に付与した表面欠陥の AI モデルによる判定結果 ..... 96

3.6 考察 ..... 98

3.6.1 本研究の結果 ..... 104

3.6.2 将来の課題 ..... 104

3.7 結論 ..... 106

**第 4 章 結論 ..... 107**

謝辞 ..... 108

参考文献 ..... 110

Appendix ..... A-1

Appendix A 実験に用いた器具の写真 ..... A-1

Appendix B 実車輪のプロファイル寸法計測 ..... B-1

Appendix C YOLO の概要 ..... C-1

図一覧

1-1 鉄道車両のメンテナンス風景 ..... 4
1-1 専用の計測器具を用いた車輪寸法の計測風景 ..... 7
1-2 車輪とレールの接触部分詳細 ..... 10
1-3 車輪踏面の表面欠陥のイメージ ..... 12

2-1 レーザー計測器の車両基地における配置 ..... 32
2-2 自動検査システムフロー ..... 33
2-3 実験機器の接続状態および取り付け状態 ..... 34
2-4 計測用車両試験片-1,-2 の表面欠陥位置 ..... 40
2-5 計測用車両試験片の画像 ..... 42
2-6 画像処理のプロセス ..... 45
2-7 YOLOv5 のメカニズム ..... 49
2-8 実車輪より取得した表面欠陥画像（剥離） ..... 51
2-9 データ拡張（実車輪） ..... 52
2-10 YOLO モデル学習結果（実車輪） ..... 55
2-11 踏面プロファイル計測結果 ..... 59
2-12 エッジ検出による表面欠陥検出結果 ..... 63
2-13 実車輪の表面欠陥検知結果 ..... 65

3-1 計測システムフロー ..... 70
3-2 計測用車両試験片-3 の表面欠陥位置 ..... 74
3-3 計測用車輪試験片-3 画像 ..... 76
3-4 アルミ板に再現した表面欠陥 ..... 80
3-5 データ拡張結果（試験片） ..... 85
3-6 YOLO モデル学習結果（試験片） ..... 87
3-7 計測結果より生成した 3 次元モデル ..... 94
3-8 プロファイル試験片の計測精度確認 ..... 95
3-9 車輪試験片の表面欠陥検知結果 ..... 97

Appendix

A-1 レーザープロファイルセンサー LJ-X8400 ..... A-1
A-2 レーザープロファイルセンサーコントローラ LJ-X8000A ..... A-2
A-3 レーザー距離センサー LK-G405 ..... A-3
A-4 レーザー距離センサーコントローラ LK-G3000 ..... A-4
A-5 試験片移動用スライダ ..... A-5

B-1 車両ピット内での撮影イメージ ..... B-3
B-2 実車輪プロファイルデータの変換 ..... B-4
B-3 実車輪プロファイルデータ変換結果 ..... B-4

C-1 YOLO による物体検出例 ..... C-2

表一覧

1-1 車輪表面欠陥の種類と特徴および運行への影響 ..... 13

2-1 実験に使用した機器 ..... 36
2-2 計測用車輪試験片-1，-2 の表面欠陥とその寸法 ..... 41
2-3 機械学習に用いた画像の分類（実車輪） ..... 54
2-4 AI モデル学習結果（実車輪） ..... 54
2-5 車輪踏面プロファイル計測結果（試験片-1） ..... 57
2-6 試験片-1，試験片-2 の表面欠陥計測結果 ..... 61

3-1 計測用車輪試験片-3 の表面欠陥とその寸法 ..... 75
3-2 表面欠陥の整理 ..... 81
3-3 機械学習に用いた画像の分類（試験片-3） ..... 83
3-4 AI モデル学習結果（試験片-3） ..... 88
3-5 踏面プロファイル計測における計測誤差 ..... 91
3-6 車輪踏面プロファイル計測結果（試験片-3） ..... 92

4-1 表面欠陥検知結果 ..... 99
4-2 欠陥検知例 ..... 102
4-3 AI モデルの分類について ..... 102

記号一覧

$v$　　試験片の移動速度

$L$　　試験片の移動距離

$t$　　計測周期

$I(a, b)$ 画像データ内のピクセル情報

$a$　　ピクセル内の水平方向の位置

$b$　　ピクセル内の垂直方法の位置

Gray($a$, $b$)　　画像データ内の各ピクセルのグレースケール情報

Red($a$, $b$)　　画像データ内の各ピクセルのレッドスケール情報

Green($a$, $b$)　　画像データ内の各ピクセルのグリーンスケール情報

Blue($a$, $b$)　　画像データ内の各ピクセルのブルースケール情報

x　　計測対象の幅方向の位置座標

y　　計測対象の長さ方向の位置座標

z　　計測対象の高さ方向の位置座標

G($a$, $b$)画像データ内の各ピクセルのガウスカーネル

σ　　ガウス分布の標準偏差

G$a$　　ソーベル演算子の $a$ 方向の 1 次導関数

G$b$　　ソーベル演算子の $b$ 方向の 1 次導関数

$\rho$　　原点(0,　0)から垂直軸の沿った線までの距離

$\theta$　　線と水平軸の間の角度

略語一覧

| | |
|---|---|
| AI | Artificial Intelligence |
| CAD | Computer-Aided Design |
| CCD | Charge Coupled Device |
| CBM | Condition-based maintenance |
| mAP | Mean Average Precision |
| TBM | Time-based maintenance |
| YOLO | You Only Look Once |

# 論文要旨

鉄道車両のメンテナンスは，熟練の作業者によって主に目視および手作業にて特殊な計測器具を用いて行われている． しかしながら，近年の日本国内における労働力の不足およびメンテナンスの更なる効率化のためにも鉄道車両業界への自動計測の導入の促進が鉄道事業者より望まれている． 本研究では，鉄道車両を安全に運用するための最重要部品の一つである車輪踏面の外観検査を自動化する手法について研究を行う． 車輪の外観検査は主として寸法計測，外観目視検査および超音波などを用いた非破壊検査が行われているが，その中でも車輪踏面のメンテナンスはその作業の多くを人力に依存している． 本研究では車輪踏面の外観検査を効率的に実施するために以下の 2 種類の自動検査方法について提案し，その研究結果を示す．

本研究で扱う自動検査の手法は，一つは車輪踏面のプロファイル（踏面形状）計測であり，もう一つは車輪踏面表面欠陥の検出である． これらの 2 つは鉄道車両の安全な運用にとって重要であり，作業者が手作業によって実施するには多くの労働力が必要であり，また安全性の確保のためにも各作業者によるばらつきを低減すると共に計測精度の向上が求められている． これらに対応した効率的な自動検査を行うために，本研究では車輪踏面プロファイル計測にはレーザー計測器を，車輪踏面表面欠陥の検出については画像内の境界要素のエッジ検出と AI による物体検出を用いた手法を提案する． 本研究における手法は，

車両基地において，メンテナンス用のピットに車両が入場した際に車両の接近を検知して計測を行うシステムを想定しており，レーザー計測器とビデオカメラを車両基地のピットに設置して，ピットに入場してくる鉄道車両の車輪を計測する状態を想定した機器構成としている． この構成を実験にて再現するために，本研究ではレーザー計測器とビデオカメラを治具に固定し，車輪踏面表面部分を再現した車輪の部分カットの試験片を，速度調整が可能な可動式のスライダに固定して移動させて計測を行う方法とした． この機器構成にて，レーザー計測器による車輪踏面プロファイル計測と同時にビデオカメラにて撮影した画像を解析し，表面欠陥を検知する実験を本研究にて実施した．

レーザー計測器も画像解析も外観の自動検査に有効な方法であるが，それぞれを個別に使用したのでは検出が難しい欠陥がある． 例えば摩耗が発生してから時間が経過した場合には，外観的特徴をエッジ検出や AI による物体検知でとらえるのが難しくなり，欠陥を検出できない場合もあるため，レーザー計測と画像解析を組み合わせてそれぞれの弱点を補う検査手法を提案する． なお，実際の車両基地において本研究で実施したようにレーザー計測器とビデオカメラを設置して計測が可能であることは確認済である．

序論である第 1 章では現在の鉄道車両業界での自動計測に関する現状と，これまでの鉄道および周辺部材について研究されている検査手法に関する先行研究について述べる． 本研究では車輪の踏面プロファイル計測と踏面の表面欠陥検知について，異なる計測用車両試験片を用いた 2 つの手法による研究を行っており，どちらもレーザー計測と画像解析による計測手法を組み合わせて互いの欠点を補い合うことにより，それぞれが個別では発見することが難しい表面

欠陥の検出が可能とすることを示している． 計測精度の確認のために実物大の車輪を切り出したプロファイル形状を有した計測用車輪試験片に機械加工によって表面欠陥を付与したものを用いている． これらの計測用車輪試験片に対して，鉄道車両の安全な運行に影響を及ぼす 5 種類の表面欠陥を，機械加工によって寸法を管理して付与しており，それらの試験片を計測することで計測精度の確認を行う． この車輪の表面欠陥は鉄道車両の運行に大きな影響を及ぼすため，これらが検知可能となることは実用上大きなメリットがある． これらの車輪の表面欠陥をレーザー計測と画像解析を用いて検出する手法について実施した 2 つの研究結果について第 2 章と第 3 章でそれぞれ述べる．

第 2 章では，第 1 の研究として，レーザー計測と画像データ内の境界となるエッジ要素の検出を用いた表面欠陥判定に関する自動検査の手法について述べる． 提案する自動検査手法のシステム構成，処理の流れとその実験結果について述べる． ここでは，線状のキズを含む表面欠陥を再現したアルミ製と鋼製の 2 種類の車輪試験片を試験片移動用スライダにて移動させて計測を行う． レーザー計測器による車輪踏面のプロファイル計測を実施するのと同時に，ビデオカメラによって撮像されたイメージデータを分析し，車輪踏面に発生した表面欠陥の検知を行う． レーザー計測器による計測では，人力による計測では非常に困難である高い精度での計測を達成し，またエッジ検出によって線状のキズを検知できることを示す． また，実車輪に発生した表面欠陥のひとつである剥離について YOLOv5 に基づく AI モデルによる物体検知を用いて判定した結果を示す．

第 3 章では第 2 章で述べた方法を発展させ，直線形状でない表面欠陥でも検

出をするために, AI を用いて計測用車輪試験片に再現した表面欠陥を判定できるようにした． エッジ検出ではマーキングなど深さの無いものでも直線状の形状のものは検出できるが，鉄道車両の安全な運用に影響を与えるような表面欠陥で，楕円形状を含む円形のものや直線よりも複雑な形状のものの欠陥の検知ができないためである． ここでは特に，鉄道車両の安全な運用に影響する踏面の表面欠陥として，①熱亀裂，②剥離，③フラット，④フランジ摩耗，⑤踏面摩耗の 5 つの踏面表面欠陥に着目して研究を行う． これら 5 種類の表面欠陥を機械加工によって再現した車輪試験片を試験片移動用スライダにて移動させて，レーザー計測器によるプロファイル計測およびデジタルビデオカメラによる表面状態の撮影を行い，得られたイメージデータを分析して評価を行う． 撮影したイメージデータに YOLOv5 に基づく AI モデルを用いた物体検知によって欠陥を検出する手法を用いる． 実際の車輪に発生する 5 つの欠陥について機械学習を行うために十分な数のデータ取得が困難であるため，本研究では，計測用車輪試験片とは別に準備したアルミ試験片に表面欠陥を機械加工で再現して機械学習用の画像を準備する方法を提案している． レーザー計測器による計測では，人力による計測では非常に困難である精度での計測を達成することができるが，一方でレーザー計測器では亀裂などの幅が狭いものや剥離やフラットでもキズの深さが 0.1mm 以下のものの検出はできず，それらの検出には AI による物体検知を用いる． AI を用いた外観欠陥判定では，人間による見落としを防ぎ作業者間の判定のばらつきを低減することが可能になる． またレーザー計測器では画像解析では判定が難しい外観的特徴に乏しい摩耗のようなものの計測が可能なことを確認する． レーザー計測器と画像解

析を組み合わせて使用することにより，現在，多大な労力を要している車輪表面の検査にかかる時間の省力化が期待できることを示す.

第 4 章は結論であり，2 章と 3 章で実施した内容を総括した結論を述べ，今後の研究への提言を提示する.

# Abstract

Skilled technicians primarily use special manual tools to maintain the conditions of railcars. Considering the lack of workforce in Japan and to ensure efficient wheel maintenance, the development of an automated inspection system is desired by the Railroad companies. Herein, an inspection method for the surface defect condition of railcar wheels is proposed. The wheel is one of the crucial railcar parts, and the geometry and tread surface condition of wheelsets are crucial for ensuring railway operation safety. Based on the assessment of wheel tread dimensions and surface conditions, investigation results of the method are presented. The parameters of wheel tread dimensions and surface conditions including detection of defects are considered because they are crucial for railway operation safety and manually inspecting them requires a large workforce.

To improve the efficiency of the system, a combined inspection method through laser measurement for wheel profile measurement, and machine vision including AI for the detection of the wheel surface defect is used, both the techniques compensate for each other's shortcomings. In this study, the installation condition of inspection equipment should be on the pit area of railcar workshop. To reproduce this configuration, the location of laser sensors and video camera are fixed, and inspection pieces of the wheel model is moved using slider unit. Both the laser sensors and machine vision are effective method for visual

inspection of wheel surface, it is difficult to detect some defect individually, for example, when time has elapsed since the occurrence of wear, it becomes difficult for machine vision to capture, and defects may not be detected, therefore, an inspection method by combining laser measurement and machine vision to compensate for the each shortcomings. In addition, it has been confirmed that it is possible to measure by installing laser sensors and a video camera as conducted in this study at an actual condition of railcar workshop.

Chapter 1, which is an introduction, describes the research results of profile measurement and the surface defect detection on railways related area. In this study, the study for wheel tread profile measurement and surface defect detection are conducted using two methods by using different inspection pieces for the measurement, and both show that it is possible to detect surface defects that are difficult to detect individually by combining laser sensors and machine vision to compensate for each other's shortcomings. Five types of surface defects that affect the safe operation of railway vehicles are intentionally applied to the inspection piece by machining, and the measurement accuracy is confirmed by measuring these inspection pieces. The detection of these surface defect has a practical advantage, because those surface defects have impact on the safe operation of railcars. In this research, the two approaches of hybrid method of laser measurement and machine vision to detect surface defect on the railcar wheel is proposed.

Chapter 2 describes the proposed automatic inspection method, as the first research, an automated inspection method for surface defect detection by machine vision using laser sensors and edge detection. The system configuration, and the verification methods are described. In this study, two types of wheel inspection pieces, one made of aluminum and one made of steel, which reproduce surface defects including linear scratches, are moved with a slider device for moving the inspection piece, and the profile measurement of the wheel tread using laser sensors and the image data captured by the video camera are analyzed by machine vision to detect the surface defects that occur on the wheel tread. Laser sensors achieve a high accuracy measurement, which is very difficult to measure by human, and linear scratches can be detected by edge detection. In addition, the detection results by an AI model based on YOLOv5 are shown. One of the surface defects that occurred on actual wheels, detection of peeling is conducted using AI.

In Chapter 3, the method described in Chapter 2 is developed to enable the detection of surface defects reproduced on inspection piece. The reason for this is that edge detection can detect objects with a straight shape even if there is no depth such as markings, but it cannot detect defects with a circular shape including an elliptical shape or a more complex shape than a straight line, which are surface defects that affect the safe operation of railway vehicles. In this study, five types of surface defects that affect the safe operation of railway vehicles are selected: (1) thermal cracks, (2) peelings, (3) flats, (4) flange wear, and (5) concave wear. Those defects are reproduced on the inspection piece. The model

is moved using a slider device and a laser measuring device takes measurements and the video camera captures surface defects, and the image data is analyzed and evaluated using machine vision. In this experiment, to detect the surface defects, image data is analyzed using machine vision including AI model based on YOLOv5. Since it is difficult to obtain a sufficient number of image data to conduct machine learning on the five defects that occur in the actual wheel, this study proposes a method to prepare images for machine learning by reproducing the surface defects on an aluminum test piece prepared separately from the inspection piece. Measurements using laser sensors can achieve measurements with precision that is extremely difficult to measure manually. Although it is difficult to detect scratches with a depth or width of 0.1mm or less by technicians, it was confirmed to measure defects that lack external features such as wear, are difficult to be detected by machine vision. For those defects, visual defect detection using machine vision makes it possible to prevent human oversight and reduce the variation in detection between technicians. In addition, by using those methods, it can be expected that the time required for inspection, which currently requires a great deal of technicians, can be reduced. Combining laser measurement and machine vision to compensate for each other's shortcomings to detect defects that are difficult to detect using each method individually.

Chapter 4 provides a conclusion and presents recommendations for future research.

# 第1章　序論

## 1.1　本研究の背景

一度に大量の人員および物品の輸送が可能である鉄道車両は自動車や飛行機などの他の輸送機械よりもエネルギー効率の良い輸送が可能である．そのため，これまでも広く人々の交通および物流の手段として用いられてきており，そして今後もそれは継続し，更に発展して使用されると考えられている．鉄道車両は先進国ではもちろんであるが，世界中の新興国での新たな導入も進んでおり，近年では新興国でも旅客用で最高時速が200km/h以上となる高速走行が可能な鉄道の導入が進んでいる．今後の更なる省エネルギー化のためにも世界中でこれまで以上に活発に鉄道車両が使用されることが期待されている．このように効率的に大量の人員輸送が可能な鉄道であるが，一方で事故が発生した際には多数の死傷者が発生する可能性もあり，鉄道の安全な運行を確保することが非常に重要となっている．鉄道車両の安全性を保つためのメンテナンスは日本国内でも訓練された作業者による目視検査や特殊な道具を用いた寸法計測が現在でも主である（Fig. 1-1）．ここで示されるように人力による作業が多くある．Fig. 1-1（a）は車両基地のピット(床面を掘りこんで車両の下部となる床面にメンテナンスのために作業者が入ることができる空間を設けたもの)にて台車を下面からもメンテナンスできるような状態にしてメンテナンスを行っている．Fig. 1-1（b）は，車両をジャッキで上昇させて，車両を床下からメンテナンスすると共に，パンタグラフや空調機などのような屋上部品を同時にメンテナンスしてい

る．

鉄道車両は高価であり，製造に多大なエネルギーを消費していることを考慮すれば，消耗品のように使い捨てることができない． したがって，適切な周期および方法でメンテナンスを行い，寿命まで使い続けていく必要がある[1][2]. また，鉄道を走らせるためには都市計画を含めて線路計画や，使用する車両の規格を決める必要があるため，簡単には車両の設計を変更することができない. 特にレールの形状を変更するなどは簡単には実施できないため，鉄道が使用される状況が変化したとしても，メンテナンスの方法を工夫するなどして対処する必要がある． このように，鉄道車両を安全に運用させるためには訓練された作業者による適切なメンテナンスの実行が非常に重要であるが，Fig. 1-1 に示すように，まだまだ作業者による手作業によるものが多いため，労働力の不足が問題視されている． 特に日本では鉄道の保守のような夜間の肉体労働作業が敬遠されることや，労働者人口の高齢化による作業者の人員減が問題となっており，鉄道事業者からは作業の効率化のためだけでなく，労働人口の減少対策のためにもメンテナンスの自動化が望まれている． そのため，メンテナンス作業の省力化と作業効率向上のために村田[1]は，鉄道車両基地に様々なセンサーを取りつけてメンテナンス業務の改善を行うことを提案している． 石塚[2]は，日本国内の鉄道事業者における作業員の大量退職について言及し，技術の継承とメンテナンスコストの低減，車両の搭載機器が複雑化してもメンテナンスの質を維持するために新技術を導入してメンテナンス体系を見直すことを提案している. 長峰[3]らは鉄道の軌道を走行中の鉄道車両から撮影して撮像した画像を用いて自動検査を行う手法を提案している． この手法により，これまで定期的に作業

員が徒歩によって実施していた巡回点検や，特殊車両を用いて行っていた検査を自動化することにより，低コスト化，検査頻度の向上および状況に応じた臨機応変な検査の実現を提案している．



（a）台車のメンテナンス風景



（b）車両床下のメンテナンス風景

Fig. 1-1 鉄道車両のメンテナンス風景

（写真；JR 西日本提供）

またメンテナンスの自動化によって人員削減が期待されることから，鉄道の運行コスト低減のためにも鉄道車両への自動計測の適用の需要が高まっている．

鉄道車両にはブレーキやモータ，空調機やパンタグラフなど多くの安全な車両の運用に欠かすことのできない部品が使用されている中で，本研究では特に鉄道の安全な運行を支える最重要部品のひとつである車輪に着目する．

車輪は鉄道車両の全荷重を支えており，万一異常を生じた場合に他の部品でバックアップするようなフェールセーフ構造にもできない部品であり，絶対的な信頼性が要求されている． また，車輪は交換部品であるため，メンテンナンスコストも大きな関心事である[4]． 車両の走行中に発生する振動や摩擦，横荷重などの様々な荷重に対して安全な状態を保つように設計・製造され，使用されている． 半田[5]は，車輪の損傷と摩耗について紹介しており，車輪踏面（車輪とレールの接触する面）に発生する摩耗について述べており，割損（車輪表面に適正な車両運行ができないような大きな亀裂または欠落が発生した状態となる破損）や剥離に進展する影響がある熱亀裂の発生メカニズムについて詳しく報告している． また，半田[6]は，車輪の損傷のうちで最も優先的に防ぐべきは車輪の割損であると報告しており，その発生原因となる熱亀裂の発生メカニズムやフラットを含む車輪表面での摩耗の発生メカニズムについて報告している．車輪に要求される性能としては①重量，②疲労強度，③踏面の接触面圧強度，④ブレーキ熱を受けた際の応力分布，⑤耐熱亀裂・耐割損性能，⑥耐摩耗性，⑦走行性能（直線走行時の安定性，曲線通過性能），⑧走行時の騒音を低減させるための音響性能，⑨耐振動性能などがある[4]． このような様々な性能が要求される車輪であるが，検査は主に熟練の作業員によって特殊な計測器具を用いた手

動検査にて実施されており，そこでは Fig. 1-2 に示すような特殊な計測器具が使用されている． Fig. 1-2 において，左上の写真は踏面プロファイルゲージと呼ばれる計測器具である． このゲージは新規製作時の踏面プロファイルの形状をしており, このプロファイルゲージを車輪踏面に当てて隙間の有無を見ることで摩耗量を計ることができる． このゲージを使用して摩耗量を確認することが可能であるが, 摩耗量を計測する場合には定規などと併用して作業者が目視で計測する必要があるので，詳細な寸法を計測するのは難しい． 左下と右側に示されるものはフランジ寸法計測用の特殊な計測器具であり，Fig. 1-3 に示す踏面のフランジ部分に接触させることでフランジ高さとフランジ厚みの 2 つの寸法を計測することができるので，フランジ部分での初期寸法からの摩耗量を計測することができる． これらの道具はこれまでのメンテナンスの中で成果を上げてきたが, 摩耗の発生位置によっては計測ができないこともあり，また摩耗以外の欠陥，例えば幅の狭い亀裂については計測ができなかった． これらの特殊器具を用いた検査は，その性質上，目視，手動の検査となるため高精度かつ高頻度の検査は難しいものであった.

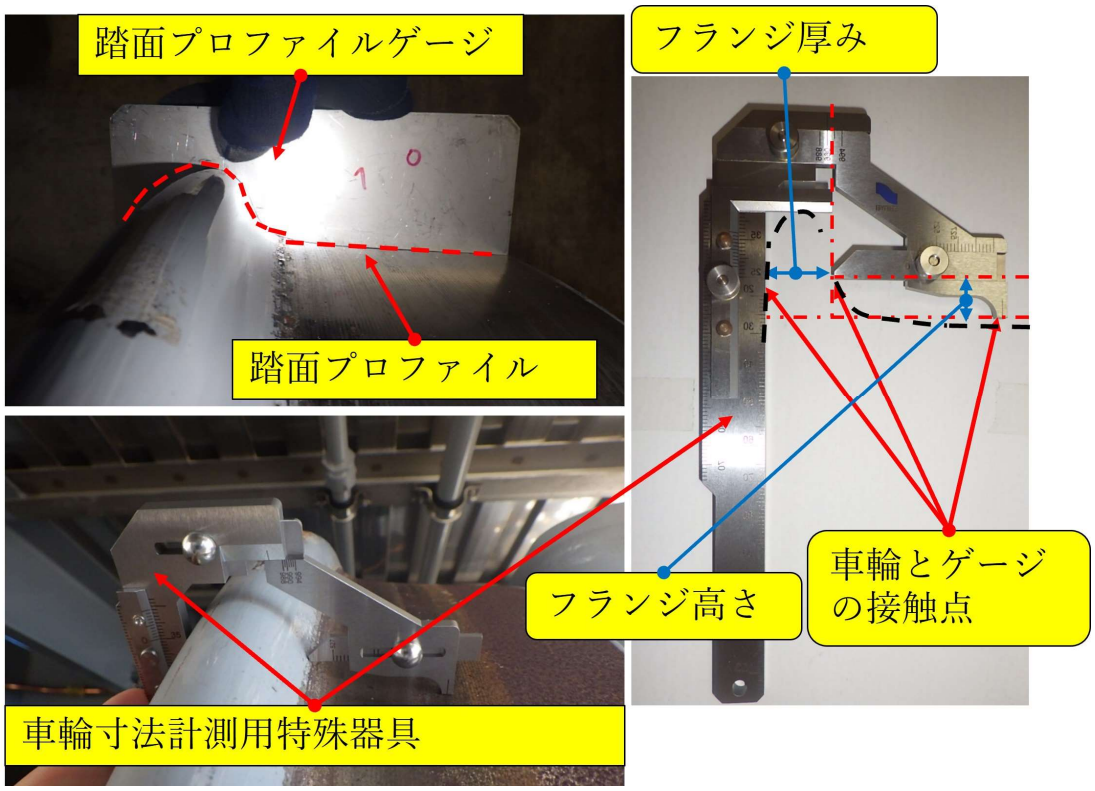



Fig. 1-2 専用の計測器具を用いた車輪寸法の計測風景
(写真；川崎車両提供)

上段左上: 踏面プロファイルゲージを用いた踏面プロファイルの計測.
※車輪表面の摩耗はプロファイルゲージと定規を用いることで確認することができる.
※摩耗量の計測寸法は±0.5mm 程度となる.
下段左下: 写真右に示す特殊な計測器具を用いてフランジ高さとフランジ厚みを計測することが可能となる.
※この計測器具を車輪踏面に対して当てて寸法値を読み取って計測を行う.

本研究では鉄道車両の安全な運行に影響を及ぼす重要部品である車輪の検査項目の中でも，特に車両の走行性能に影響する車輪踏面形状の寸法検査および車輪踏面表面欠陥検査に着目して，これらの自動化検査手法についての研究を行う．

まず車輪踏面プロファイル形状についてであるが，車輪は Fig. 1-3 に示すような状態でレールと接触している． 鉄道車両の車輪は全幅が 120 から 130mm 程度であり，そのほぼ中央部分でレールの中央部分と接触している． 走行中には風による荷重や, 他の車両とのすれ違い時に受ける荷重による揺動などの影響もあり，車輪踏面の中心部分を主として，その周辺で接触している． Fig. 1-3 中央部に示すような赤の斜線部分が通常走行中にはレールと接触しており，この部分に最も踏面摩耗が発生しやすい． Fig. 1-3 左側の青い斜線で覆われた部分が車輪フランジ部分である． 車輪フランジ部分は曲線通過時などにレールの頭頂面の側面寄りの部分またはレール側面が接触する部分であり，フランジ摩耗はレール側面と接触する部分に発生しやすい． 鉄道車両の車輪は，車両荷重を背負いながらレール上の車両を安全に案内するレールと同様にきわめて重要な車両の構成要素である． また，レールと車輪は製造方法，品質，輸送力，保守などの面から多くの検討がなされ, その形状および材質が今日まで発展してきている[7]． 鉄道車両は直線では高速で安定して走行することが求められており，曲線では滑らかに通過することが求められている． そのためには車輪踏面形状やレールの断面形状は，高速安定性と曲線通過性の両方の要求を満足させる形状となっている． 中橋[8]は，分岐通過時のレールと車輪の接触点の解析手法を提案している．また山本[9]らは車輪踏面の接触面形状の変化による車両の運動

性能への影響を報告している． 車両が走行するにつれて車輪とレール双方の摩耗によって車輪の踏面形状が変化すると，走行安定性や乗り心地の低下を招き，曲線を一定速度で通過することができなくなり，場合によっては脱線などを引き起こす可能性もある． Ishida[10]らは分岐通過時の乗り上げ脱線(曲線通過時などに発生する車両に対する横方向荷重が垂直荷重より過大な場合に車輪がレール上に乗り上げてしまうことで発生する脱線)の計算手法について報告している． 中橋[11]らはフラットや踏面摩耗によって振動が発生し，走行安定性や乗り心地性能におよぼす影響について報告している． それを防ぐためにも定期的に車輪を削正(車輪表面を機械などで削って元のプロファイル形状に近い適正な形状に修正する作業であり，運行の安定性や安全性を保つために定期的に実施されている）して適切な踏面プロファイル形状を維持するメンテナンスが行われている[8].

車輪の削正は，一定の期間（半年など）や一定距離の走行（10,000km など），または不定期の場合としては車両の運行に支障をきたすレベルのフラットなどの踏面表面欠陥が発生した際に行われるが，車両の走行時のバランスを保つためにも最低でも 1 車両または 1 編成すべての車両の全車輪に対して専用の旋盤にて削正を行う必要がある． そのため車輪削正作業は鉄道事業者にとっても大きな負担となるメンテナンスであり，基本的には一定周期での計画的な削正が実施されている[5]．車輪削正の際には削正専用設備に同時に設置されているレーザー計測器で寸法を計測し，目標の形状との比較を行いながら自動または手動での削正が行われる．

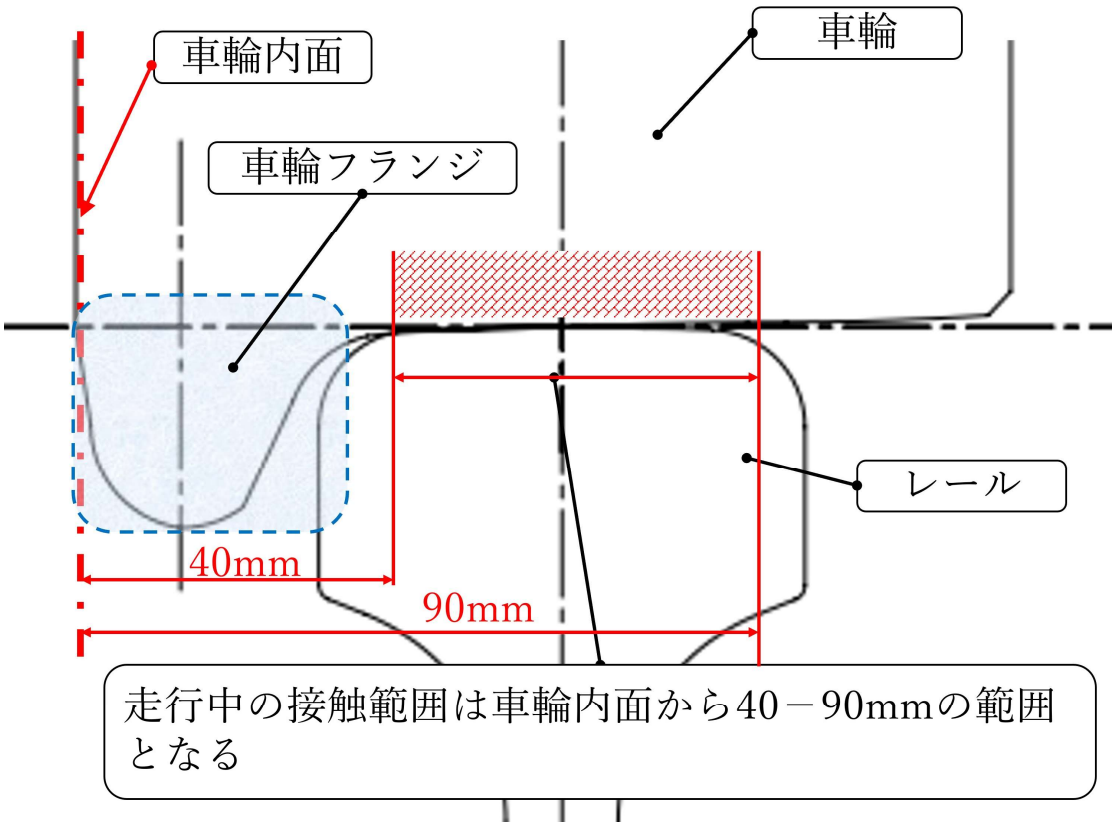



Fig. 1-3 車輪とレールの接触部分詳細

車輪踏面表面欠陥検査について，その外観から判別できる欠陥には様々な種類のものがあるが，本研究では鉄道車両の安全な走行に影響を及ぼす次の 5 種類の欠陥に関する検査手法について研究を行う． それらの欠陥とは①熱亀裂，②剥離，③フラット，④フランジ（鉄道車両が脱線しないように車輪の内側に設けられたものである．Fig. 1-3 参照）摩耗，そして⑤踏面摩耗である． Table 1-1 にそれぞれの欠陥の特徴と運行への影響を記載し，Fig. 1-4 にそれぞれの欠陥の代表的な形状を示す． これらの欠陥は目視による外観検査で発見可能なものもあるが，踏面プロファイル計測でないと発見が難しいものもある． 以下にそれぞれの欠陥内容の詳細について述べる． ①の熱亀裂は車輪の円周上で車軸と平行な方向に発生する表面欠陥である． 発生原因はブレーキを作用させた際の熱による影響が大きい[12][13]． 熱亀裂が剥離に進展する場合があり，更には割損に発展することがあることから安全への影響が懸念される[5][6]． 熱亀裂が多数発生した場合には車輪削正時の削正量を増加せざるを得ないことから車輪使用寿命を著しく短縮させる原因となっており，車輪管理の主要な課題となっている．

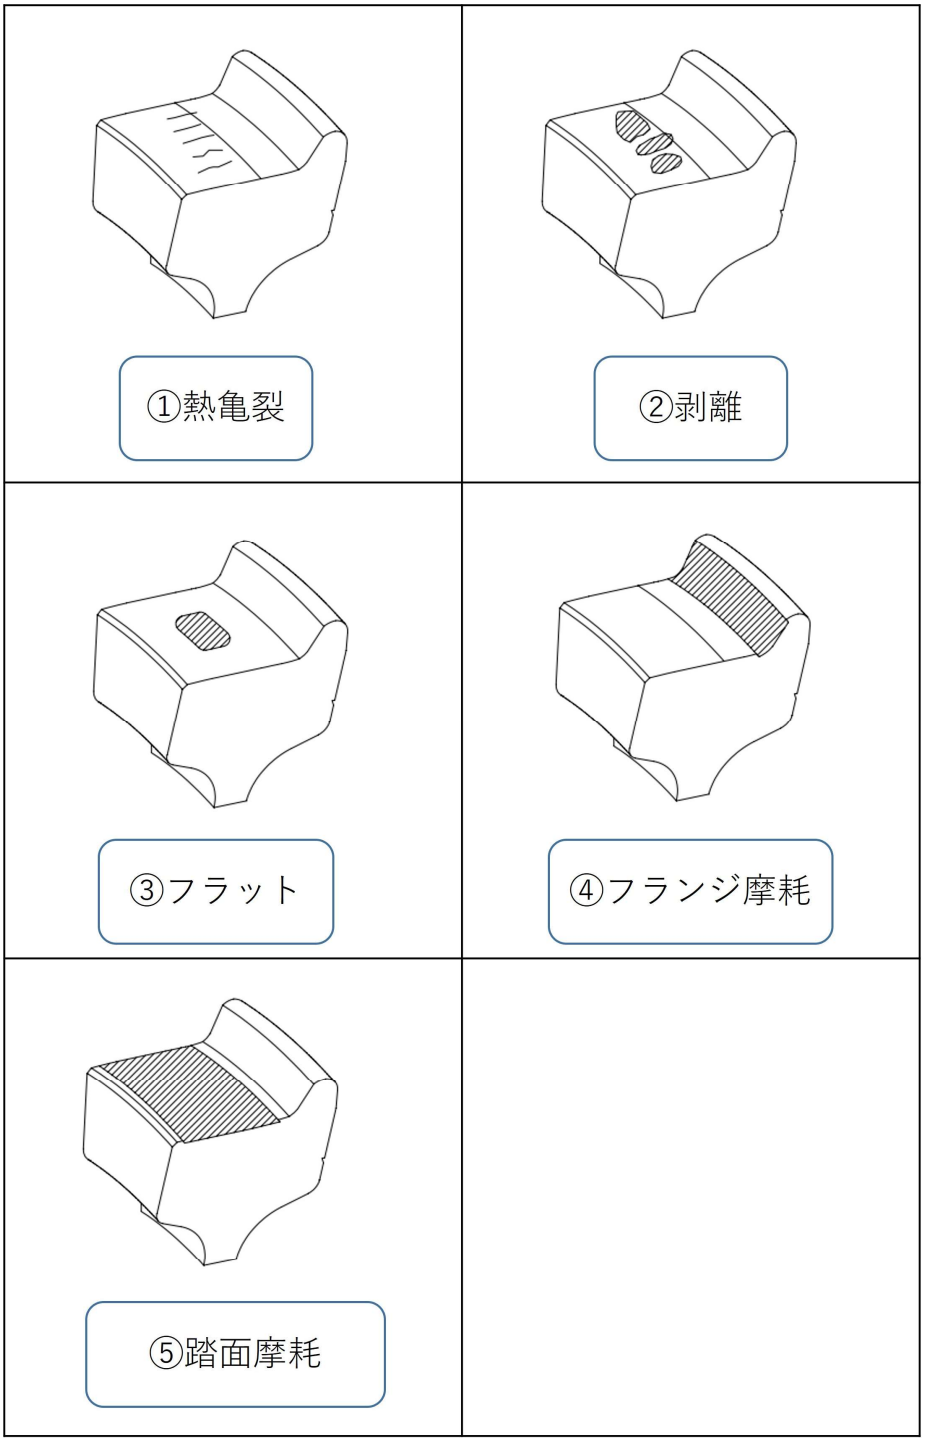



Fig. 1-4 車輪踏面の表面欠陥のイメージ

Table 1-1 車輪表面欠陥の種類と特徴および運行への影響

| 欠陥種類 | 欠陥の詳細 | 鉄道車両の運行への影響 |
|---|---|---|
| 熱亀裂 | 車輪踏面表面の円周上に発生する線状の亀裂. | 熱亀裂から剥離へと進展し，更に進展すると車輪割損へとつながる. |
| 剥離 | 熱亀裂が車輪踏面表面にある状態で走行することで剥離に進展する． 外観形状は様々であり，円形や楕円形の組み合わせのようなものが多い. | 熱亀裂から進展し，車輪割損へとつながる. |
| フラット | 車両にかけられるブレーキ力が車輪とレールの摩擦力を上回った際に車輪とレールの摩擦によって車輪に発生する局部的な摩耗となる． 形状は摩耗と類似のものになるが，車輪とレールの接触部の局部的なものになる. | 走行中の騒音と振動が増加する. |
| フランジ摩耗（凹摩耗） | カーブ通過時に車輪とレールの摩擦によって生じる車輪のフランジ部分への摩耗． 形状は摩耗であり，長期にわたって進展するため外観的特徴が少ない. | 摩耗が進むことでレールの分岐部を通過する際の脱線の可能性が上昇する. |
| 踏面摩耗 | 車輪とレールの接触によって発生する摩耗．フラットのように局部的に発生するものでなく，車輪のレールとの接触面全体にわたって発生する摩耗． 摩耗は長期にわたって進展するため外観的特徴が少ない. | 高速走行時の乗り心地性能が低下する. |
| 割損 | 熱亀裂や剥離から発展することが多く，形状は様々であるが，目視でも容易に発見可能な大きな亀裂が発生する場合もあり，車輪の一部が欠落するなど鉄道車両の運行に影響を及ぼす欠陥. | 正常な運用ができなくなるほどの車輪表面での破損となる. |

②の剥離は熱亀裂と熱亀裂の間が連続してつながることによって発生しやすい． 剥離も熱亀裂と同様に車輪の円周上に連続的に発生することが多く，剥離の間の健全部分も熱亀裂や剥離が進展することによって連続したものとなり，いずれは車輪の割損につながる場合もある[6]ため，初期段階で熱亀裂や剥離を発見することが車輪の割損を防ぐことにつながる． 剥離の発生メカニズムについては山本[14]の研究に紹介されている． 車輪とレールの接触部に発生する損傷としては，接触による摩耗の他，疲労が関係するものとしてフレーキングやシェリングと呼ばれる表面損傷と内部疲労損傷などがある． 表面損傷は車輪の転動により，レールと車輪の接触面に繰り返し荷重がかかることによって生じる疲労破壊であり，本研究では剥離の一部として取り扱う． ③フラットは車輪へのブレーキが作用した際に車輪が固着して滑走した際に発生する損傷で，フラット発生部が摩擦によって急激に加熱・冷却されて車輪表面に局所的な摩耗が発生することにより発生する． 車輪がレール上を滑ることによって表面が削られて車輪の真円が崩されるため，走行時に車輪が回転するたびに振動や騒音を発生させることにより乗り心地性能が低下する． 真木[15]らはフラットの長さにおける走行への影響について調査を行い，数値解析モデルとの比較を行うことでフラットとその形状が走行に与えるメカニズムについて紹介している．Hua[16]らは車輪の表面欠陥が接触面への振動に与える影響を実験とシミュレーションによる評価している． Ng[17]らはレールに表面欠陥を与えた状況で車輪が通過する際に回転振動が及ぼす影響をシミュレーションにより評価する手法を提案している． ④のフランジ摩耗は車輪のフランジ部分（Fig. 1-3）に発生する摩耗で，フランジ摩耗が進展するにつれて車輪のフランジ厚さが減少する

ことにより車輪の強度低下を引き起こすと共に分岐通過時にトングレール（鉄道の分岐部分において車両をひとつの軌道から他の軌道へ移す役割を果たす可動式のレール）への乗り上がりが発生することにより脱線の原因となる． 運輸安全委員会[18]による報告によると，平成 20 年 7 月に発生した三重県での列車脱線事故の原因は左右車輪の車輪径差が拡大しており，フランジ部分への摩耗が発生していたことによりトングレールへの乗り上がりが発生しやすい状態となっていたことが報告されている． このように，曲線部でレール上をせり上がるようにして生じる乗り上がり脱線と，高速走行時に車輪のフランジ部分がレールに突き当たってその勢いで滑り上がって脱線にいたる滑り上がり脱線がある． これらの脱線はフランジ摩耗の摩耗による形状変化によって発生率が変動する． 高澤[19]は車輪の踏面形状と摩耗や，車輪の踏面形状と脱線への影響についての研究結果を報告している． ⑤踏面摩耗（凹摩耗とも呼称される）はフラットと同じく車輪踏面に発生する摩耗である，フラットが局所的な摩耗であるのに対して，踏面摩耗は車輪踏面のレールとの接触面全体に渡って発生することが多い． また踏面摩耗は走行中の蛇行動の原因となる． Yang[20]らは，従来のように静止時に手作業で実施するのではなく，レール摩耗による振動の影響からレールの摩耗量を精度よく求める方法を研究した結果を報告している． 車輪踏面プロファイルは車両の運動特性や曲線通過性能などを考慮して設計されており，踏面摩耗が進展すると計画した運動特性を発揮できなくなり，異常な揺動が発生する場合もある[5].

このようにフラット，フランジ摩耗，踏面摩耗は発生する部位や大きさはそれぞれ異なるが，レールと車輪の摩擦によって発生する摩耗であるため外観は類

似したものとなる． 車輪踏面表面の欠陥は最悪の場合には脱線を引き起こす場合がある[10][18][19]．そのような事態を防ぐためにも車輪踏面表面の状態を的確に把握し，適切にメンテナンスすることは乗客や鉄道設備の安全を維持するためにも不可欠である． 従来から実施されている安全監視や巡回検査などの多くの業務は人間の視覚に頼って行われてきている． しかしながら全ての対象を人間が常に監視を行うことは困難である． 笹間[21]は人間の機能を補完してシステムの各部を監視する視覚システムの実現を鉄道のメンテナンスに応用することを提案している． また御堂[22]らは物体の欠陥を検知するために画像解析と機械学習を用いて実施する研究を行っている． このように欠陥検知のためのマシンビジョンの適用についても，画像変換を用いた検出のみでなく，Artificial Intelligence（AI）モデルとの複合によって検知を行う手法の研究が進んでいる． 本研究ではレーザー計測器とマシンビジョンを同時に用いて車輪の走行に影響を与える踏面表面欠陥を検知する新たな手法を提案し，その有用性を示す． なお，本研究ではマシンビジョンを，ビデオカメラなどによって撮像されたイメージデータの解析を行ってエッジ部分を検出することや, 物体検知に用いて自動検査に利用することを示すものと定義する．

## 1.2 関連研究

本研究では車輪の踏面プロファイル形状の計測および外観から判定が可能な踏面欠陥のうち，車両の運動性能に影響を与える 5 種類の表面欠陥の自動検査手法に関する研究を行う． 半田[5][6]が報告しているように車輪に発生する欠陥の中でも最も避けるべき欠陥である熱亀裂と剥離，運動性能に影響を及ぼすフラットを検知できる手法を研究する必要がある． 世界中の多くの研究者が様々な方法で車輪の表面欠陥検査に関する研究を行っており，その中でも鉄道車両の車輪踏面プロファイルの自動計測や, 車輪表面およびそれに類似した欠陥となることが多いレール表面の外観欠陥に関する先行研究の調査について述べる．村田[1]はカメラやセンサー類を用いて画像データや寸法の変化の情報を得ることによって鉄道車両の自動検査を行うことを提案している． また，村田はその提案の中で Charge Coupled Device Camera（CCD カメラ）による車輪踏面プロファイルの計測を提案しており，具体的には車輪のフランジ厚さを計測する手法を提案している． Jinlong[23]らは CCD カメラを用いた位相測定プロファイロメトリにて非接触で車輪表面形状の計測を行う手法を提案している．Yangkai[24]らは従来の車両を静止させて接触式プローブを用いて車輪の真円からのずれを計測する方法から，車両が低速で通過時に車両を静止させることなく計測を行う方法を提案している．また Xu[25]らは接触式のプローブをレールに当てて超音波により計測することでレール表面欠陥を計測する方法を報告している． Zhang[26]らは CCD カメラを用いて車輪のフランジ部分のリムの厚さを車両の移動を静止させることなく計測する実験をおこなっている．Wu[27]

らはレーザーと CCD カメラを用いて車輪踏面プロファイルを計測する方法を報告している． この研究ではレーザー光は距離を計測する目的ではなく，照射した線状のレーザー光を CCD カメラで撮影して断面形状を計測している．Gazafrudi[28]らは，レーザーとカメラを用いてレールコルゲーション(鉄道車両の走行に伴って軌道のレール頭頂面に規則的な波長の凹凸パターンが形成される現象． 振動や騒音の原因となり，鉄道の安全性や快適性に影響を与える)を計測する手法を提案している． レールコルゲーションを計測することができる手法は車輪の摩耗などを計測するためにも有効である． また Duan[29]らは CCD カメラを用いて撮影した画像にエッジ検出をかけて車輪の表面欠陥を検出する方法を提案している． Yang[30]らは 2 方向から照射したレーザー光を CDD カメラで撮影して重ね合わせることによって車輪プロファイルを計測する手法を提案している． Alippi[31]らはレール表面にレーザー光を照射して撮影した画像を解析してレール表面形状を計測する方法を報告している． CCD カメラを用いる手法では照明や露光時間の影響を除去してプロファイルを計測しやすくする方法が提案されている． このように，多くの研究者が CCD カメラを表面形状の計測に用いているが，CCD カメラを用いる場合には照明や露光時間を適切に調整しないと正確な計測が難しいという問題があり，本論文で提案する車両ピット内に計測機器を設置してセンサーで車両の接近を検知して計測を実施する方法への適用へは難しいと判断した． また，接触式プローブを用いる場合には安全に配慮して，計測時に車両を停止させることが必要になるため，自動検査を円滑に行う妨げとなるため本研究では除外した． 車両走行時の振動を計測する手法はフラットの発生を検知するには有効であるが，欠陥の発生位置やそ

の寸法の計測に用いるのには適していないため，本研究では除外している．Xuefeng[32]らや，Li[33]らはレールの表面欠陥を画像データから検出する手法を提案しており，画像処理を行うことで欠陥を画像内のエッジ要素を分析して検出する手法を提案している． Guo[34]らはレール表面の欠陥検出を行うのに車両通過時にカメラで撮影した画像を処理して扱う，例えばガウシアン画像変換を行うことにより検出する手法を提案している． Li[35]らは車両基地のピットにレーザー距離計を複数配置して車輪のフランジ高さ，フランジ幅や車輪直径を計測する方法を研究している． 1 台のレーザー距離計では車輪全周のプロファイル形状計測はできないため，複数のレーザー距離計を設置することは有効であると判断しており，本研究にもこの考えを取り入れている． Liu[36]らは車輪表面形状のレーザー距離計による計測手法を提案しているが，その提案では車両から取り外した車輪を治具で固定したうえで回転させ，固定したレーザー距離計にて車輪全周を計測しているため，本研究で提案するように車両の通過時に車両を静止させることなく計測を行う手法とは考え方が異なる． Pan[37]らは複数の CCD カメラとレーザー照射を用いて車輪踏面プロファイルを計測し，計測結果を合成して踏面全体を計測する方法を提案している． 石塚[2]は車両基地内に当別な計測装置を設定して車輪表面形状を計測して Computer Aided Design（CAD）データとの比較を行う手法を提案している． 車輪の摩耗量を記録して検査の計画を立てるためにも CAD データとの比較を行うことは重要であるため本研究でもこの考えを取り入れている． またレーザー計測器を用いた車輪踏面形状の計測に関する特許も出願されている． その中でも 2 次元レーザーを用いて車輪寸法を迅速，正確に計測する車輪形状測定装置の特許が複数件

出願されている[38－40]． 阪急電車[38]は車両が走行する線路近傍に車両位置を検出するセンサーを設置し，レーザー変位計を用いて車輪直径，フランジ高さ，フランジ厚さ，左右車輪間隔の距離などの寸法を計測する方法を提案している．アクト電子工業[39]は，車両の移動に追従して車輪踏面形状を計測する方法を提案している．日立交通テクノロジー[40]は走行中の車両にレーザー光を照射し，3 次元プロファイルカメラで撮影することで車輪各部位の寸法を計測する手法を提案している． 日立プラントテクノロジー[41]は非接触式とするためにレーザー距離センサーとレールの沈下量を計測して車輪の形状を演算する装置の特許を出願している． 他には接触式で車輪プロファイルを正確に計測する特許も出願されている[42]． この方法は，接触式ではあるものの作業員の技量に関わらず短時間で精度高く車輪踏面プロファイル形状を計測することを可能としている． これらの方法は，レーザー計測を単独で使用しており，マシンビジョンとの併用がなされていない． マシンビジョンとレーザー計測を組み合わせることが本研究の特徴である． また海外でも線路上に設置した計測器にて車両通過時にレーザー計測を用いて車輪プロファイルを計測する方法が紹介されている[43]． これも同じくレーザー計測単独によるものである． Torabi[44]らはレーザー光とカメラにて車輪直径を計測する手法を提案している． Yang[45]らはフラットを検知するための接触式センサーの改良についての提案している． また Krummenacher[46]らは通過する車両の車輪からの荷重の動きを機械学習にてフラットを検知する仕組みを提案している． 車輪からの荷重を検知する仕組みはフラットの検知などには有効であるが，摩耗の寸法を正確に検知するのが難しい． 葛田[47]は鉄道車両にレーザー距離計を取り付けて踏面形状を計測し，

摩耗量を計測する手法を提案している． 鉄道車両にレーザー距離計を取り付ける方法は車輪のプロファイル全周を正確に計測するには良いが，全ての車輪を計測するには通常の 1 両に 4 輪車輪を装着した台車の場合で，1 両あたり 8 台の計測器が必要となるため，実際の運用時に適用される可能性は低い． また，梅原[48]らは車両基地のピット線など水平な直線区間に留置された在姿車両（台車や車輪を外さない状態の車両）において，可搬式の計測器を車輪に接触させて踏面損傷の長さや凹み量などの形状測定を 3 次元測定で検出する手法を提案している． このように接触式を含むプロファイルの計測手法が研究されているが，接触式では車両を静止させて計測を実施する必要があるため，高頻度の計測を実施するためには適していない． 本研究では様々な種類がある計測手法の中でもプロファイルの寸法計測精度として手動計測で標準となる 0.5mm よりも高い精度での計測を達成できる可能性があり，照度などの影響を受けにくいレーザー距離計を車輪踏面プロファイル形状計測のための計測器として選定する．接触式の計測器では計測の際に安全上車両を停止させる必要があるが，非接触のレーザー計測では車両を停止させることなく計測が実施可能という利点がある． 車両を停止させる必要がないことから，車両基地での車両の移動時に計測を行うことが可能となり，高頻度計測の実現が可能となる． これもレーザー距離計を使用する理由である．

画像データの分析の研究では，取得した画像をコントラストの変換などによって表面欠陥を見えやすくした上で検知を行う方法を Fan[49]が提案している．取得した画像をそのまま使用するのではなく，画像変換を行って欠陥を検知しやすくすることは重要な手法である． Zhang[50]はレール表面の画像を撮像し，

剥離などの表面欠陥を変換してセグメンテーションを行うことで検知対象を分類して AI による検知を行う手法を提案している． Shang[51]らは，キャニーエッジ変換を適用した上で機械学習を行い，AI による欠陥検出を実現している．Han[52] らは threshold segmentation， morphological analysis や pattern matching などの画像変換を用いてレール表面の欠陥検出を行う手法を報告している． また，Nieniewski[53]らは速く，非破壊で，正確にレール表面の欠陥検出を行うために morphological detection を用いて実施する手法を提案している．Ma[54]らは Gabor Filter を用いて画像内の線状の成分を検知する手法を紹介している． Gan[55]らの手法でもレール表面の画像を画像変換して欠陥を検出する手法を紹介している． Vijaykumar[56]らは，取得したレール表面の画像を解析し, 輝度の差によって Gabor filter を用いて欠陥検出する手法を紹介している．このように車輪やレール表面の欠陥を検出する方法の研究成果が様々な研究者によって報告されており，マシンビジョンは表面欠陥を検出するのには有効な方法であると考えられている． マシンビジョンによって検知を行いやすくするための画像処理は必須であり，本研究ではその中でも二値化変換を行ってエッジを検出する手法を選定している．

欠陥検出に AI を用いる手法も多く研究されている． 長峰[3]らはハンディカメラを用いて撮影したレール前方画像からレールや枕木の劣化度を AI にて判定する手法を紹介しており，AI を用いた判定に関する研究事例を紹介している．画像を用いた欠陥検出における AI の利用には, 精度, 速度, 一貫性の向上など, いくつかの利点がある． その利点とは欠陥をリアルタイムで物体形状を特定し, 人為的ミスを軽減し，広範なデータセットを効率的に処理できるため品質管理

が強化され, 時間とリソースを節約できることである．多くの研究者が, YOLO（You Only Look Once）などの深層学習技術を利用して，鉄道部品に関連する表面欠陥検出を調べてきた． Liu[57]らや Tan[58]らは YOLO の検知メカニズムについての研究を紹介している． YOLO を使用した AI モデルを用いて線路上のさまざまなタイプの締結品の検出を行う手法が提案されている．Wang[59]らは，線路を締結する様々な種類の締結品の YOLOv5 を用いて構築した AI モデルによって検出する手法を紹介している． Resendiz[60]らは線路上を移動しながら撮影を行い, 線路を締結する要素である締結品, 接続プレートや枕木を AI モデルの使用によって検出する手法を提案している．また Li[61]らや Ruvo[62]らは線路上を走行する特殊車両に取り付けたカメラにて撮影した画像を用いて線路を締結する締結品の取り付け位置を検出する手法を提案している． YOLO を使用した AI モデルを使用した物体検知は様々な場面で使用されており， 鉄道車両に関連するものでは，Li[63]らは YOLO を使用して線路上の枕木の亀裂を検出する方法を提案し，Zhang[64]らや，Yang[65]らは YOLO を使用してレール表面の欠陥を検出する方法を提案している．Liu[66]らは線路周辺に存在するビニールごみを昼夜にわたって検出するための AI モデルの開発について提案している． また, Li[67]らは軌道を締結する締結品の AI モデルを用いた検知手法の実験結果を提案している． このように鉄道に関連する研究だけでも AI モデルの検査への導入に関する研究が多く実施されており，今後の更なる研究の深化が期待される．AI モデルにも様々なモデルが存在しているが, 本研究では, 学習モデルを作成するための手法が公開されており，表面欠陥画像から学習データを作成して AI モデルが作成可能なことから，本研究の目的達成のために最

適である YOLO を選定している． 効果的な自動検査システムを開発するために，本研究ではレーザー計測器とマシンビジョンの使用を組み合わせた手法を実験にて検討する．

将来的にはレーザー計測器によるプロファイル計測とマシンビジョンを組み合わせた計測方法が増えてくるものと予想されるが，現在の機器の利用方法では，それぞれが個別に使用されており，個別での研究が主である． 先に述べたようにレーザー計測器のみでは亀裂のような幅が 0.1mm 以下の欠陥を検出するのは困難であり，またそのような幅の狭い亀裂の深さを計測することは非常に困難である． またエッジ検出のみではホコリや汚れなどを欠陥と誤検知してしまう場合がある．

著者らはこれまでにレーザー計測とエッジ検出や AI による物体検知を組み合わせて車輪表面欠陥の検出を研究してきた． 2021 年には 3 次元プリンタにて製作したプラスチック製車輪の 20%スケールサイズの模型を回転させてレーザー計測器で計測する方法で車輪の踏面プロファイル形状を計測し，実車両から撮影した表面欠陥を含む車輪の画像を解析して表面欠陥を検出する方法の研究を行った[68]． この研究では画像に含まれる欠陥の存在する部位を検出するために輝度を画像の縦方向と横方向で分解し，画像内で輝度の値が異なる箇所に欠陥が存在することを確認した． レーザー計測器で模型の断面形状を計測することが可能であることを明らかにしたが, 3 次元プリンタで製作したモデルは透明なプラスチック製であるため，レーザーの反射や吸収により正確な形状を計測するのが難しい場合があることや, 3 次元プリンタによる製作精度が悪いという問題があった． また画像内の輝度から欠陥有無を判定する方法は画像の照度

の差による明暗の影響を大きく受けるため，この方法単独で欠陥を検知することが難しいことが明らかになった． 2022 年には踏面表面欠陥を含む実物の車輪の踏面プロファイル形状をレーザー距離計で計測し，そしてイメージデータを AI による物体検出によって欠陥検出を行うことの研究を行い，また車輪踏面形状を CAD データのオリジナルの踏面形状と比較した[69]． この研究では，車輪の状態がほぼ新品であったため，計測した車輪の踏面形状がオリジナルの踏面形状とほぼ一致する結果であった． また車輪踏面形状を正確にレーザー計測器にて計測できることが分かったが，計測精度の検証までは実施することができていなかった． このため，計測精度を確認するための方法を準備する必要性が課題として残った． 本論文でも述べたように，レーザー計測器の計測可能範囲が 300－560mm であるため，車輪全周を計測するためには 1 レールあたり 14 台のレーザー計測器が必要であることがわかっている． 2023 年にはレーザー計測器の計測精度の確認のために，機械加工によって寸法を管理し，意図的に欠陥を与えた試験用の車輪サンプルの計測を行うことで実用化のための研究を行った[70]． ただし，この際には深さのある表面欠陥も深さの無い表面欠陥も線状のもののみを付与しており，深さの無い円形状または楕円形状の欠陥を付与できておらず，また，鉄道車両の運行に影響を及ぼす欠陥を検知するという観点が欠けていた． これまでの研究結果から，試験用車輪サンプルはプラスチックなどでは無くて，実際に使用されているものであるか，またはそれに近い外観を有する材質を選定する必要があることを認識していたため，まずは鋼製の車輪試験片を準備した．これに加えて，AI モデル作成のための機械学習のために表面欠陥を機械加工によって付与する必要があることから，アルミ製の車輪試

験片も準備した.

2024 年には 2023 年までの研究成果を発展させてレーザー計測器と画像解析を組み合わせて鉄道車両の安全な運行に影響を及ぼす車輪踏面の表面欠陥を検出する手法の研究を行った． 計測用車輪試験片を機械加工して意図的な表面欠陥を付与したものをレーザー計測でプロファイルを計測し，撮像した表面欠陥画像を画像変換してエッジ検出する手法で欠陥検知を行った． これらの 2 つを組み合わせて実車輪に生じている剥離欠陥を AI モデルにより検知する方法の実験を実施した[71]. 本論文ではエッジ検出と実車輪の踏面表面欠陥について AI モデルを作成して検知するこの手法に関する研究について第 2 章に述べる.

またその研究で用いたエッジ検出から発展させて摩耗や亀裂など実運用に影響を及ぼす 5 種類の表面欠陥を機械加工によって付与した計測用試験片をレーザー検出と， AI モデルによって検知することを検証した[72]. この 5 種類の表面欠陥を，AI を用いて検出する研究に関する記述を第 3 章に述べる． AI モデルの作成にあたっては，摩耗のように欠陥のある部分と欠陥の無い部分の境界の特徴に乏しいものの検知が非常に難しいことがわかっている． この状態で機械学習を実施して AI モデルを作成すると，光沢部分や薄い線の入った部分を検知してしまい，多数の誤検知が発生したため，試験片に再現する表面欠陥については，外観的特徴があるものを作成する必要があることがわかっている． また，実車両の車輪表面に発生する表面欠陥の画像データの入手が非常に重要であるが，大量の画像データの入手が非常に困難であり，発生頻度の高い表面欠陥でも，外観的特徴に乏しい種類の摩耗については検知を行うことができる AI モデルの作成ができていない． レーザー計測器やマシンビジョンを用いた表面欠

陥の計測手法はこれまでにも提案されているが，それぞれを個別で使用する研究が主であり，レーザー計測器とマシンビジョンを組み合わせた手法でも，車両の走行に影響を及ぼす表面欠陥の検知について着目されている研究はこれまでなかった． 本研究ではこれまで着目されていなかったレーザー計測器とマシンビジョンを組み合わせて車両の走行性能に影響を及ぼす表面欠陥をレーザー計測とマシンビジョンそれぞれの欠点を補って計測を行う手法を提案することを目的とし，その研究成果について述べる．

## 1.3 本論文の構成

本研究では鉄道車両車輪の踏面に発生し，鉄道の安全な運用に影響を及ぼす①熱亀裂，②剥離，③フラット，④フランジ摩耗，⑤踏面摩耗の 5 種類の表面欠陥をレーザー計測器とマシンビジョンを用いて検査する手法を提案し，その検出結果を実験により検証する． 本論文は全 5 章で構成されており，以下にそれぞれの章の概要を示す.

第 1 章（本章）は序論であり，本研究の背景として車輪やレールの踏面プロファイル計測および表面欠陥に関する先行研究について述べ，本研究の目的とする車輪踏面表面欠陥検査のコンセプトおよびこれまでの研究内容について述べる.

第 2 章と第 3 章では本研究で実施した実験の計測方法と計測結果について述べる．本研究では 2 本の論文の投稿を行っており，第 2 章は 1 本目の論文の内容について述べている．第 3 章では 2 本目の論文の内容について述べている．そのため，実験装置などは 2 本の論文で同じものを用いており，大きな差異は用いる試験片に含まれる欠陥種類を車両の走行に影響を及ぼす欠陥としたこととなる．また，第 2 章の内容ではレーザー計測とイメージデータ内のエッジ要素検出により表面欠陥検出を行う手法を研究しており， 第 3 章の内容では車両の走行に影響を及ぼす 5 種類の表面欠陥をレーザー計測と AI による物体検知で検出する手法を研究している．以下に第 2 章と第 3 章の内容について記載する.

第 2 章では，レーザー計測とエッジ検知を用いたマシンビジョンによる計測システムの定義と課題を示し，計測を行う対象と計測方法について述べる． 車

輪踏面の表面形状を模擬した計測用車輪試験片を準備し，摩耗などを機械加工によって意図的に与えて，レーザー計測器の計測精度の確認を行う． 計測用車輪試験片はスライダを用いて移動させて実際の使用状況を模擬した計測を行う．また計測用車輪試験片に与えられた表面欠陥をビデオカメラで撮像し，その画像データを解析して画像内のエッジ要素検出による欠陥の判定を行う． それに加えて実車輪から収集した表面欠陥を含む画像を，欠陥検出のために学習を行った AI モデルによって判定する． AI モデル作成のために準備した画像の種類や AI モデル作成の方法について述べる． 本章で実施した研究における限界を含む問題点などの考察および将来の課題について述べる．

第 3 章では，2 章で述べた方法を発展させ，鉄道車両の安全な運行に影響をおよぼす 5 種類の表面欠陥をレーザー計測器と YOLOv5 を基に作成された AI モデルを用いて，それぞれの欠点を補うことで 5 種類の表面欠陥の判定を行う手法について述べる． ここではレーザー計測器による踏面プロファイル計測と AI モデルによる物体検出を用いた踏面表面欠陥検出の判定の結果について述べる．本章での結果から得られたこと，限界を含む問題点などの考察および将来の課題について述べる．

第 4 章は結論であり，第 2 章， 第 3 章での研究で得られた成果について述べる．

# 第 2 章　レーザー計測とエッジ検出を用いた表面欠陥検出手法

本章では①レーザー計測による車両踏面プロファイルの計測と，②マシンビジョンを用いた車輪踏面表面欠陥検出手法の実験に用いた機器のシステム構成と実験手順およびその結果について述べる． マシンビジョンを用いた表面欠陥を検知するための手法として,取得したイメージデータを画像処理して行うエッジ検出手法と実車輪に発生した表面欠陥を検知するための AI モデルの作成についても本章で述べる． 本研究で提案する手法は，これまで別々に実施されていた①レーザー計測による車輪踏面プロファイルの計測と②マシンビジョンによる表面欠陥検知を同時に実施し，レーザー計測器とマシンビジョンのそれぞれの欠点を補って計測することである． レーザー計測器による車輪踏面プロファイル計測と，車輪踏面の表面欠陥を検出するエッジ検出手法，および AI モデルを用いた実車輪に発生した表面欠陥を検知するための計測システムの研究について述べる．

## 2.1　計測対象とシステム構成

本研究で想定される使用状況は Fig. 2-1 に示すとおりである． 本研究の目的は鉄道車両基地において点検が実施されるピットの入り口への計測装置の設置を想定しており，ピット線において，レーザー計測器およびビデオカメラを Fig.

2-1 の通りレール下部に設置することにより鉄道車両の入場時に車輪踏面プロファイル形状の計測と踏面表面欠陥の判定を行うことができる検査手法を提案することである． 本研究で使用するレーザー計測器の有効計測範囲は 300－560mm であり，図に示すようにレーザー計測器と車輪踏面の距離が 300 から 560mm の範囲にある時に踏面形状の計測が可能となる． 車輪全周の計測を行うためには鉄道車両の片側に対して 12 セットの計測器が必要となり，両側の計測を行うには 24 セットの計測器が必要となる．本研究では 1 セットの計測器を用いて計測条件の検証を行うものとする． 画像データを用いた検証時には，ビデオカメラの照明条件や取り付け位置を制限し過ぎるとロバスト性が下がってしまうため，照度条件には制限を加えずに実験を実施した．本計測システムのフローを Fig. 2-2 に示し，実験に用いたシステムの構成を Fig. 2-3 に示す.

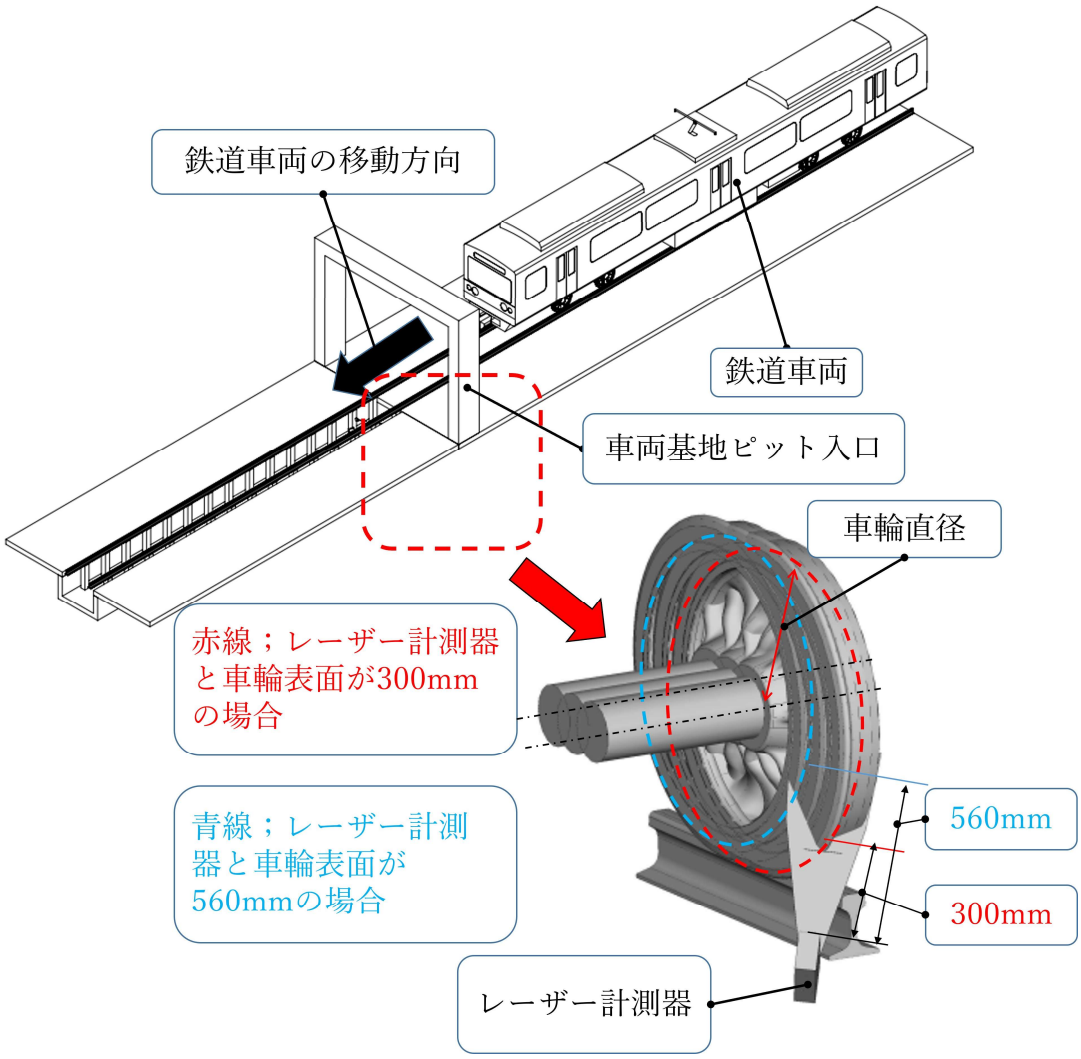
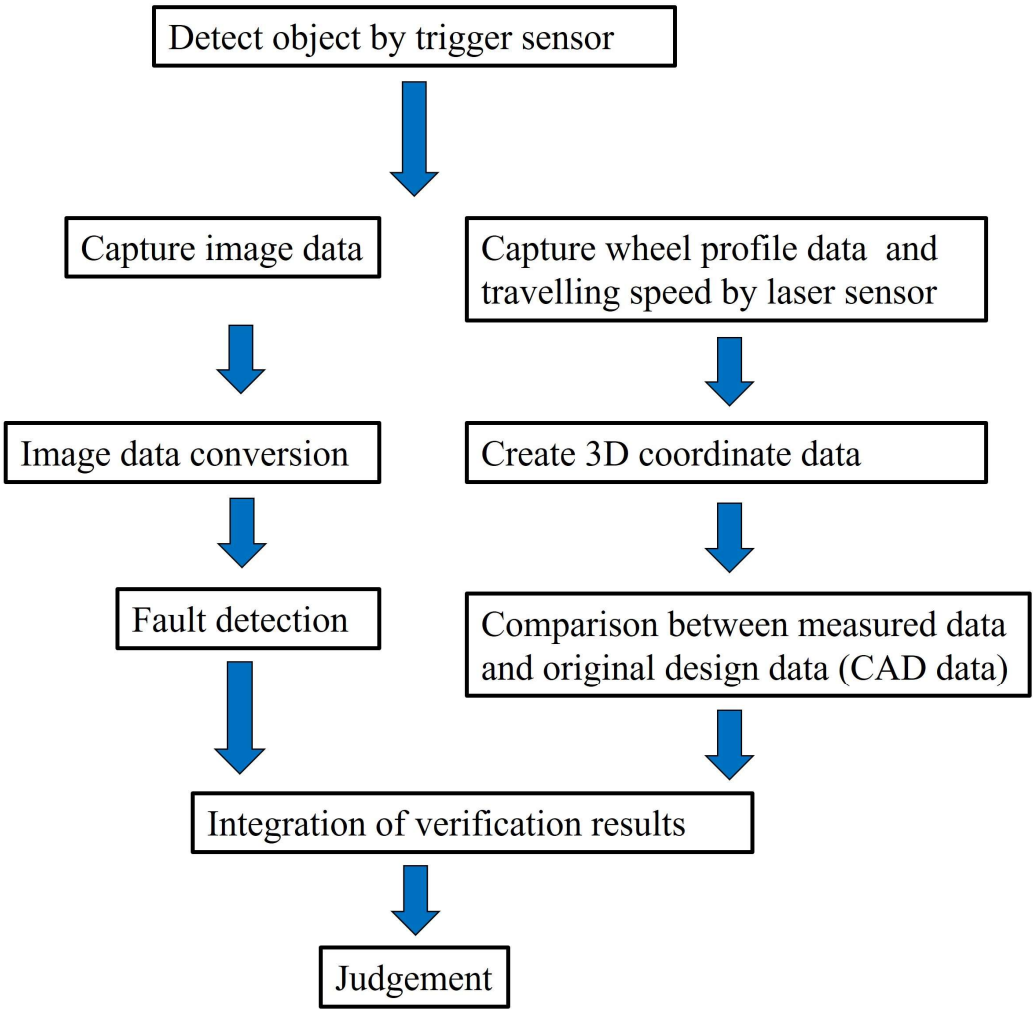



Fig. 2-1　レーザー計測器の車両基地における配置




*判定はレーザープロファイルセンサーとビデオカメラによるエッジ検出結果，AI による欠陥検知の結果を用いて実施される．

Fig. 2-2 自動検査システムフロー

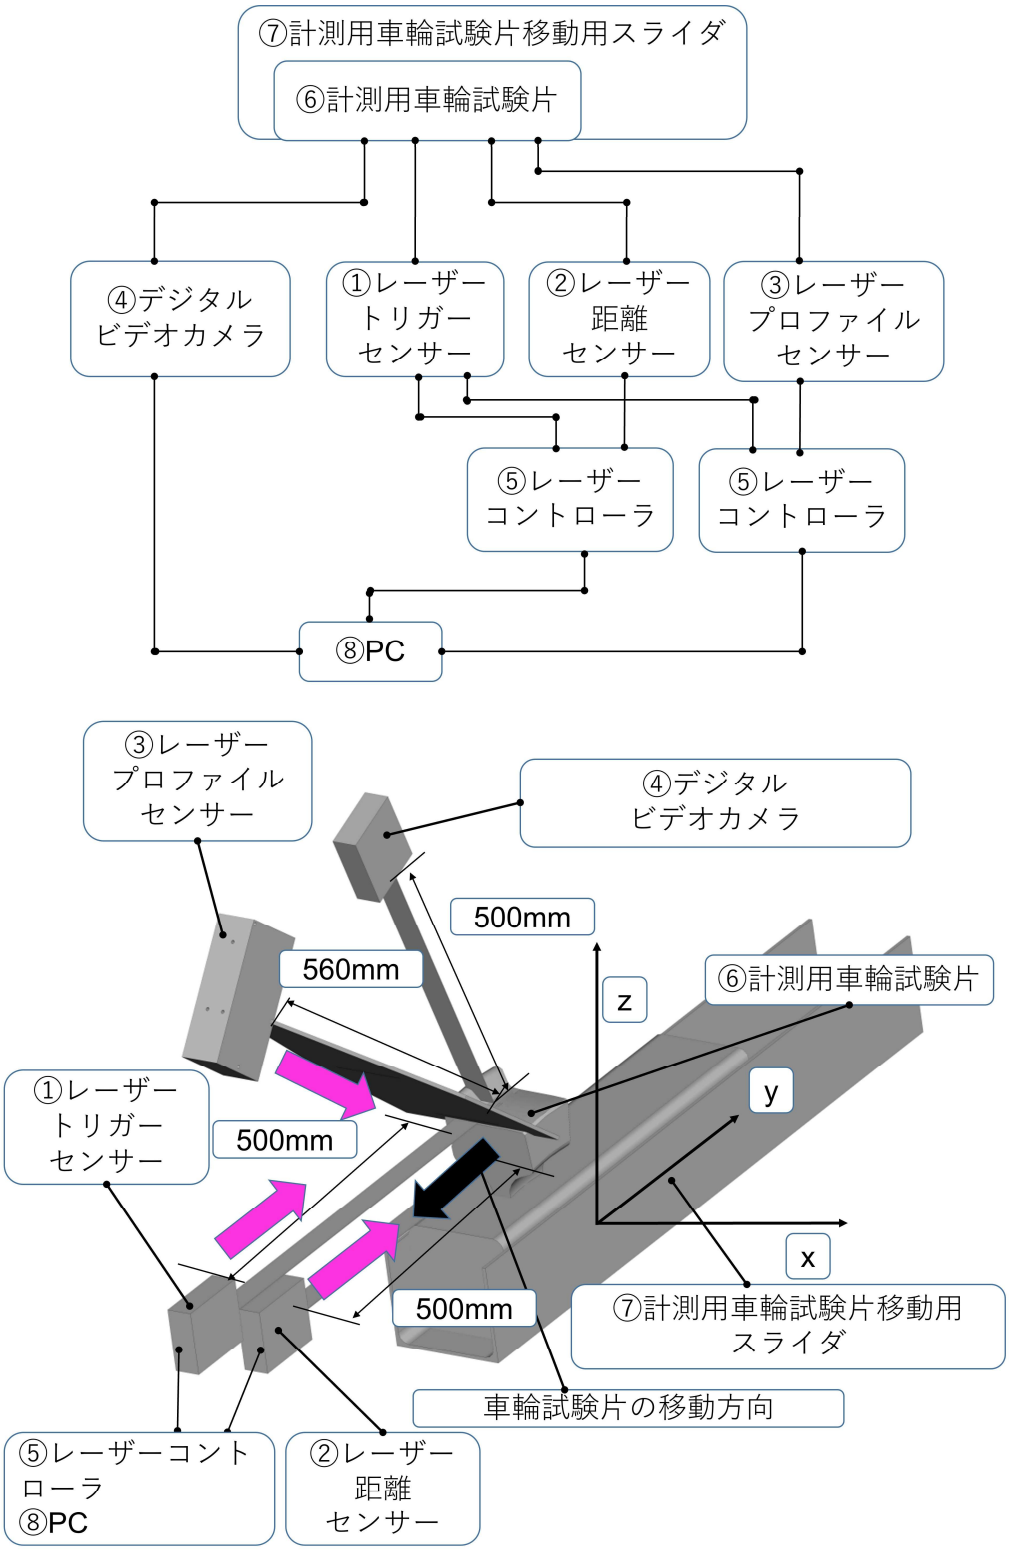



Fig. 2-3 実験機器の接続状態および取り付け状態

実験機器の配置は Fig. 2-3 に示すように床面に上向きに設置された計測用車輪試験片を上側から計測する構成としている． 実験システムは①レーザートリガーセンサー，②レーザー距離センサー，③レーザープロファイルセンサー，④デジタルビデオカメラ，⑤レーザーコントローラ，⑥計測用車輪試験片，⑦計測用車輪試験片移動用スライダ，⑧PC で構成される．それぞれの仕様詳細は Table 2-1 に示される． この実験では材質の異なる 2 種類の計測用車輪試験片を車輪試験片移動用スライダにて移動させて実験を行うことにより車両がピット線を移動する様子を模擬した． 収集されるデータは①車輪踏面の幅方向および②高さ方向の座標データをレーザープロファイルセンサーによって計測し，③試験片移動方向となる座標データをレーザー距離計によって計測する． そしてビデオカメラによって④画像データを取得する． ①，②，③のデータを用いて 3 次元モデルまたはプロファイルの断面形状モデルを作成する． 収集された④の画像のデータは，キャニーエッジ変換やハフ変換などで処理されてエッジ検出が実施される．

Table 2-1 実験に使用した機器

| 機器 | モデル名 | 仕様 |
|---|---|---|
| ① レーザートリガーセンサー | Keyence LR-TB5000 | 検出距離 60－5000mm<br>応答時間（最小） 1ms |
| ② レーザー距離センサー | Keyence LK-G405 | 検知距離 300–500mm<br>分解能 0.001mm |
| ③ レーザープロファイルセンサー | Keyence LJ-X8400 | 検知距離 300–560mm<br>分解能 0.1mm （幅方向）<br>0.001mm （高さ方向） |
| ④ デジタルビデオカメラ | GoPro Hero 8 | 60 frames per second<br>12 Mega pixels （camera mode）<br>4K resolution |
| ⑤ レーザープロファイルセンサーコントローラ | Keyence LJ-X8000A | N/A |
| ⑤ レーザー距離センサーコントローラ | Keyence LK-G3000 | N/A |
| ⑧ PC | Windows 10 PC | Windows 10 Pro （64 bit）<br>Intel Core i5<br>8 GB RAM<br>GPU: NVIDIA GeForce RTX 2070 (8GB)<br>1TB SSD |
| プログラム言語 | Python | Version 3.8.5<br>OpenCV version 4.7.0<br>Numpy version 1.22.4<br>Pytorch version 1.7.1 |
| AI モデル | YOLO | Version 5 |

実験は次のフローで進められる.

ステップ 1; ⑥の計測用車輪試験片を⑦の計測用車輪試験片移動用スライダに固定する.

ステップ 2; ⑦計測用車輪試験片移動用スライダに取り付けられた⑥計測用車輪試験片を⑧の PC より⑦のスライダを操作して①レーザートリガーセンサーに向かって移動させる.

ステップ 3; ①レーザートリガーセンサーと⑥計測用車輪試験片の距離が500mm になったときに①レーザートリガーセンサーが距離を検知してトリガーが入り⑤のレーザーコントローラに信号を送り, ②レーザー距離センサー, ③レーザープロファイルセンサー, ④デジタルビデオカメラによる計測を開始させる.

ステップ 4; ⑤のレーザーコントローラは②レーザー距離センサー, ③レーザープロファイルセンサーを, ⑦の PC は④デジタルビデオカメラをそれぞれ動作させる.

ステップ 5; ⑤レーザーコントローラを通じて②レーザー距離センサー, ③レーザープロファイルセンサー, ④ビデオカメラから得られる計測データを⑧PC に記録する.

ステップ 6; 記録されたデータは Fig. 2-2 に示すフローで処理される.

ステップ 7; ②レーザー距離センサー進行方向の座標情報 y を, ③レーザープロファイルセンサーからは高さ方向の座標情報 z と幅方向の座標情報 x をそれぞれ取得し，2 次元のプロットまたは 3 次元モデルを作成する.

ステップ 8; ④ビデオカメラから得られた画像データは二値化やキャニーエッジ変換，ハフ変換などの加工を行なった後にエッジ検出と AI モデルによる欠陥検知に使用される.

ステップ 9； エッジ検出結果と AI による表面欠陥検知結果を⑧PC に記録する.

ステップ 10； ステップ 7 とステップ 9 の情報を統合し，車両の安全な運行に影響があるような表面欠陥が存在するかどうかを判断する.

## 2.2　表面欠陥を付与した計測用車輪試験片

レーザーセンサーによって計測用車輪試験片を計測した際の測定精度を確認するために, 車輪の実物と同じプロファイル形状を有する計測用車輪試験片を 2 種類準備する．これらは車輪の踏面部分を切り出した形状を有しており，それぞれ計測用車輪試験片-1, 計測用車輪試験片-2 と呼ぶ．計測用車輪試験片-1 の材質はアルミ製で，計測用車輪試験片-2 の材質は鋼製である．Fig. 2-5 に計測用車輪試験片の画像を示す．また Fig. 2-4 には実験で用いた車輪試験片の寸法情報を表す．Fig. 2-4 の上段では車輪試験片の外形図を示し，中段では断面 A-A, B-B の情報をそれぞれ示す．ここでは表面欠陥の幅や深さなどの情報を示している．下段では鳥観図を示し，車両試験片の表面欠陥の位置を記している．この鳥観図に表面欠陥の位置を表すのに用いる座標の原点となる(x, y, z) = (0, 0, 0)の位置が示されている．ここで示される表面欠陥のそれぞれの位置情報を Table 2-2 に示す．計測用車輪試験片には赤色と黒色のマーカーによるマーキングによって厚みのない線状の欠陥を模擬したものを付与している．Fig. 2-4 に示されるように(x，y，z) = (0，0，0）の位置を原点とし，x 方向は車軸の軸に平行な方向，すなわち試験片の幅方向，y 方向はレールに平行な方向つまり試験片の移動方向，そして z 方向は鉛直方向，試験片の高さ方向とする．その座標系にもとづいた欠陥のそれぞれの座標位置と寸法情報を Table 2-2 に示す．このようにして様々な形状をした表面欠陥を付与した計測用車両試験片の計測を行うことにより本研究で提案する手法の有効性を確認する．

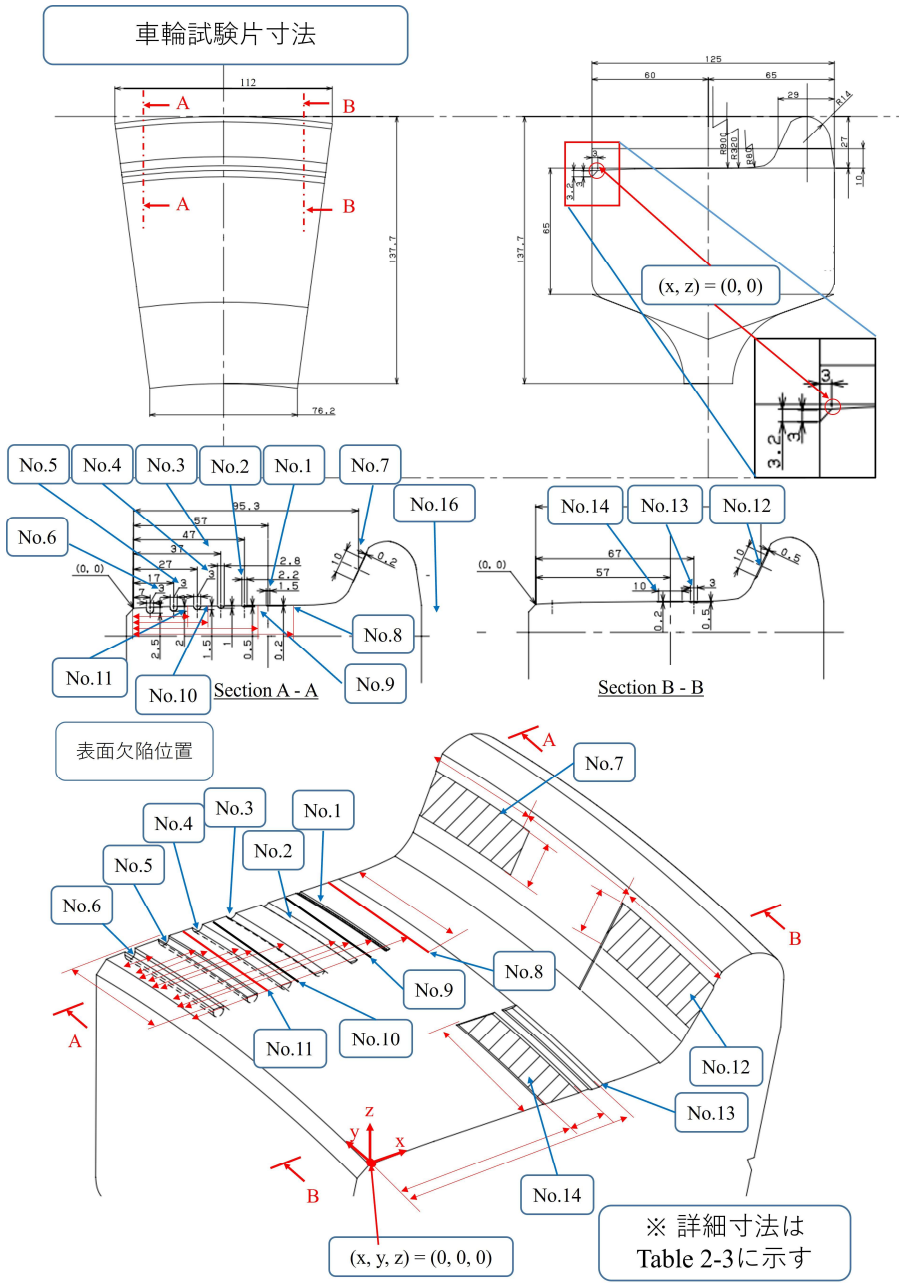



Fig. 2-4 計測用車両試験片-1, -2 の表面欠陥位置

試験片-1;アルミ製, 試験片-2;鋼製

上段；計測用車両試験片の外形図

中段；断面 A-A, B-B での欠陥寸法位置

下段；計測用車輪試験片の鳥観図

Table 2-2 計測用車輪試験片-1,-2 の表面欠陥位置とその寸法
単位 = mm　　材質; 試験片-1；アルミ製, 試験片-2；鋼製

| No | 欠陥の種類 | 位置（中心位置） | | | 欠陥の寸法 | | |
|---|---|---|---|---|---|---|---|
| | | x | y | z | 長さ | 幅 | 深さ |
| 1 | 深い傷 | 57 | 70 | 1.2 | 35 | 1.5 | 0.2 |
| 2 | 深い傷 | 47 | 70 | 1.1 | 35 | 2.2 | 0.5 |
| 3 | 深い傷 | 37 | 70 | 1.0 | 35 | 2.8 | 1.0 |
| 4 | 深い傷 | 27 | 70 | 0.9 | 35 | 3 | 1.5 |
| 5 | 深い傷 | 17 | 70 | 0.8 | 35 | 3 | 2.0 |
| 6 | 深い傷 | 7 | 70 | 0.4 | 35 | 3 | 2.5 |
| 7 | フランジ摩耗 | 95.3 | 70 | 16.3 | 35 | 10 | 0.2 |
| 8 | マーキング（赤） | 65 | 60 | 1.1 | 45 | 5 | 0 |
| 9 | マーキング（黒） | 52 | 70 | 1.0 | 35 | 3 | 0 |
| 10 | マーキング（黒） | 32 | 70 | 0.9 | 35 | 3 | 0 |
| 11 | マーキング（赤） | 22 | 68 | 0.8 | 37 | 3 | 0 |
| 12 | フランジ摩耗 | 95.3 | 0 | 16.3 | 35 | 12 | 0.5 |
| 13 | 踏面摩耗 | 67 | 0 | 1.3 | 35 | 3 | 0.5 |
| 14 | 踏面摩耗 | 57 | 0 | 1.2 | 35 | 10 | 0.2 |

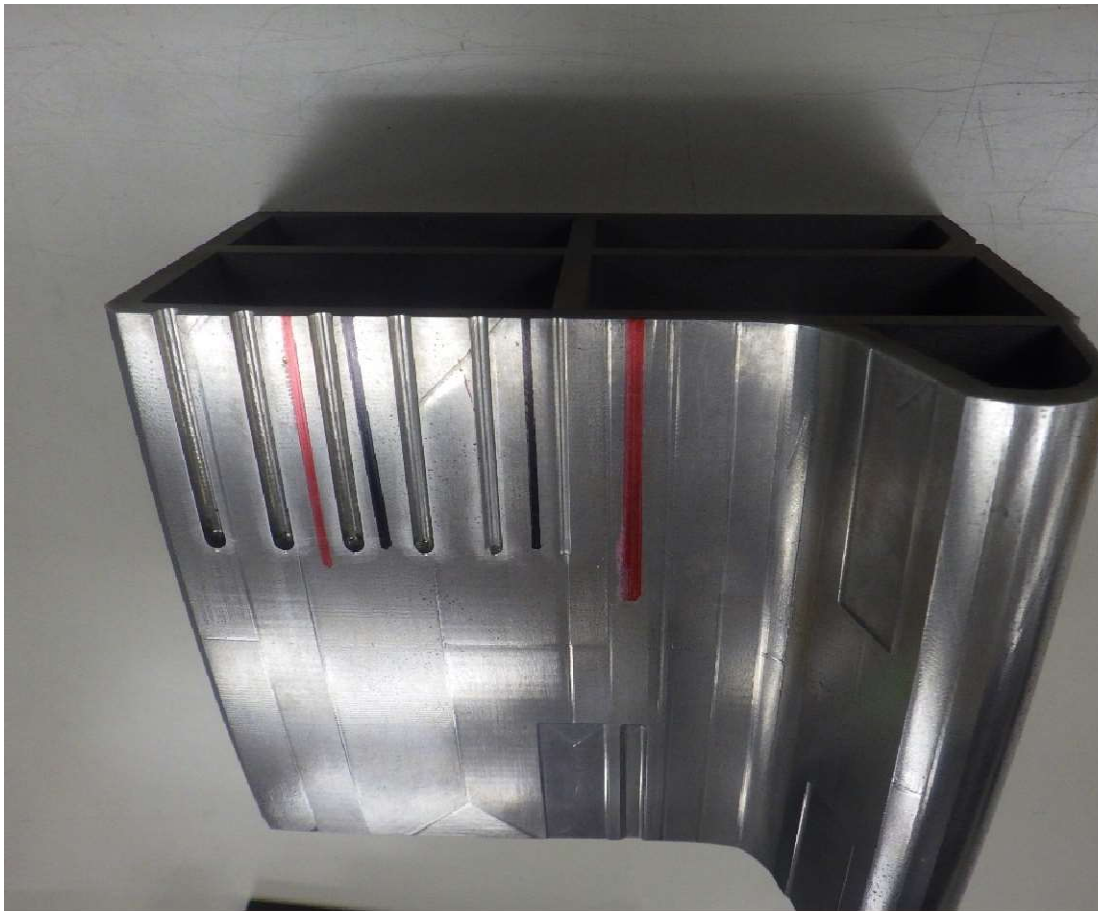


Fig. 2-5 計測用車輪試験片-1, -2 画像

## 2.3　レーザープロファイルセンサーによる踏面プロファイル計測

2.1 節で述べた計測ステップに従って計測を行う．レーザー距離センサーとレーザープロファイルセンサーの計測周波数を同じに設定することで計測タイミングを一致させ，対象物の長さつまり移動方向（y 方向），幅方向（x 方向），および高さ方向（z 方向）のそれぞれの寸法を計測する．計測用車輪試験片の移動速度は計測用車輪試験片移動用スライダの制御ソフトによって変更可能であり，スライダにより移動可能な速度は実際には 3～13km/h となるが，本実験では日本における鉄道車両基地内でピットへ入る際に想定される移動速度である 5～7.3km/h と想定した．レーザー距離計によって得られる距離情報から対象物の移動速度を$v$とすると，この値は式（2-1）で求めることができる．

$$v = L / t \tag{2-1}$$

ここで，$t$を計測周期，$L$を試験片の移動距離とする．計算例として計測周期 $t_1$ = 0.0001 秒で，その間の移動距離 $L_1$ = 0.1mm の時，移動速度 $v_1$ は計算式（2-2）で計算される．

$$v_1 = 0.1 / 0.0001 = 1000\text{mm/s} \quad (= 3.6\text{km/h}) \tag{2-2}$$

レーザープロファイルセンサーでは対象物の幅方向（x 方向），および高さ方向（z 方向）の寸法を計測する．レーザー距離センサーでは対象物の長さ（y 方向）の寸法を計測して 3 次元モデルを作成するために必要な情報を記録する．この x，y，z のそれぞれの座標情報から，オリジナル CAD データと計測結果で

の各断面の情報を比較することや 3 次元モデルを表示しての視覚的比較が可能となる． ステップ 7 で述べたようにレーザー距離センサーより進行方向の座標情報 y を, レーザープロファイルセンサーにて高さ方向座標 z と幅方向座標 x を取得し，それらの値を csv データとしてリスト化する．

## 2.4 エッジ検出を用いた画像データからの欠陥検知

取得された画像データに以下の操作を行い，キャニーエッジ検出, ハフ変換, の処理によりエッジ検出を行う．

画像処理プロセス Fig. 2-6 に示す．プロセスは以下のステップで処理される．

ステップ 1: 画像データはビデオデータから抽出され，抽出された画像データ内の各ピクセル$I(a,\ b)$からそれぞれのRGB（赤，緑，青）値を得る．

$$\{Red(a,\ b),\ Green(a,\ b),\ Blue(a,\ b)\} = I(a,\ b) \qquad (2\text{-}3)$$

ステップ 2: 各ピクセル$I(a,\ b)$のRGB値をグレースケールデータ$Gray(a,\ b)$に式（2-4）を用いて変換する．

$$Gray(a,\ b) = 0.299 \times Red(a,\ b) + 0.587 \times Greeen(a,\ b) + 0.144 \times Blue(a,\ b) \qquad (2\text{-}4)$$

ここで変数 $Red(a,\ b)$, $Green(a,\ b)$, $Blue\ (a,\ b)$ はそれぞれ各ピクセルでの赤, 緑，青の値となる．

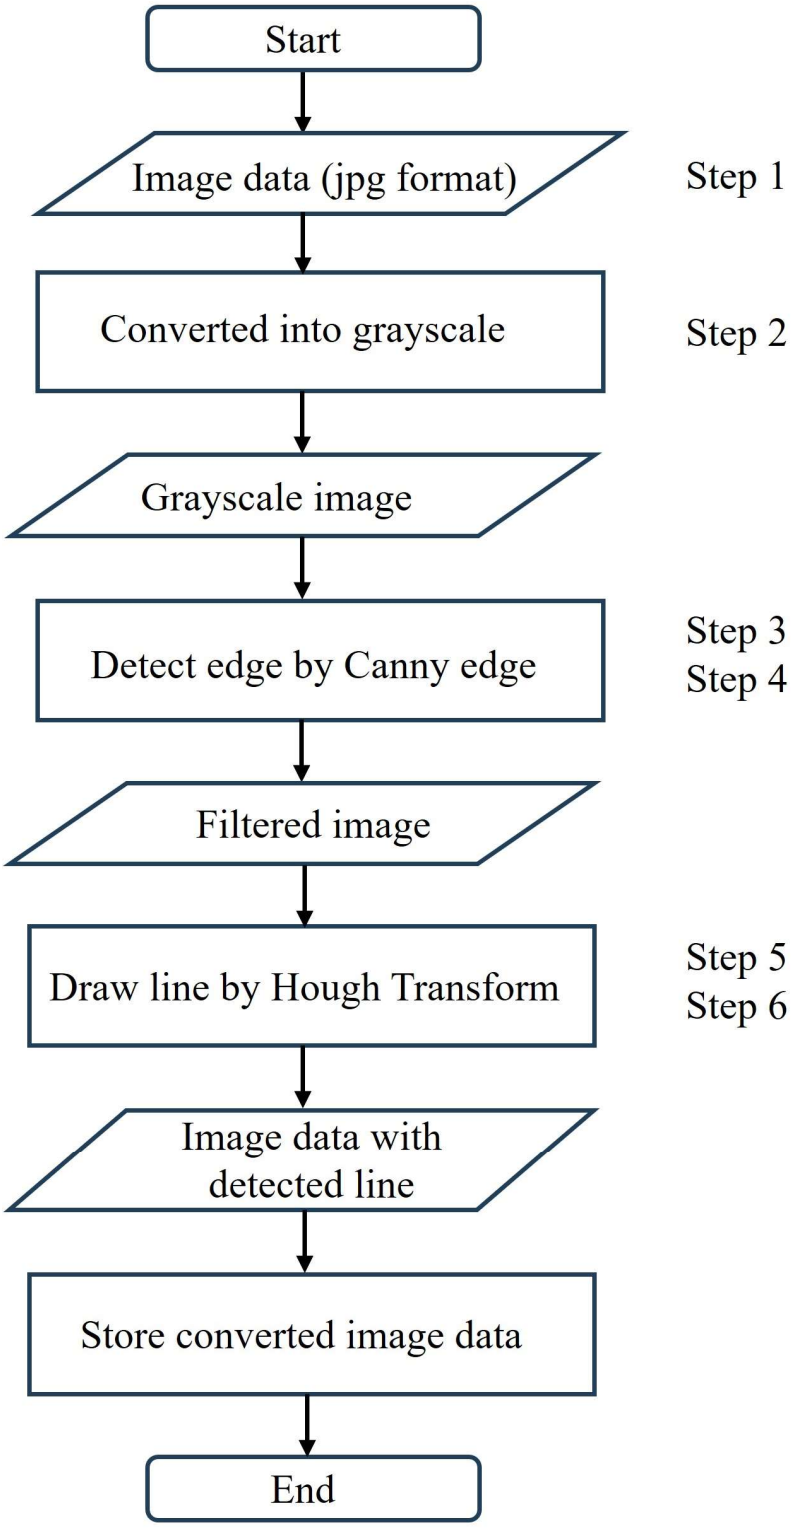



Fig. 2-6 画像処理のプロセス

ステップ 3: 画像に式（2-5）のガウシアンフィルターを適用してノイズを除去し，画像を滑らかにする.

$$G(a,\ \ b) = \frac{1}{2\pi\sigma^2} \times e^{-\left(a^2+b^2\right)/2\sigma^2} \tag{2-5}$$

ここで，$G(a,\ b)$はピクセル $I(a,\ b)$におけるガウスカーネルとなり，$\sigma$はガウス分布の標準偏差となる.

ステップ 4: ソーベル演算子を適用して，平滑化されたイメージの勾配の大きさと向きを計算して変換を行う．ソーベル演算子は，$a$ 方向と $b$ 方向それぞれについての 1 次導関数を決定し，対応する勾配の方向を決定する．ソーベル演算子の計算式は式（2-6）および（2-7）で表される.

$$Ga = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \tag{2-6}$$

$$Gb = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \tag{2-7}$$

ここで，$Ga$ と $Gb$ は，それぞれソーベル演算子の $a$ 成分と $b$ 成分となる.

ステップ 5: グラデーションの境界を削除し，その局所的な最大値のみを維持するために，その大きさには最大値以外の抑制を適用する.

ステップ 6: 間引きされたエッジイメージにヒステリシスのしきい値を適用して，弱いエッジを除去し，強いエッジを保持させる.

ハフ変換は, 画像内の線や円などの幾何学的形状を検出するために使用されるマシンビジョンアプローチであり, ハフ変換によって線を特定する式を式(2-8)に示す.

$$\rho = a\cos\theta + b\sin\theta \tag{2-8}$$

ここで，$\rho$ は原点(0，0)から垂直軸に沿った線までの距離，$\theta$ は線と水平軸の間の角度となる． この式は, 画像空間の各点($a$, $b$)をハフ空間の正弦曲線にマッピングする． ハフ空間におけるこれらの曲線の交点は，元のイメージで検出された線のパラメータ($\rho$, $\theta$)に対応する． 画像に示されている線分は，前述の方法を使用して取得される.

## 2.5　表面欠陥判定用 AI モデルの作成

本研究では，AI モデルの作成に YOLOv5 を使用する． YOLOv5 は，2020 年にリリースされた YOLO シリーズの 5 番目のバージョンであり，これまでのシリーズよりもハイパーパラメーターの最適化，一般的なファイル形式へのエクスポートが可能となる自動エクスポートなどの新機能が追加されてモデルのパフォーマンスが向上している． YOLOv5 のメカニズムを Fig. 2-7 に示す．YOLOv5 はビデオファイルを含む画像データ内にある複数の物体をリアルタイムで高速かつ正確に検出し，その検出結果を画像データに記録できる物体検出アルゴリズムである． YOLOv5 の機能は，画像を固定されたサイズのグリッドセルにそれぞれ分割し，各グリッドセル内の複数の境界ボックスとクラスの予測を生成する． YOLOv5 は，画像全体を一度に処理することで，シーンの全体像を把握し，高速かつ同時に物体を検出することができる． 速度と精度のバランスをとる YOLOv5 のアルゴリズムは，リアルタイムの物体検出が重要な自動運転車や監視などのアプリケーションでよく使用されている． 高速かつ正確に物体を検出できる YOLOv5 の特性から, 本研究では YOLOv5 を採用している．本研究で AI モデル作成に用いた YOLOv5 のファイルは公開サイトである github (https://github.com/ultralytics/yolov5)からダウンロードしたものを使用している．また転移学習には，このサイトよりダウンロードした yolov5n.yaml のファイルを用いている．

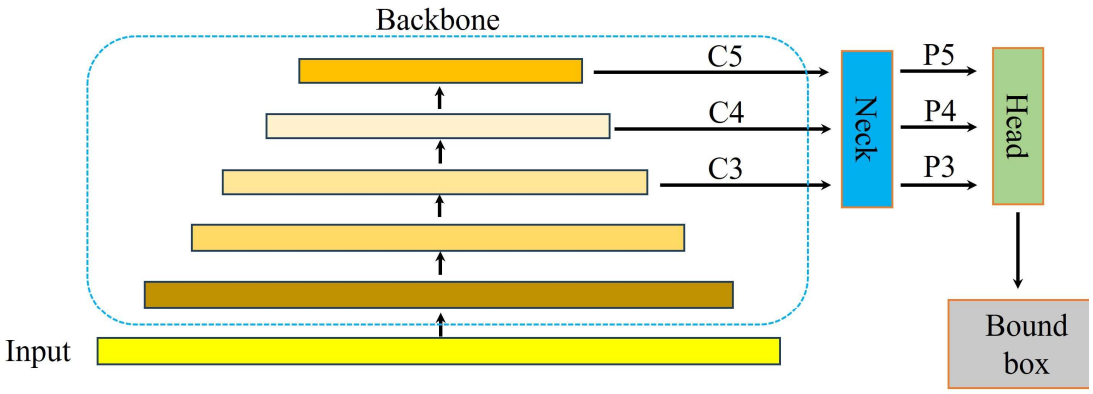



Fig. 2-7 YOLOv5 のメカニズム

### 2.5.1 実車輪の表面欠陥からの AI モデル作成

実物の車輪の表面欠陥検知のための AI モデルの作成について述べる． 実物の車輪に発生する表面欠陥としては，剥離についてのみは AI モデルを作成するのに十分な量の表面欠陥を含む画像データを収集することができている． 本研究の研究成果として実際の車輪表面に発生する欠陥の検知可否の確認は非常に重要であるため，実車輪への適用可否判断のためにも AI モデルを作成して検知実験を行った． なお，本項で用いる画像については実車両で発生した表面欠陥の調査のために収集された画像を用いており，本論文で提案されるシステムにて撮影された画像ではない． 収集された画像から AI モデルを作成し判定を実施する． 実車輪より収集した表面欠陥の画像を Fig. 2-8 に示す． 車輪表面の欠陥を検出する AI モデルを作成するために，実際の鉄道車両の車輪表面の欠陥画像 1024 枚をデータセットとして準備した． 1024 枚の画像を準備するために，データオーグメンテーション（データ拡張）が実施される． データオーグメンテーション前にはオリジナルのデータセットとしては 128 枚の画像を準備し，それぞれトレーニングデータセットに 96 枚, バリデーションデータセットに 16 枚，テストデータセットに 16 枚の画像に分割し，これらのデータを水平方向への反転，垂直方向の反転，回転や輝度補正，コントラスト調整といった方法を複合して実施することで拡張される． Fig. 2-9 にデータオーグメンテーションの例を示す． このようにしてデータオーグメンテーションを実施してデータ数を 128 から 1024 へと 8 倍に拡張させて機械学習を行い，AI モデルの作成を行う．




Fig. 2-8 実車輪より取得した表面欠陥画像（剥離）

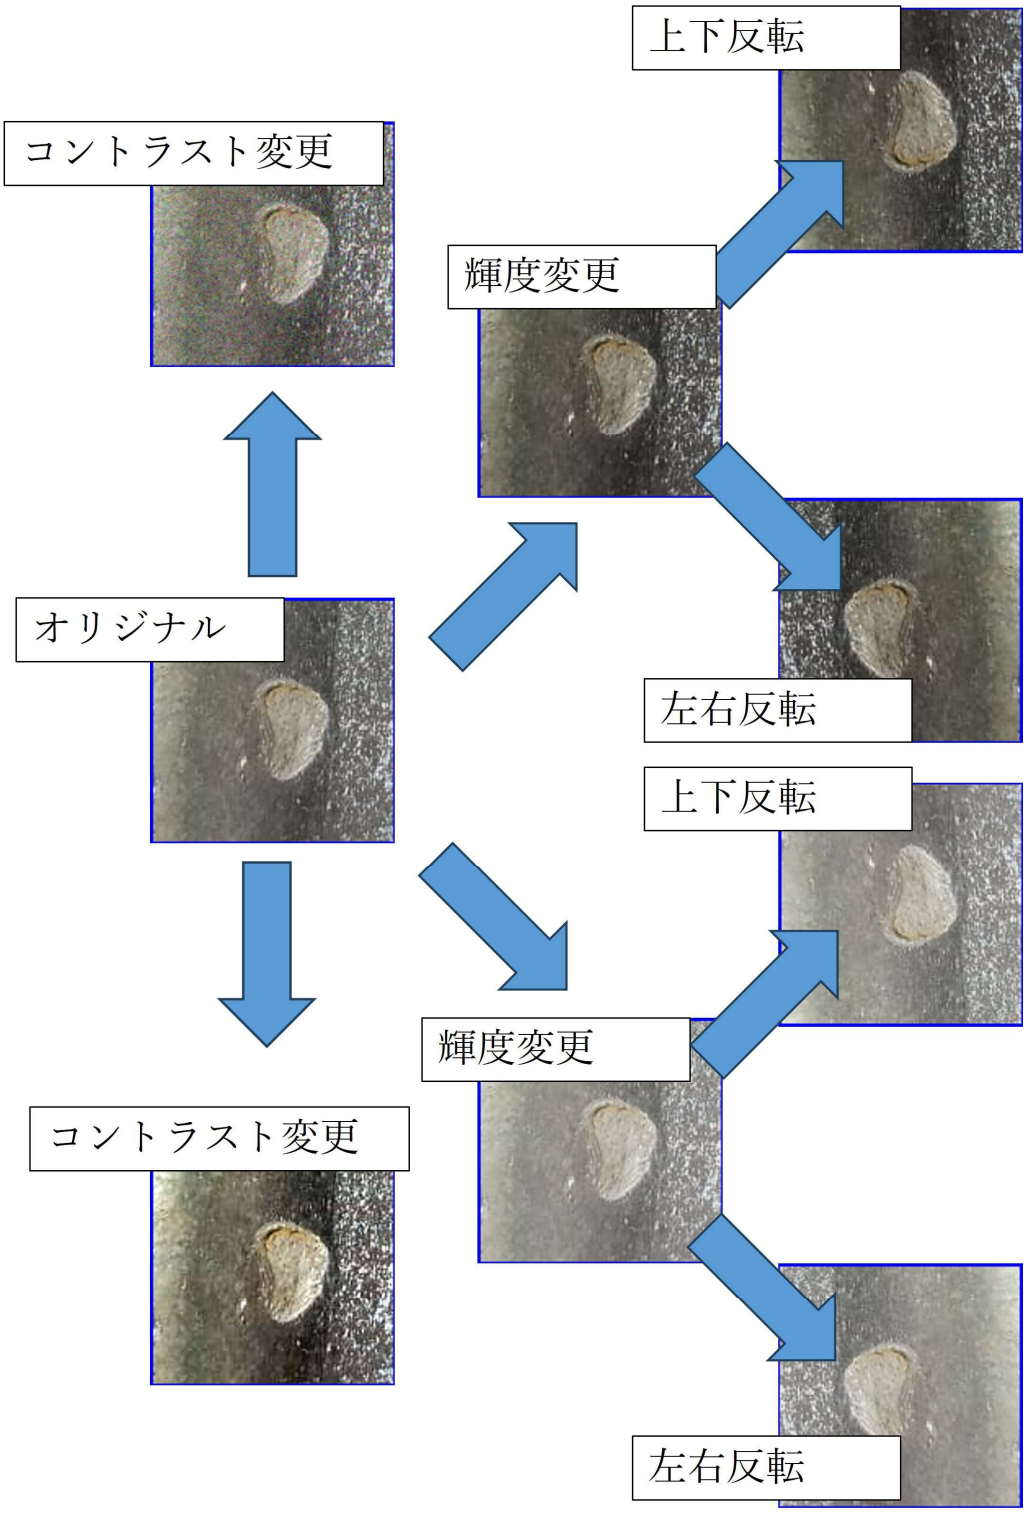



Fig. 2-9 データ拡張（実車輪）

データオーグメンテーションを用いて準備した機械学習用の画像データは，1024 枚の 640 × 480 ピクセルの画像で構成され，それらの画像データは，データリーケージを防ぐためにトレーニングデータセット（75%，768 枚），バリデーションデータセット (12.5%, 128 画像), およびテストデータセット (12.5%, 128 画像）に分割される． Table 2-3 にそれらの分割を示す.

次に”labelImg”ツール（https://github.com/HumanSignal/labelImg）を用いて AI の学習に用いるアノテーションを実施する． 事前学習済みモデル YOLOv5 は，車輪の表面欠陥の機械学習モデルを作成するための出発点として使用されている.

このようにして作成した学習データによる機械学習の結果は，Precision が 95.28%，Recall が 85.96%，そして mean average precision（mAP50）は 97.90% であった． モデル学習結果（Precision， Recall， mean average precision)を Table 2-4 に，AI モデルの学習結果を Fig. 2-10 にそれぞれ示す． Fig. 2-10 の上段では学習に用いたデータの例を，中段では学習途中の状態を，下段では学習の結果による欠陥判定の状態をそれぞれ示す． 先行研究における検出結果では Krummenacher[46]らは Flat spot については Precision が 89±4%，Recall が 86±6%であり，Shelling については Precision が 92±3%，Recall が 93±3%であり，Zhang[50]らの結果では Precision が 88.8%，Recall が 92.0%であった．これらの研究結果と比較して，本研究の Precision は高くなっており優位性が認められる.

Table 2-3 機械学習に用いた画像の分類(実車輪)

| Defect Type | Number of images | | | |
|---|---|---|---|---|
| | Training | Validation | Test | Total |
| Defect | 768<br>(75%) | 128<br>(12.5%) | 128<br>(12.5%) | 1024 |

Table 2-4 AI モデル学習結果(実車輪)

| 欠陥種類 | Precision | Recall | mAP50 |
|---|---|---|---|
| 剥離 | 0.9528 | 0.8596 | 0.9790 |

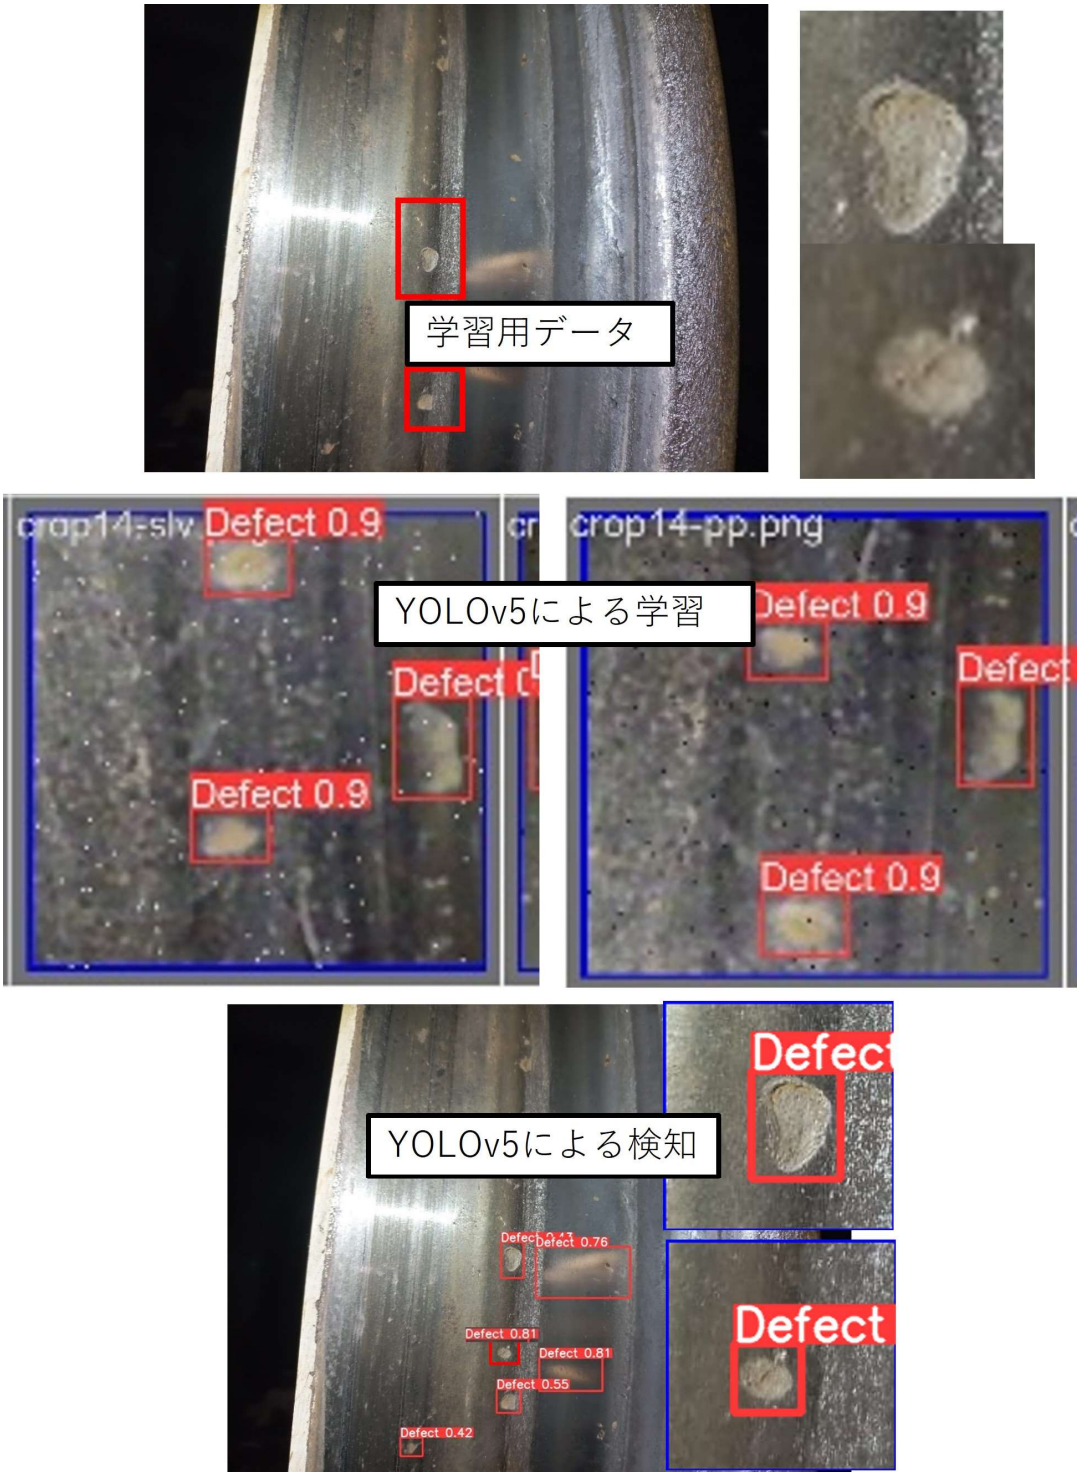



Fig. 2-10 YOLO モデル学習結果（実車輪）

## 2.6　計測結果

本章ではレーザー計測とエッジ検出および実車輪の表面欠陥を学習したAIを用いた表面欠陥検出手法の判定結果について述べる.

### 2.6.1　踏面プロファイル計測結果

レーザー計測器による車輪踏面プロファイル計測結果を Table 2-5 に示す. スライドレールによって設定可能な速度は 3.0～13.0km/h であるが, 鉄道車両が留置される車両基地内での移動速度は営業中の走行速度よりも抑えられたものとなり, 特に本検査装置が設置されると想定されているピット線への車両の侵入速度は約5km/h程度のため, 移動速度は最大でもその約1.5倍となる7.3km/hとして, 計測用車輪試験片の移動に用いるスライダレールの設定値を 5.0km/h と 7.3km/h に設定して計測を行った. Table 2-5 の左の表は設計上の 3 次元座標を示す. 中の表は移動速度が 5.0km/h の際の計測結果を示す. 右の表は移動速度が 7.3km/h での計測結果を示す.

本実験でのレーザー計測器の分解能はTable 2-1に示すようにx方向が0.1mm, y 方向が 0.001mm, z 方向が 0.001mm であった. 従来の手動による計測では計測精度が 0.5mm 程度であったので, 目標としては欠陥の深さ方向となる z 方向で 0.1mm の精度が達成できることが望ましい. この表では Fig. 2-2 に示した実験装置を用いて計測用車輪試験片を 5 .0km/h と 7.3km/h でそれぞれ動かして計測を行った結果を示している. このような低速での移動の場合には試験片-1, 試験片-2 ともに速度の差による計測結果の差は 0.100mm 以下であり, 差がほとんど見られない結果となった.

Table 2-5 車輪踏面プロファイル計測結果（試験片-1）(単位 = mm)
下の表で左は設計上の 3 次元寸法を示す．中および右の表はそれぞれ移動速度が 5.0km/h および 7.3km/h の計測を示す． *座標 x，y，z の向きは Fig. 2-4 と一致する．

| Original (Design) | | | | $v$ = 5.0km/h | | | | $v$ = 7.3km/h | | |
|---|---|---|---|---|---|---|---|---|---|---|
| x | y | z | | x | y | z | | x | y | z |
| 0.100 | 0.000 | 27.00 | | 0.100 | 0.000 | 27.00 | | 0.100 | 0.000 | 27.00 |
| 0.100 | 0.100 | 27.71 | | 0.100 | 0.100 | 27.71 | | 0.100 | 0.100 | 27.70 |
| 0.100 | 0.200 | 28.41 | | 0.100 | 0.200 | 28.37 | | 0.100 | 0.200 | 28.41 |
| | | | | | | | | | | |
| 0.100 | 14.00 | 54.00 | | 0.100 | 14.00 | 53.98 | | 0.100 | 14.00 | 54.01 |
| 0.100 | 14.10 | 53.97 | | 0.100 | 14.10 | 53.99 | | 0.100 | 14.10 | 53.97 |
| 0.100 | 14.20 | 53.93 | | 0.100 | 14.20 | 53.96 | | 0.100 | 14.20 | 53.93 |
| | | | | | | | | | | |
| 0.100 | 65.00 | 27.00 | | 0.100 | 65.00 | 27.09 | | 0.100 | 65.00 | 27.06 |
| 0.100 | 65.10 | 27.03 | | 0.100 | 65.10 | 27.11 | | 0.100 | 65.10 | 27.00 |
| 0.100 | 65.20 | 27.06 | | 0.100 | 65.20 | 27.12 | | 0.100 | 65.20 | 27.05 |
| | | | | | | | | | | |
| 0.100 | 120.0 | 25.92 | | 0.100 | 120.0 | 25.95 | | 0.100 | 120.0 | 25.94 |
| 0.100 | 120.1 | 25.91 | | 0.100 | 120.1 | 25.94 | | 0.100 | 120.1 | 25.93 |
| 0.100 | 120.2 | 25.91 | | 0.100 | 120.2 | 25.94 | | 0.100 | 120.2 | 25.93 |

計測結果を図示するために計測結果を 2 次元グラフ，3 次元グラフにそれぞれプロットしたものを Fig. 2-11 に示す． Fig. 2-11 の上側のプロファイルは 7.3km/h で走行した際の試験片-2 の形状計測結果を示したものである，図中の青色部分が計測結果で，赤色部分がオリジナルのモデル形状となる． Fig. 2-11 の中段の図は断面 A-A の部分をプロファイルを示したものである．どちらの図を見ても大きな差がないことが分かる．下側はそれぞれ 3.0，5.0，7.3，10.0，13.0km/h で移動した際の計測結果とオリジナルの断面形状を重ねたものであり，大きな差がないことがわかる．スライダにより調整可能な移動速度は 3～13km/h となるが，鉄道車両が留置される車両基地内での移動速度は営業中の走行速度よりもかなり抑えられたものとなり，特に本検査装置が設置されると想定されているピット線での車両の走行速度は約 5km/h 程度である．本実験では計測用車輪試験片の移動に用いるスライダレールの設定値を標準速度とした 5.0km/h と，その約 1.5 倍となる 7.3km/h に設定して計測を行った．

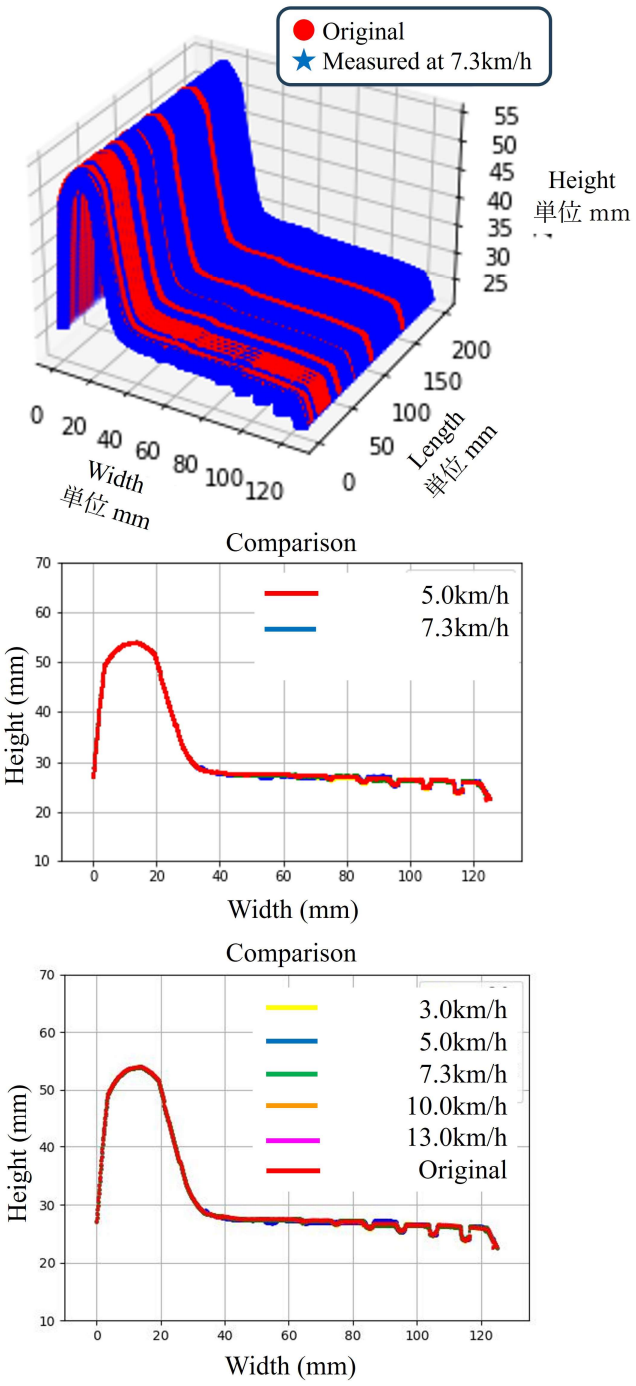



Fig. 2-11 踏面プロファイル計測結果（試験片-2）（計測速度 5.0km/h, 7.3km/h）
上段: 3 次元プロット図, 中段: 断面図(5.0km/h, 7.3km/h), 下段: 3.0km/h から 13.0km/h までの速度での計測結果

Table 2-6 に各表面欠陥部分の計測結果を示す． y は幅方向，z は高さ方向とする．（Fig. 2-4 と同様）Table 2-6 に示される左側の表はオリジナルの CAD データの寸法を示し，中央はアルミ製の試験片-1 を 7.3km/h で移動させた際の計測結果であり，右側の表は鋼製の試験片-2 を 7.3km/h で移動させた際の計測結果となる． 試験片-1，試験片-2 の計測結果は 55 回の測定結果の平均であり，幅方向の標準偏差が 0.1 で深さ方向の標準偏差は 0.05 となった． 標準偏差を計算する際に計測データの中から精度の低い 5 つのデータと精度の高い 5 つのデータを除外した． 5 つの高いデータと低いデータのそれぞれを除外する理由は，最終の比較結果に与えられる外れ値の影響を減らし，データの分散をより確実に測定できるようにするためである．

本実験でのレーザー計測器の分解能は Table 2-1 に示すように x 方向が 0.1mm, y 方向が 0.001mm, z 方向が 0.001mm であった． 従来の手動による計測では計測精度が 0.5mm 程度であったので，目標としては z 方向で 0.1mm の精度が達成できることが望ましい． この表では Fig. 2-2 に示した実験装置を用いて計測用車輪試験片を 7.3km/h で動かして計測を行った結果を示している． このような低速での移動の場合には試験片-1，試験片-2 ともに速度の差による計測結果の差は 0.080mm 以下であり，差がほとんど見られない結果となった． このように手動計測よりも高い精度での計測が実施できており，先行研究における結果と比較しても，Li[35]らの結果が直径方向で 0.5mm の精度であり，幅方向に 0.2mm の精度であり, Torabi[44]らの計測でも直径方向において 0.245mm の精度であったことから，本研究での提案手法によって高精度な計測が実現できており優位性がある．

Table 2-6 試験片-1，試験片-2 の表面欠陥計測結果（単位 = mm）
左: オリジナル設計寸法値
中: 試験片- 1 (アルミ製);計測時の移動速度=7.3km/h
右: 試験片-2(鋼製);計測時の移動速度=7.3km/h

| 欠陥 | 幅 (y) | 深さ (z) | | 欠陥 | 幅 (y) | 深さ (z) | | 欠陥 | 幅 (y) | 深さ (z) |
|---|---|---|---|---|---|---|---|---|---|---|
| No. 1 | 1.50 | 0.20 | | No. 1 | 2.20 | 0.31 | | No. 1 | 2.00 | 0.28 |
| No. 2 | 2.20 | 0.50 | | No. 2 | 2.50 | 0.53 | | No. 2 | 2.70 | 0.53 |
| No. 3 | 2.80 | 1.00 | | No. 3 | 2.70 | 1.03 | | No. 3 | 3.20 | 1.04 |
| No. 4 | 3.00 | 1.50 | | No. 4 | 2.90 | 1.55 | | No. 4 | 3.20 | 1.47 |
| No. 5 | 3.00 | 2.00 | | No. 5 | 3.30 | 2.05 | | No. 5 | 3.00 | 1.99 |
| No. 6 | 3.00 | 2.50 | | No. 6 | 2.90 | 2.49 | | No. 6 | 3.10 | 2.53 |
| オリジナル CAD データ | | | | 試験片-1 $v$ = 7.3km/h | | | | 試験片-2 $v$ = 7.3km/h | | |

### 2.6.2 エッジ検出による判定結果

マシンビジョンによるエッジ検出の結果を Fig. 2-12 に示す. エッジ要素検出時には線状の欠陥は深さに関わらず線要素が検知されていることがわかる. ここに示されるように直線状の表面欠陥であればエッジ検出によって十分検出することができている. エッジ検出の特徴としては深さが無くても線状の特徴があれば検出が可能となることである. 本研究では汚れや錆を模擬した深さのない線状のマーキングと線状の深さのあるキズを車輪プロファイル試験片に付与したものを撮影した画像に対してエッジ検出を行っており, エッジ検出によってそれらが検出できていることが分かる. またエッジ検出では深さがないものでも検知ができていることが分かる.

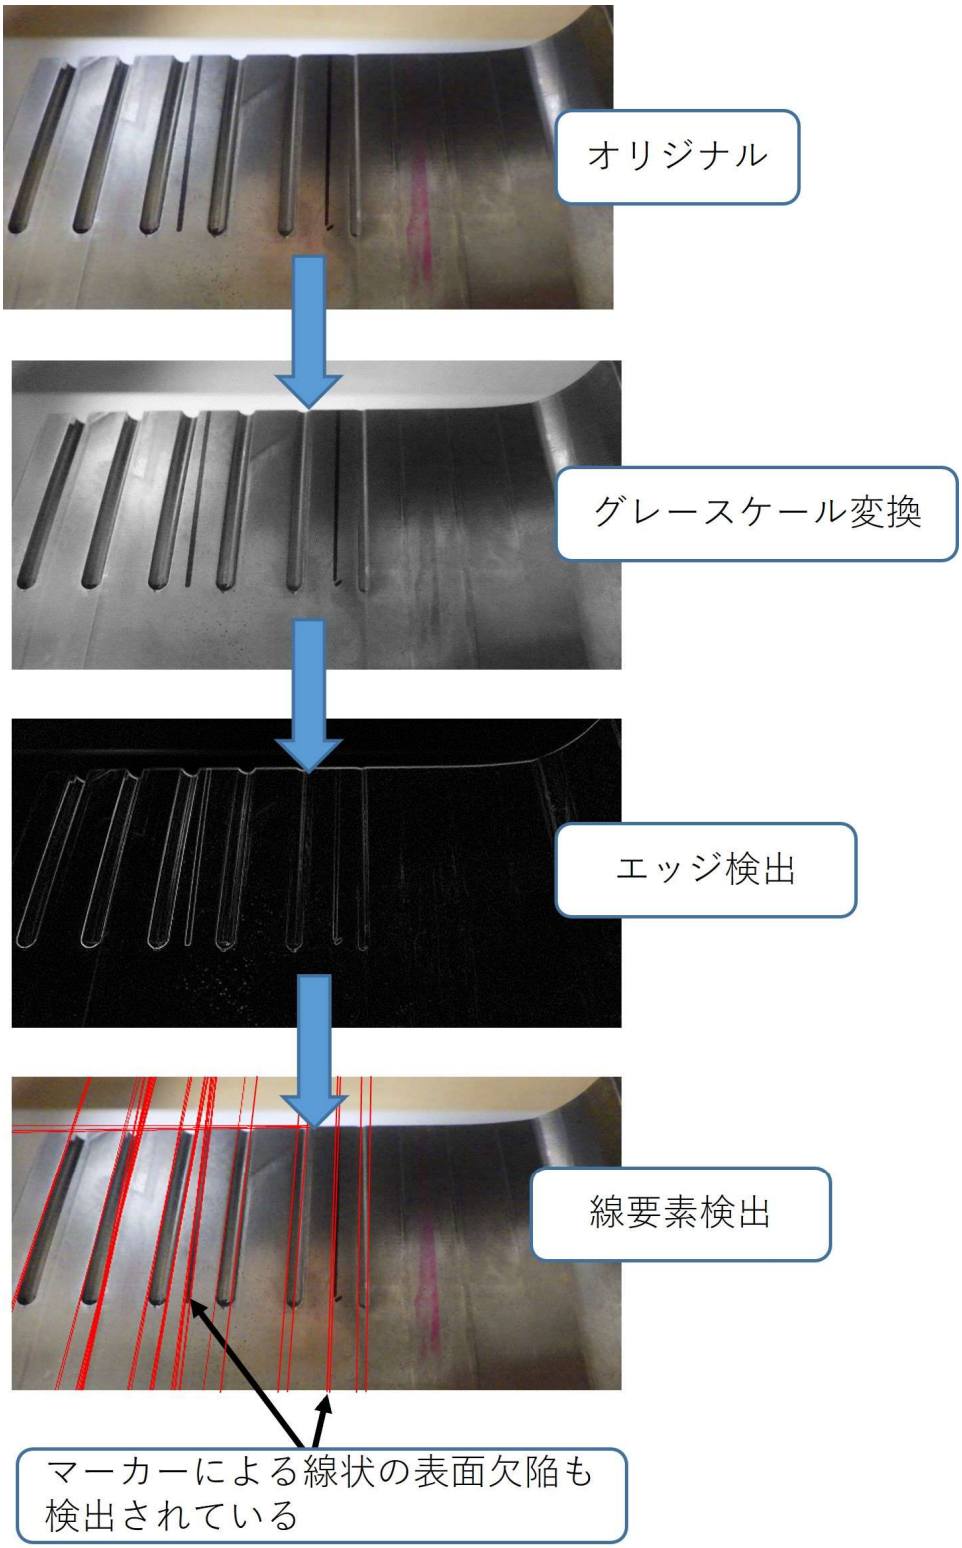



Fig. 2-12 エッジ検出による表面欠陥検出結果

### 2.6.3 実車輪に発生した表面欠陥の AI モデルによる判定結果

実車輪の踏面表面に発生した表面欠陥の画像から収集したイメージデータを用いて AI による物体検知の判定を行った．実車輪に発生する様々な表面欠陥の中でも，実車輪の表面欠陥判定の AI モデルを作成するのに十分な量の画像が収集できた欠陥は剥離についてのみであった．AI の物体検知精度を向上させるために, データオーグメンテーションを用いて機械学習に用いる画像数を増やすことにより, Fig. 2-13 に示すように剥離の検知が可能となる AI モデルを作成することができた．これらの剥離欠陥は剥離の深さが 0.1mm 程度のものであったためレーザー計測器では検知ができないものであり，マシンビジョンを用いないと計測ができないものであった．

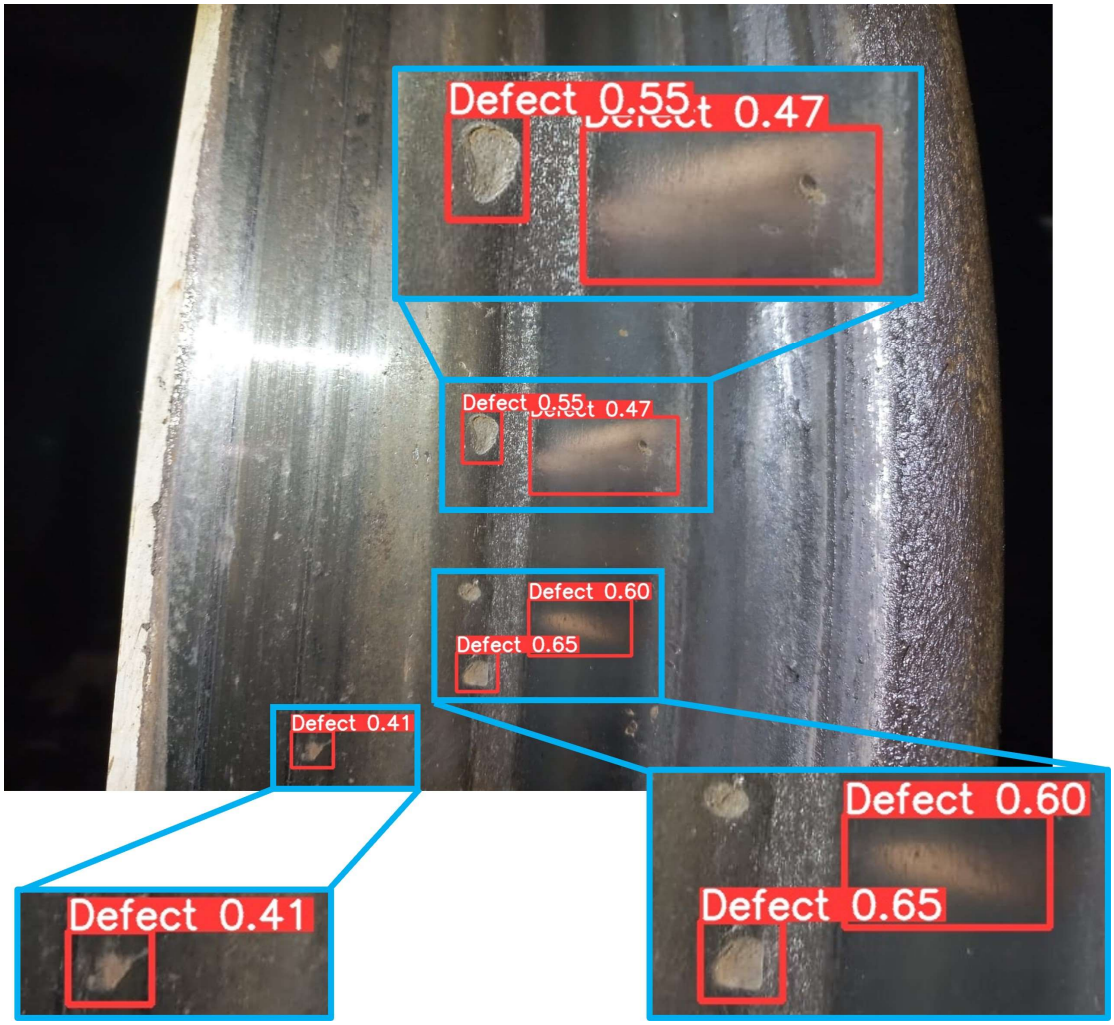



Fig. 2-13 実車輪の表面欠陥検知結果

## 2.7 考察

エッジ検出は, 画像の境界や不規則性を強調することで, 画像内のエッジ要素を検出することで異常の識別精度を高める. エッジ検出と AI の組み合わせにより，偽陽性/偽陰性を減らすことで品質管理が強化され，欠陥検出の全体的な有効性が向上する． 直線状の欠陥であれば，キャニーエッジ検出などによる検出が可能であるが，マシンビジョンのみでは画像として特徴が少なく見えるようなものの検出が難しい． キャニーエッジ検出では直線状の欠陥などは検出可能だが，運行に影響するような表面欠陥は検出可能な形状が限られる． レーザー計測器による検出は 0.2mm 以上の摩耗量があれば可能であるが，欠陥深さが 0.1mm 以下のものは検出が難しい. レーザー計測とマシンビジョン両方の技術の長所を活用し, それぞれの短所を補いあうことで, 欠陥検出のためのロバストで信頼性の高いシステムの実現が可能となる.

### 2.7.1 本研究の結果

本研究によって得られた成果を以下の通りまとめる.

- 0.2mm 以上の深さのある欠陥はレーザー計測によって検出可能である.
- 移動速度および材質が異なる車輪試験片を用いた計測試験を実施した結果, 欠陥の検出精度において差異がないことが分かった.
- レーザー計測による標準偏差は幅方向で 0.1mm，深さ方向で 0.05mm であり，先行研究と比較しても高精度での計測が達成できており優位性が認められる． しかし欠陥深さが 0.2mm 以下の場合の計測の差異は 0.8～1.1mm あり，深さが 0.5mm 以上の場合と比べて差が大きいものであった.

- 画像データ内の境界要素をエッジ要素検出によって抽出することが可能であり，マーキングによる深さの無いエッジ要素でも検出が可能である．
- レーザープロファイルセンサーと AI による物体検知を組み合わせた表面欠陥検出は同じ範囲をレーザーで計測し，AI との複合にて判定を行うことで，誤検知が低減できることを示した．
- AI を用いることで，Fig. 2-13 のように円形や楕円形の欠陥を検出することができる．
- 作成した AI モデルの Precision は 95.28%であり，先行研究と比較しても高い精度での検知ができており，本研究の優位性が認められる．

### 2.7.2 将来の課題

本研究を実際の車輪の点検作業に応用するためには，以下の課題があり，将来解決する必要がある．

- 欠陥深さが 0.2mm 以下の場合に計測の差異が大きく，欠陥深さが 0.5mm 以上の場合と同じく計測差異が 0.05mm 以下となるべく調査が必要となる．
- レーザープロファイルセンサーの幅方向の分解能が 0.1mm であることが幅方向の計測誤差と標準偏差が大きい原因であるため，分解能が深さ方向と同じ 0.001mm レーザープロファイルセンサーを使用する必要がある．
- エッジ検出ではキズや錆などの線状の形状のもののみが検出可能であり，それ以外の欠陥をエッジ検出では検出できていない．他の形状を検出できるような処理の方法を検証する必要がある．
- AI モデルは追加の検知対象を検出するための継続的な学習を実行する必要

がある．Fig. 2-13 にも示されるように光が反射している部分を欠陥であると誤検知している．本研究では見落としを防ぐことを重要視するため，Recall（再現率）を向上した AI モデルとする必要がある．

- 鉄道車両の運用に影響を及ぼす表面欠陥の整理を行い，鉄道車両の安全な運用に影響を及ぼす表面欠陥の検知方法を検証する必要がある．
- 実車輪に発生している表面欠陥の画像データを収集し，剥離以外の表面欠陥以外を検知するための AI モデルを作成する．
- AI モデルは照度条件を変更することや，ノイズを含んだ画像を用いて機械学習を行うことでロバスト性の高いモデルへと更新を行う必要がある．

## 2.8 結論

本章では車輪踏面形状を模擬した試験片を用いたレーザー計測とエッジ検出を用いた表面欠陥検出手法の判定を行い，レーザー計測では深さのあるキズの計測が可能であり，エッジ検出では深さのない欠陥を検知可能であることを確認した． また，実車輪に発生した剥離を検知する AI モデルの作成を行い，欠陥の検知が可能であることを示した． 本研究で実施した手法を基にして鉄道車両の安全な運用に影響を及ぼす表面欠陥の検知手法を確立し，鉄道車両を安全に運用するために有効なメンテナンス手法の研究に貢献する．

# 第 3 章　レーザー計測と AI による車両運行に影響を及ぼす表面欠陥検出

本章では第 2 章で実施した①レーザー計測による車輪踏面プロファイルの計測と②エッジ検出手法と AI による物体検知手法を用いたマシンビジョンによる表面欠陥計測を同時に実施する手法を発展させ，鉄道車両の安全な運行に影響を及ぼす 5 種類の車輪踏面表面欠陥である①熱亀裂，②剥離，③フラット，④フランジ摩耗，⑤踏面摩耗をレーザー計測器とマシンビジョンのそれぞれの欠点を補って計測することについて実施した研究について述べる． 以下に研究の内容について述べる．

## 3.1　計測対象とシステム構成

本研究で想定される検査システムの使用状況は前章と同じく Fig. 2-1 に示す車両基地のピットである． 本研究の目的は鉄道車両基地において点検が実施されるピットの入り口において，レーザー計測器およびビデオカメラを Fig. 2-1 の通りレール下部に設置することにより鉄道車両の入場時に車輪踏面プロファイル形状の計測と踏面表面欠陥の判定を行うことができる検査手法を提案することである． 前章で実施した手法を踏襲し，アルミ製の試験用車輪試験片-3 に付与する表面欠陥を車両の安全な運用に影響する 5 種類の表面欠陥としている．本計測システムのフローを Fig. 3-1 に示す.

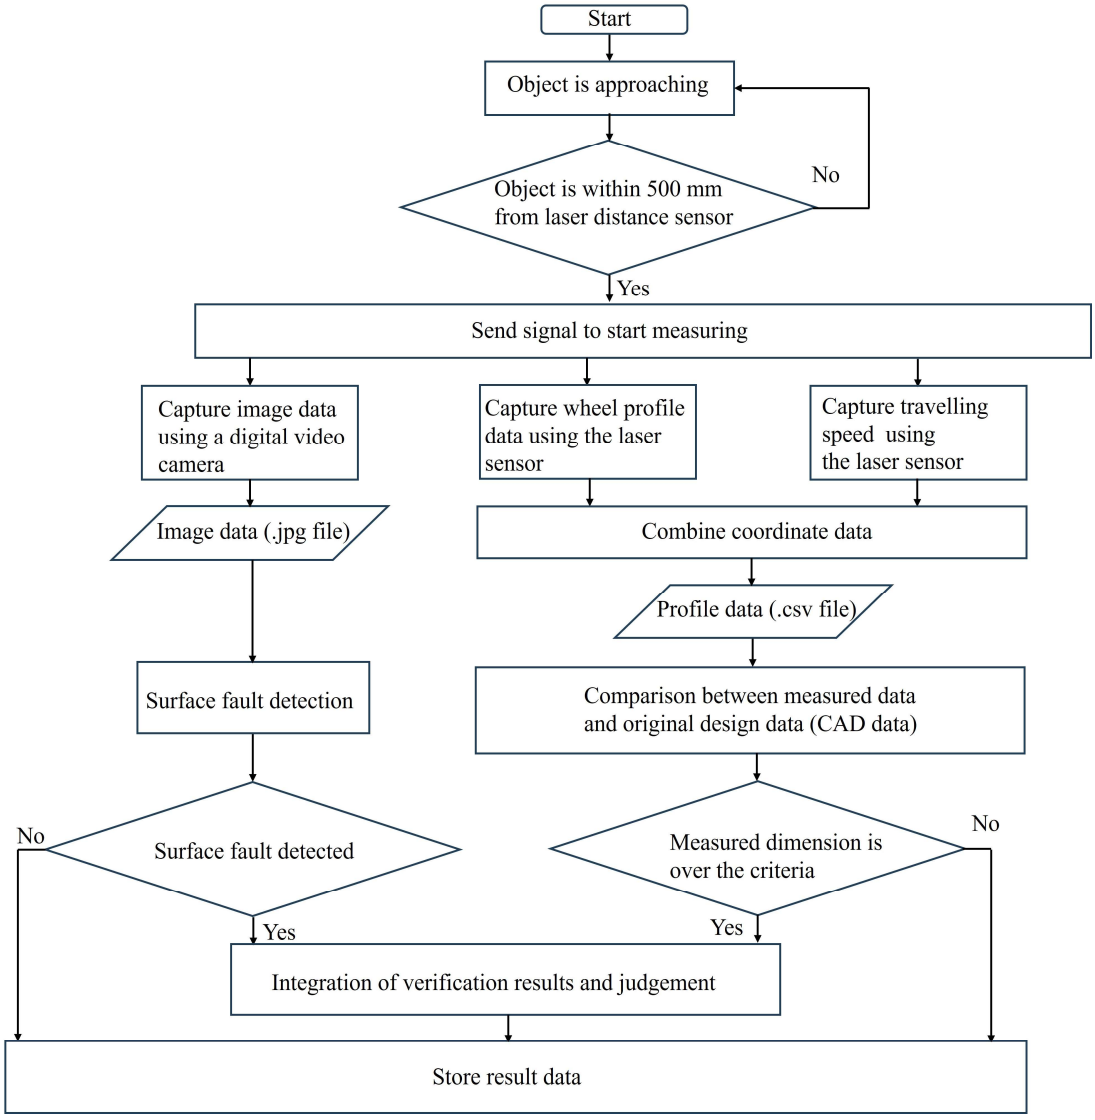



Fig. 3-1 計測システムフロー

実験に用いたシステムの構成は前章と同じであり，Fig. 2-3 に示すとおりである． 違いは使用する計測用試験片の違いのみとなる． 実験システムは①レーザートリガーセンサー, ②レーザー距離センサー, ③レーザープロファイルセンサー，④デジタルビデオカメラ，⑤レーザーコントローラ，⑥計測用車輪試験片，⑦計測用車輪試験片移動用スライダ, ⑧PC で構成される． それぞれの仕様詳細は前章と同じであり，Table 2-1 に示される．

実験は次のフローで進められる．

ステップ 1; ⑥の計測用車輪試験片を⑦の計測用車輪試験片移動用スライダに固定する．

ステップ 2; ⑦計測用車輪試験片移動用スライダに取り付けられた⑥計測用車輪試験片を⑧の PC より⑦の試験片移動用スライダを操作して①レーザートリガーセンサーに向かって移動させる．

ステップ 3; ①レーザートリガーセンサーと⑥計測用車輪試験片の距離が 500mm になったときに①レーザートリガーセンサーが距離を検知してトリガーが入り⑤のレーザーコントローラに信号を送り, ②レーザー距離センサー, ③レーザープロファイルセンサー，④デジタルビデオカメラによる計測を開始させる．

ステップ 4; ⑤のレーザーコントローラは②レーザー距離センサー, ③レーザープロファイルセンサーを, ⑦のPCは④デジタルビデオカメラをそれぞれ動作させる.

ステップ 5; ⑤レーザーコントローラを通じて②レーザー距離センサー, ③レーザープロファイルセンサー, ④ビデオカメラから得られる計測データを⑧PCに記録する.

ステップ 6; 記録されたデータはFig. 2-2に示すフローで処理される.

ステップ 7; ②レーザー距離センサー進行方向の座標情報yを, ③レーザープロファイルセンサーからは高さ方向の座標情報zと幅方向の座標情報xをそれぞれ取得し, 2次元のプロットまたは3次元モデルを作成する.

ステップ 8; ④ビデオカメラから得られた画像データはAIモデルによる欠陥検知に使用される.

ステップ 9； エッジ検出結果と AI による表面欠陥検知結果を⑧PC に記録する.

ステップ10； ステップ7とステップ9の情報を統合し, 車両の安全な運行に影響があるような表面欠陥が存在するかどうかを判断する.

## 3.2　表面欠陥を付与した計測用車輪試験片

本章での実験では，前章と同じく，車輪の実物と同じプロファイル形状を有する計測用車輪試験片を準備する．この試験片は車輪の踏面部分を切り出した形状を有しており，計測用車輪試験片-3 と呼ぶ．計測用車輪試験片-3 の材質はアルミである．前章の試験片との違いは，本章の試験片が車両の安全な運行に影響を及ぼす 5 種類の表面欠陥を再現していることである．本章における試験片材質としてアルミ製のみを採用したのは 5 種類の表面欠陥を機械加工にて試験片に再現するためである．鋼製よりも熱亀裂や剥離を再現しやすいためアルミ製を採用している．Fig. 3-2 に実験で用いた車輪試験片-3 の寸法情報を表す．試験片には①熱亀裂，②剥離，③フラット，④フランジ摩耗，⑤踏面摩耗のような第 1 章の Fig. 1-4 で示した鉄道車両の走行に影響を及ぼす 5 種類の表面欠陥を機械加工によって付与している．試験片には Table 3-1 に示すように，熱亀裂を模擬した線状の表面欠陥や剥離を模擬した楕円形状の表面欠陥およびフラットを模擬した摩耗状の表面欠陥を付与する．車輪試験片-3 に与えられた外形および表面欠陥の寸法情報を Fig. 3-2 に表す．Fig. 3-2 の上段では車輪試験片-3 の外形図を示し，中段では断面 A-A，B-B，C-C の情報をそれぞれ示す．ここでは表面欠陥の幅や深さなどの情報を示している．下段では鳥観図を示し，車両試験片-3 の表面欠陥の位置を記している．この鳥観図に表面欠陥の位置を表すのに用いる座標の原点となる(x，y，z) = (0，0，0)の位置が示されている．ここで示される表面欠陥のそれぞれの位置情報を Table 3-1 に示す．Fig. 3-5 には車輪試験片-3 の画像を示す．

このようにして準備した車両試験片-3 を使用して実験を実施した．

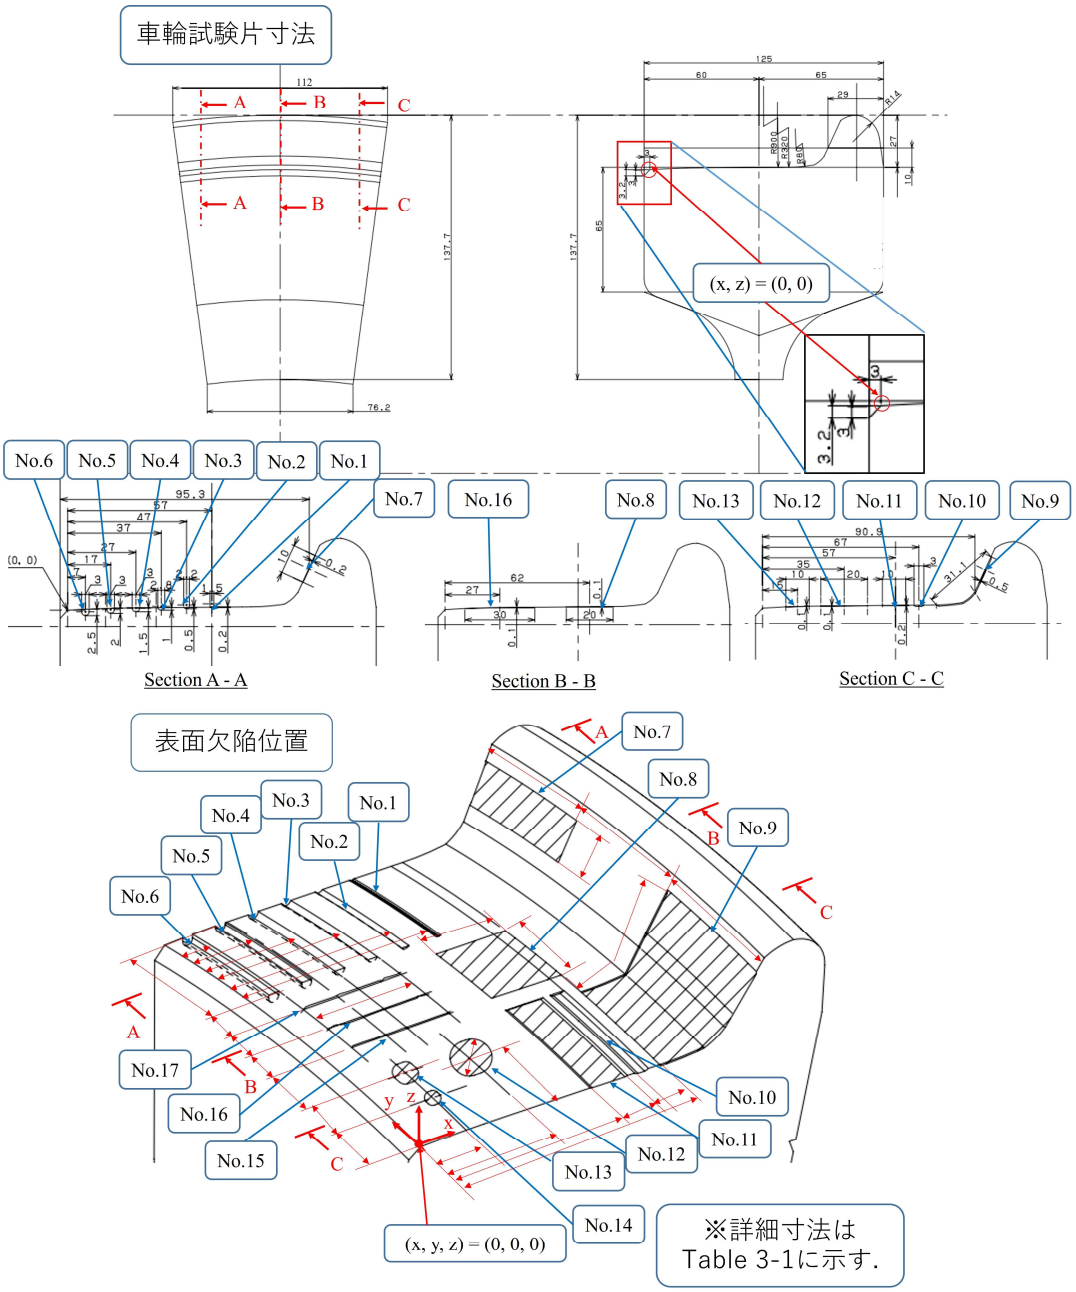



Fig. 3-2 計測用車両試験片-3 の表面欠陥位置

試験片-3;アルミ製

上段；計測用車両試験片-3 の外形図

中段；断面 A-A, B-B, C-C それぞれでの欠陥寸法位置

下段；計測用車輪試験片-3 の鳥観図

Table 3-1 計測用車輪試験片-3 の表面欠陥とその寸法

（単位 = mm） 材質; アルミ製

| No | 欠陥の種類 | 位置（中心位置） | | | 欠陥の寸法 | | |
|---|---|---|---|---|---|---|---|
| | | x | y | z | 長さ | 幅 | 深さ |
| 1 | 深い傷 | 57 | 70 | 1.2 | 35 | 1.5 | 0.2 |
| 2 | 深い傷 | 47 | 70 | 1.1 | 35 | 2.2 | 0.5 |
| 3 | 深い傷 | 37 | 70 | 1.0 | 35 | 2.8 | 1.0 |
| 4 | 深い傷 | 27 | 70 | 0.9 | 35 | 3 | 1.5 |
| 5 | 深い傷 | 17 | 70 | 0.8 | 35 | 3 | 2.0 |
| 6 | 深い傷 | 7 | 70 | 0.4 | 35 | 3 | 2.5 |
| 7 | フランジ摩耗 | 95 | 70 | 16 | 35 | 10 | 0.2 |
| 8 | フラット | 62 | 45 | 1.2 | 35 | 20 | 0.1 |
| 9 | フランジ摩耗 | 91 | 0 | 6.8 | 35 | 31.1 | 0.5 |
| 10 | 深い傷 | 67 | 0 | 1.3 | 35 | 3 | 0.5 |
| 11 | 踏面摩耗 | 57 | 0 | 1.2 | 35 | 10 | 0.2 |
| 12 | 剥離 | 35 | 25 | 1.0 | 20 dia. | | 0.1 以下 |
| 13 | 剥離 | 15 | 12 | 0.7 | 10 dia. | | 0.1 以下 |
| 14 | 剥離 | 15 | 27 | 0.7 | 5 dia. | | 0.1 以下 |
| 15 | 亀裂 | 27 | 40 | 0.9 | 30 | 0.1 以下 | 0.1 以下 |
| 16 | 亀裂 | 27 | 50 | 0.9 | 30 | 0.1 以下 | 0.1 以下 |
| 17 | 亀裂 | 27 | 60 | 0.9 | 30 | 0.1 以下 | 0.1 以下 |

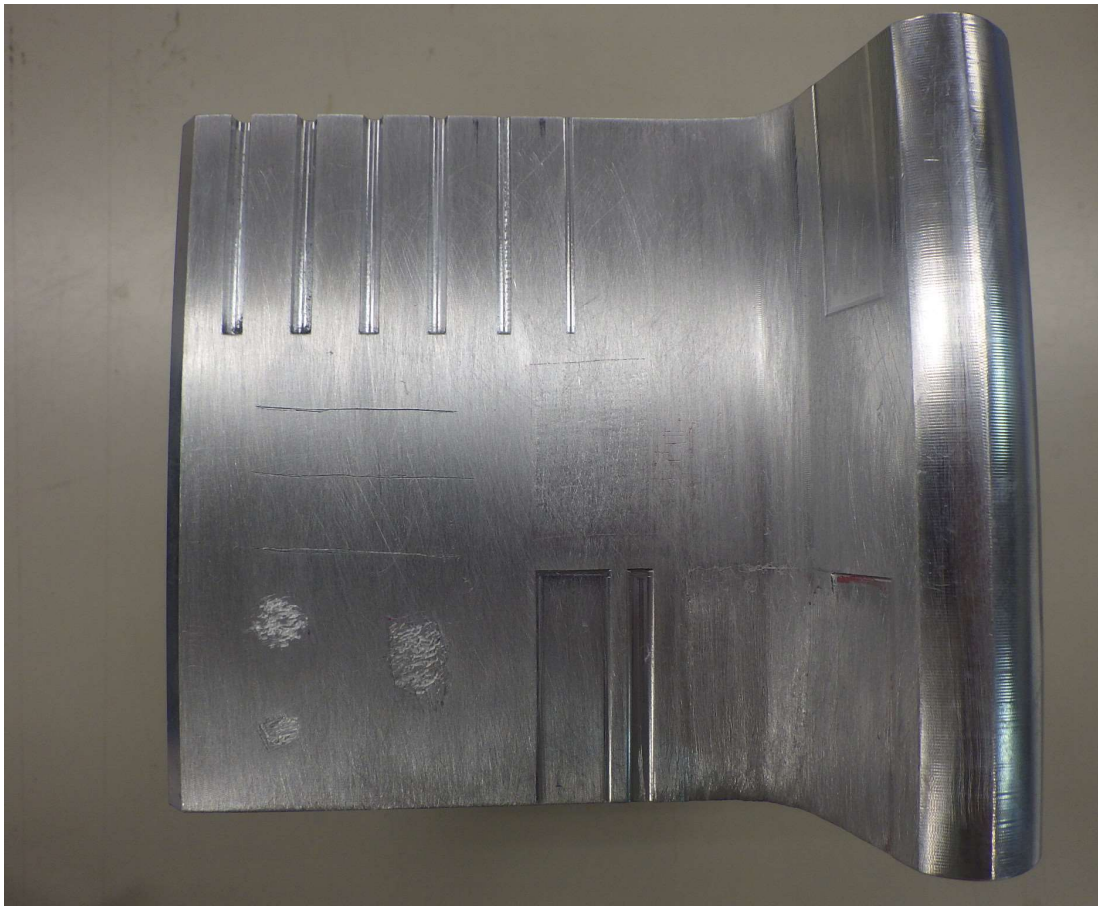


Fig. 3-3 計測用車輪試験片-3 画像

## 3.3　レーザープロファイルセンサーによる踏面プロファイル計測

3.1 節で述べた計測ステップに従って計測を行う．レーザー距離センサーとレーザープロファイルセンサーの計測周波数を同じに設定することで計測タイミングを一致させ，対象物の長さつまり移動方向（y 方向），幅（x 方向），および高さ（z 方向）のそれぞれの寸法を計測する．計測用車輪試験片の移動速度は計測用車輪試験片移動用スライダの制御ソフトによって変更可能であり，本実験では日本における鉄道車両基地内でピットへ入る際に想定される速度である 5〜8km/h と想定した．レーザー距離計によって得られる距離情報から対象物の移動速度を$v$とすると，この値は式（3-1）にて求めることができる．

$$v = L / t \tag{3-1}$$

ここで $t$ を計測周期，$L$ を試験片の移動距離とする．計算例として計測周期 $t_1$ = 0.0001 秒で，その間の移動距離 $L_1$ = 0.1mm の時，移動速度 $v_1$ は計算式（3-2）で計算される．

$$v_1 = 0.1 / 0.0001 = 1000\text{mm/s} \quad (= 3.6\text{km/h}) \tag{3-2}$$

レーザープロファイルセンサーでは対象物の幅方向（x 方向），および高さ方向（z 方向）の寸法を計測する．レーザー距離センサーでは対象物の長さ（y 方向）の寸法を計測して 3 次元モデルを作成するために必要な情報を記録する．この x，y，z のそれぞれの座標情報から，オリジナルと計測結果での各断面の情報を比較することや 3 次元モデルを表示しての視覚的比較が可能となる．

ステップ7で述べたようにレーザー距離センサーより進行方向の座標情報yを，レーザープロファイルセンサーにて高さ方向座標 z と幅方向座標 x を取得し，それらの値を csv データとしてリスト化する．

## 3.4　試験体に再現した表面欠陥判定用 AI モデルの作成

本研究では，前章と同じく AI モデルの作成に YOLOv5 を使用する． 実験時に取得された画像データから以下の手順にて学習モデルの準備とAIモデルの作成を行う．

### 3.4.1　試験用車輪試験片の表面欠陥からの AI モデル作成

計測用車輪試験片には意図的に機械加工による表面欠陥を付与して表面欠陥検知用の AI モデルを作成する． データリーケージを防ぐために，計測用車輪試験片とは別に表面欠陥付与のためのアルミ板を準備し，アルミ板に表面欠陥を付与する． アルミ板に付与する車輪踏面の表面欠陥として，以下の欠陥を準備する．①熱亀裂は真の直線ではなく複数の線状が交差したものとし，長さ 20－50mm，幅および深さは 0.1mm 未満とする． ②剥離は，直径 10－30mm，深さ 0.1mm 未満の円周に垂直な方向に発生する傷とする． ③フラットは車輪周方向に発生する長方形または楕円形の欠陥で, 長さ 10－20mm, 幅 10－20mm, 深さ 0.1mm 未満の目が細かい傷とする． ④フランジ摩耗と⑤踏面摩耗は，長さ約 35mm，幅 10－35mm，深さ 0.2－0.5mm で，周方向に発生する目の細かい摩耗となるように再現する． これらの欠陥は，半田[5][6]の資料に示されて

いる写真を参照して再現している． Fig. 3-4 にアルミ板に再現した表面欠陥の画像を示し，Table 3-2 に表面欠陥の種類とその寸法に関する情報を示す.

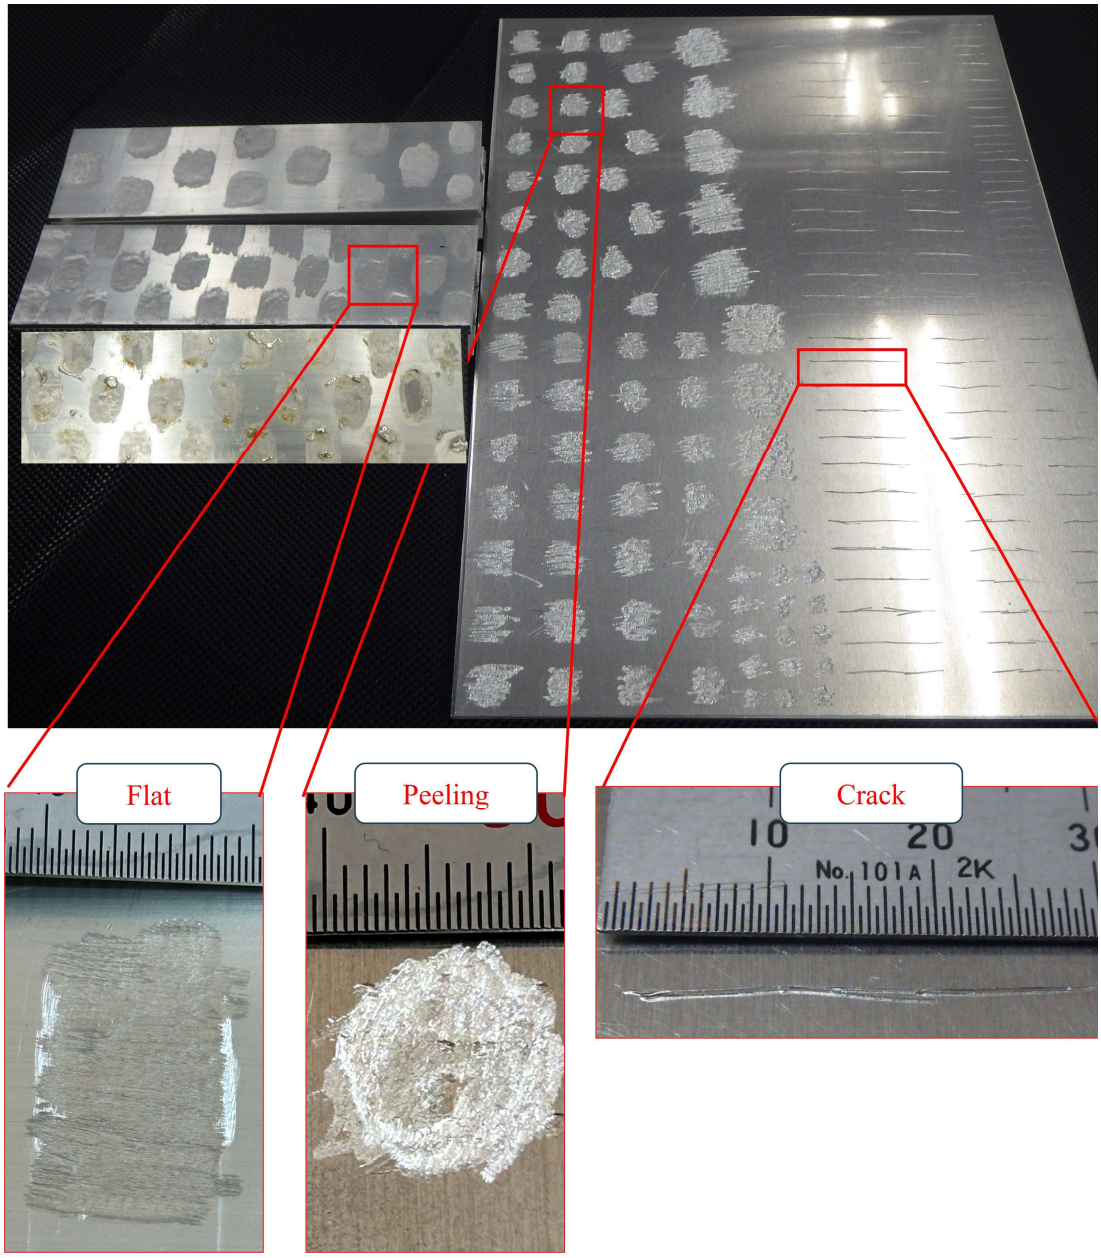
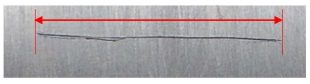
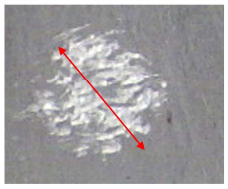
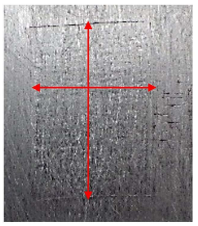
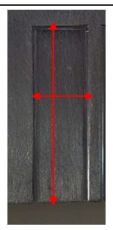



Fig. 3-4 アルミ板に再現した表面欠陥

Table 3-2 表面欠陥の整理

| 欠陥種類 | 長さ | 幅 | 深さ | イメージ |
|---|---|---|---|---|
| ① 熱亀裂 | 20－50mm | 0.1mm未満 | 0.1mm未満 |  |
| ② 剥離 | 直径<br>10－30mm | | 0.1mm未満 |  |
| ③ フラット | 10－20mm | 10－20mm | 0.1mm未満 |  |
| ④ フランジ摩耗 | 35mm | 10－35mm | 0.2－0.5mm |  |
| ⑤ 踏面摩耗 | 35mm | 10－35mm | 0.2－0.5mm |  |

アルミ板への表面欠陥の機械加工だけでも 1000 枚以上の画像を準備するのは困難であるため以下のようにしてデータオーグメンテーション（データ拡張）を行った． 車輪踏面表面の欠陥を検出する AI モデルを作成するために，計測用車輪試験片-3 とは異なるアルミ板に再現した欠陥画像 1024 枚をデータセットとして準備する． 1024 枚の画像を準備するために，データオーグメンテーションが実施される． データオーグメンテーション前にはオリジナルのデータセットとしては 128 枚の画像があり, それぞれトレーニングデータセットに 96 枚, バリデーションデータセットに 16 枚，テストデータセットに 16 枚の画像に分割されている． これらのデータは水平方向への反転，垂直方向の反転，回転や輝度補正，コントラスト調整といった方法を複合して実施することで拡張される． このようにしてデータオーグメンテーションを実施してデータ数を 128 から 1024 へと 8 倍に拡張させる．車輪表面の欠陥を検出するための学習として，転移学習が使用される． この転移学習には事前学習済みの YOLOv5 モデルが表面欠陥のある車輪画像をデータセットとして用いてトレーニングされ，データリーケージを防ぐために，データセットはトレーニングデータセット，バリデーションデータセットとテストデータセットの 3 種類に分割される． 画像データは，1024 枚の 640 × 480 ピクセルの画像で構成され，それらの画像データは，トレーニングデータセット（75%，768 枚），バリデーションデータセット（12.5%，128 画像），およびテストデータセット（12.5%，128 画像）に分割される． Table 3-3 にそれらを示す． データオーグメンテーションの例を Fig. 3-5 に示す． なお，フラット，フランジ摩耗，踏面摩耗については外観的特徴としては摩耗が主となる表面欠陥であり，車輪踏面での発生する場所とサイズが異

なる違いのため，AI 学習モデルはフラットについてのみ作成した． そのため，AI によって検知する対象は熱亀裂，剥離，フラットの 3 種類としている．

Table 3-3 機械学習に用いた画像の分類（試験片-3）

| 欠陥種類 | イメージ数 | | | |
|---|---|---|---|---|
| | Training | Validation | Test | Total |
| 熱亀裂 | 768 (75%) | 128 (12.5%) | 128 (12.5%) | 1024 |
| 剥離 | 768 (75%) | 128 (12.5%) | 128 (12.5%) | 1024 |
| フラット (*摩耗) | 768 (75%) | 128 (12.5%) | 128 (12.5%) | 1024 |

*フラット，フランジ摩耗，踏面摩耗については摩耗が主となる表面欠陥のため，学習モデルはフラットについてのみ作成した.

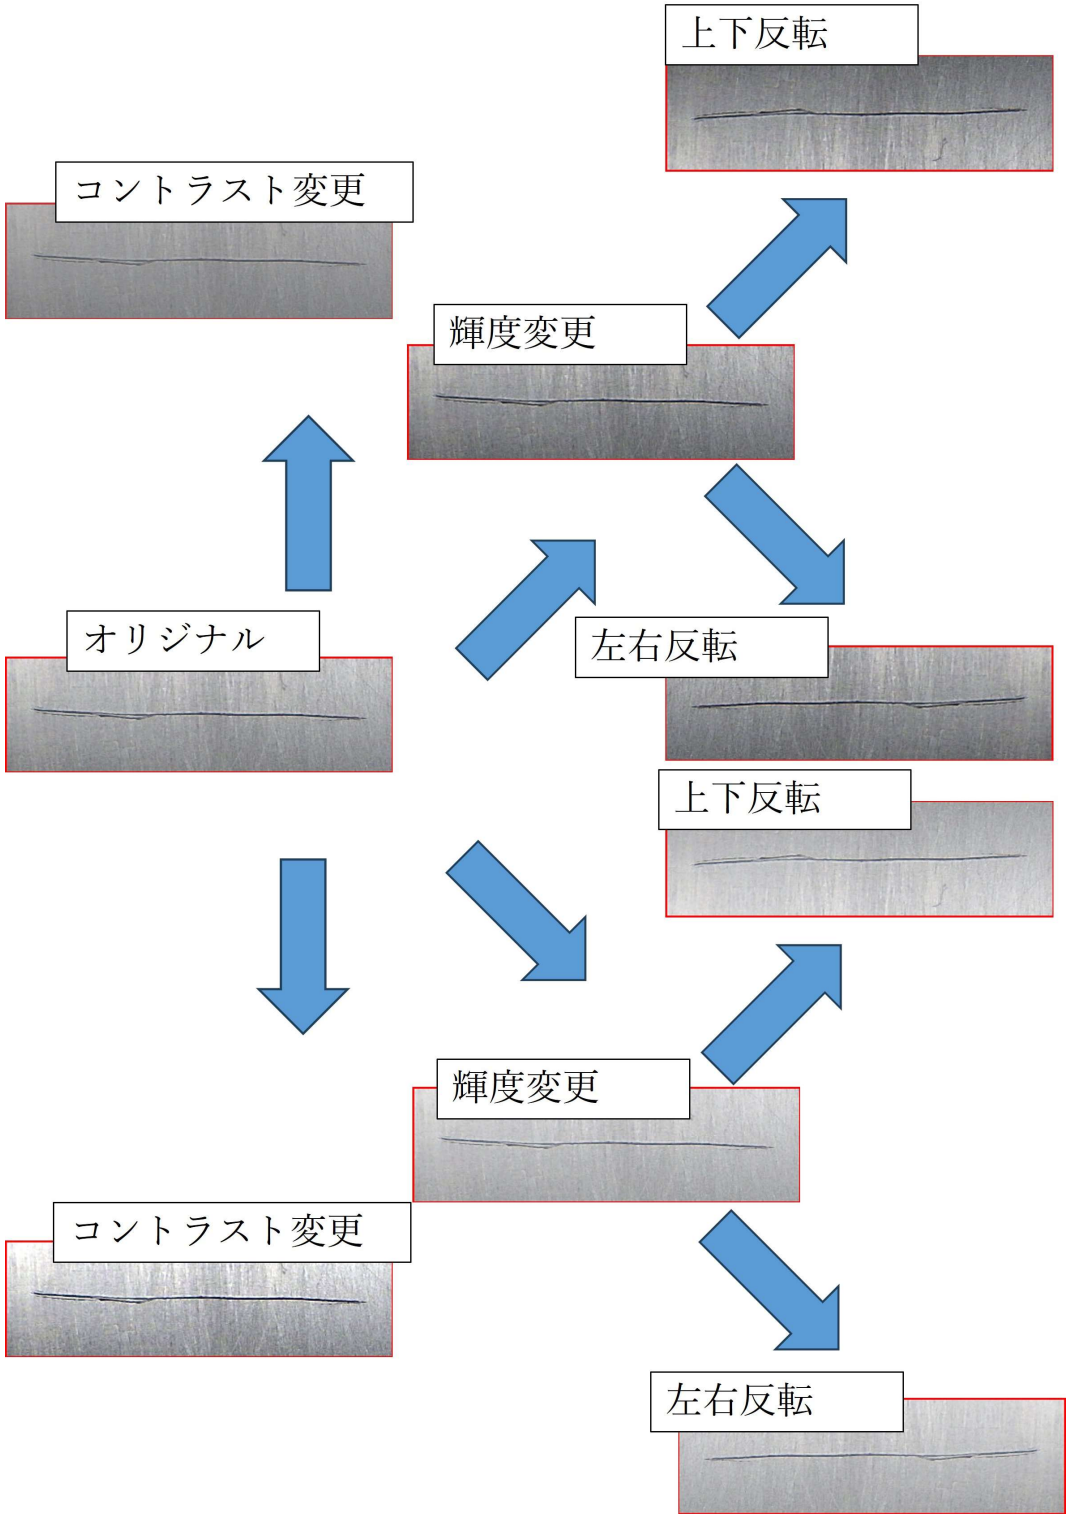



Fig. 3-5 データ拡張結果（試験片）

次に”labelImg”ツールを用いてAIの学習に用いるアノテーションを実施する．事前学習済みモデルYOLOv5は，車輪の表面欠陥の機械学習モデルを作成するための出発点として使用されている． モデルのパフォーマンスを測定するために，precision（精度），recall（再現率），そしてmean average precision（平均精度 mAP50）を指標として用いる． 以上のようにして作成したAIモデルの学習結果をFig. 3-6に示す． Fig. 3-6の上段では学習に用いたデータの例を，中段では学習途中の状態を，下段では学習の結果，検証用画像に検知を行ったことによる欠陥判定の状態をそれぞれ示す． また，それぞれのモデルの学習結果（Precision，Recall，mean average precision)をTable 3-4に示す．先行研究における検出結果ではKrummenacher[46]らはFlat spotについてはPrecisionが89±4%，Recallが86±6%であり，Shellingについては Precisionが92±3%，Recallが93±3%であり，Zhang[50]らの結果ではPrecisionが88.8%，Recallが92.0%であり，これらの研究結果と比較して，Precision，Recall共に本研究の方が高い数値が実現できており，本研究の優位性が認められる．

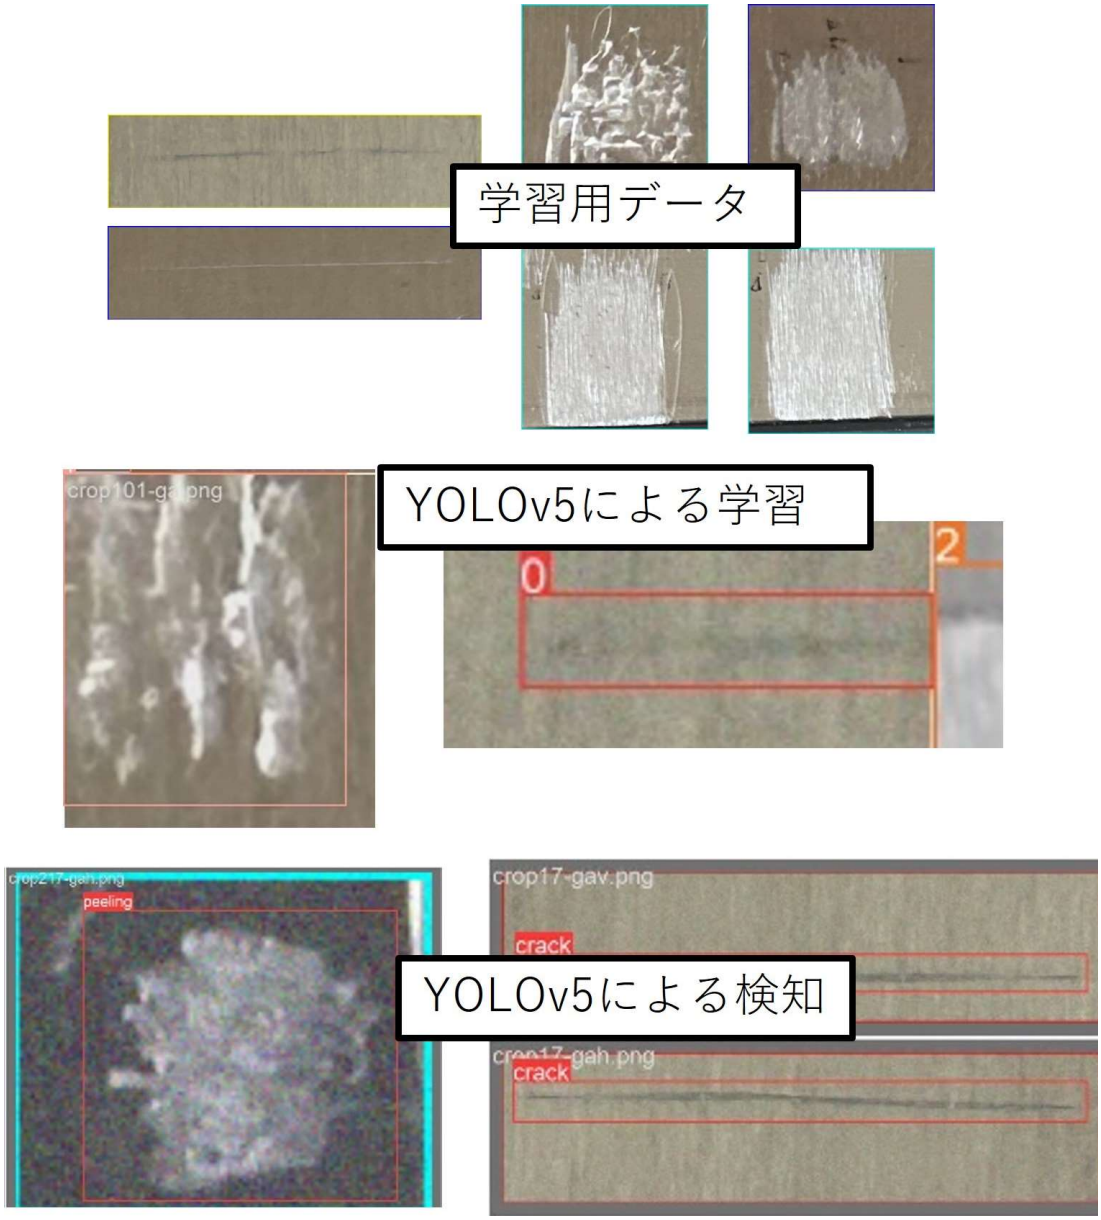



Fig. 3-6 YOLO モデル学習結果（試験片）

Table 3-4 AI モデル学習結果（試験片-3）

| 欠陥種類 | Precision | Recall | mAP50 |
|---|---|---|---|
| Crack | 0.996 | 1.000 | 0.995 |
| Peel | 0.974 | 1.000 | 0.995 |
| Flat (wear) | 0.979 | 1.000 | 0.995 |

## 3.5 計測結果

本節ではレーザー計測と表面欠陥判定AIを用いた車輪踏面の表面欠陥検出手法の実験結果について述べる.

### 3.5.1 踏面プロファイル計測結果

レーザー計測器による車輪踏面プロファイル計測結果を Table 3-5 に示す. Table 3-5 の左の表は設計上の3次元座標を示す. 右の表は移動速度が7.3km/hの計測結果を示す. 計測結果としては幅(x)方向での誤差が±0.9mmであり, 深さ(z)方向には±0.1mm, 長さ(y)方向では±3.37mmであった. 標準偏差はそれぞれ幅方向が0.1mm, 深さ方向が0.05mm, 長さ方向が1.5mmであった. 長さ方向のばらつきはあるが幅方向と深さ方向の標準偏差は2章の結果と同等であった.

本実験でのレーザー計測器の分解能は Table 2-1 に示すように幅(x)方向が0.1mm, 長さ(y)方向が0.001mm, 深さ(z)方向が0.001mmであった. 従来の手動による計測では計測可能な精度が0.5mm程度であったので, 自動計測による目標としては深さ(z)方向で 0.1mm の精度が達成できることが望ましい. 結果としては, 深さ方向の差が 0.1mm 程度であったので目標とされる精度を満足している結果となった. このような高い計測精度は人力ではほぼ不可能であり, 目的を達成することができたと考える. 一方で長さ方向については3mm以上の差があり, 表面欠陥は検出できているので目標は達成できているが, 今後の改善が必要となる.

Table 3-6 は計測精度の再現性を確認するために実施した. Table 3-6 の表は,

左の表が y = 0.1mm の位置，中央の表が y = 50.0mm の位置，右の表が y = 100.0mm の位置となる． x＝0 から 0.2mm の位置では差が 0.3mm 程度となっているが，それ以外では 0.16mm 以内となっており，このような高い精度での計測は人力では，ほぼ不可能である． このように，レーザー計測によるプロファイル計測は，迅速かつ高精度な計測を可能とする．

Table 3-5 踏面プロファイル計測における計測誤差

（単位 ＝ mm）　　（試験片-3 移動速度=7.3km/h）

| オリジナル CAD データ | | | | 試験片-3（アルミ） | | | | | |
|---|---|---|---|---|---|---|---|---|---|
| 欠陥 | 深さ | 幅 | 長さ | 深さ | 幅 | 長さ | 深さ方向誤差 | 幅方向誤差 | 長さ方向誤差 |
| 1 | 0.18 | 1.40 | 35.0 | 0.31 | 2.20 | 32.2 | +0.13 | +0.80 | −2.85 |
| 2 | 0.48 | 2.20 | 35.0 | 0.53 | 2.50 | 37.2 | +0.05 | +0.30 | +2.21 |
| 3 | 1.00 | 2.80 | 35.0 | 1.03 | 2.70 | 37.5 | +0.03 | −0.10 | +2.52 |
| 4 | 1.50 | 3.00 | 35.0 | 1.55 | 2.90 | 38.3 | +0.05 | −0.10 | +3.30 |
| 5 | 2.00 | 3.00 | 35.0 | 2.05 | 3.30 | 37.8 | +0.05 | +0.30 | +2.76 |
| 6 | 2.50 | 3.00 | 35.0 | 2.49 | 2.90 | 37.8 | −0.01 | −0.10 | +2.78 |
| 7 | 0.20 | 10.0 | 35.0 | 0.18 | 10.8 | 32.4 | −0.02 | +0.80 | −2.59 |
| 8 | 0.10 | 20.0 | 25.0 | レーザー計測器では計測不能 | | | | | |
| 9 | 0.50 | 35.0 | 35.0 | 0.52 | 35.9 | 31.6 | +0.02 | +0.90 | −3.37 |
| 10 | 1.00 | 3.00 | 35.0 | 1.05 | 3.20 | 32.9 | +0.05 | +0.20 | −2.07 |
| 11 | 0.20 | 10.0 | 35.0 | 2.05 | 10.2 | 31.9 | +0.05 | +0.20 | −3.14 |
| 12 | 0.10 | 直径 20.0 | | レーザー計測器では計測不能 | | | | | |
| 13 | 0.10 | 直径 10.0 | | レーザー計測器では計測不能 | | | | | |
| 14 | 0.10 | 直径 5.00 | | レーザー計測器では計測不能 | | | | | |
| 15 | 0.10* | 0.10* | 30.0 | レーザー計測器では計測不能 | | | | | |
| 16 | 0.10* | 0.10* | 30.0 | レーザー計測器では計測不能 | | | | | |
| 17 | 0.10* | 0.10* | 30.0 | レーザー計測器では計測不能 | | | | | |

Table 3-6 車輪踏面プロファイル計測結果（試験片-3）

（単位 = mm） 材質;アルミ製

移動速度 7.3km/h, 左；y = 0.100mm, 中央； y = 50.00mm,

右；y = 100.0mm の位置

| 移動速度 7.3km/h | | |
|---|---|---|
| x | y | z |
| 0.000 | 0.100 | -0.414 |
| 0.100 | 0.100 | 0.292 |
| 0.200 | 0.100 | 0.999 |
| | | |
| 15.00 | 0.100 | 26.21 |
| 15.10 | 0.100 | 26.17 |
| 15.20 | 0.100 | 26.14 |
| | | |
| 50.00 | 0.100 | 0.029 |
| 50.10 | 0.100 | 0.004 |
| 50.20 | 0.100 | -0.003 |
| | | |
| 100.0 | 0.100 | -0.955 |
| 100.1 | 0.100 | -0.989 |
| 100.2 | 0.100 | -0.988 |
| | | |
| 120.0 | 0.100 | -1.272 |
| 120.1 | 0.100 | -1.273 |
| 120.2 | 0.100 | -1.275 |
| | | |
| 124.0 | 0.100 | -3.758 |
| 124.1 | 0.100 | -3.865 |
| 124.2 | 0.100 | -3.972 |

| 移動速度 7.3km/h | | |
|---|---|---|
| x | y | z |
| 0.000 | 50.00 | 0.000 |
| 0.100 | 50.00 | 0.299 |
| 0.200 | 50.00 | 1.012 |
| | | |
| 15.00 | 50.00 | 26.221 |
| 15.10 | 50.00 | 26.179 |
| 15.20 | 50.00 | 26.142 |
| | | |
| 50.00 | 50.00 | 0.046 |
| 50.10 | 50.00 | 0.017 |
| 50.20 | 50.00 | 0.016 |
| | | |
| 100.0 | 50.00 | -0.941 |
| 100.1 | 50.00 | -0.974 |
| 100.2 | 50.00 | -0.979 |
| | | |
| 120.0 | 50.00 | -1.175 |
| 120.1 | 50.00 | -1.181 |
| 120.2 | 50.00 | -1.188 |
| | | |
| 124.0 | 50.00 | -3.749 |
| 124.1 | 50.00 | -3.765 |
| 124.2 | 50.00 | -3.951 |

| 移動速度 7.3km/h | | |
|---|---|---|
| x | y | z |
| 0.000 | 100.0 | -0.336 |
| 0.100 | 100.0 | -0.061 |
| 0.200 | 100.0 | 0.999 |
| | | |
| 15.00 | 100.0 | 26.22 |
| 15.10 | 100.0 | 26.17 |
| 15.20 | 100.0 | 26.14 |
| | | |
| 50.00 | 100.0 | 0.039 |
| 50.10 | 100.0 | 0.012 |
| 50.20 | 100.0 | 0.009 |
| | | |
| 100.0 | 100.0 | -0.949 |
| 100.1 | 100.0 | -0.985 |
| 100.2 | 100.0 | -0.982 |
| | | |
| 120.0 | 100.0 | -1.119 |
| 120.1 | 100.0 | -1.121 |
| 120.2 | 100.0 | -1.191 |
| | | |
| 124.0 | 100.0 | -3.755 |
| 124.1 | 100.0 | -3.861 |
| 124.2 | 100.0 | -3.962 |

計測結果を図示して判断を容易にするするために計測結果から3次元モデルを作成したものをFig. 3-7に示す． Fig. 3-7の上側の3次元モデルはオリジナルの3次元CADデータとなる． Fig. 3-7の下の3次元モデルは速度7.3km/hで計測用試験片-3を移動させた際の試験片-3の形状計測結果を示したものである． オリジナルの3次元モデルの青枠で囲んだ部分は深さ0.1mmのものも判別可能であるが，計測したものでは判別がはっきりできないことが分かる． 深さが0.2mm以上あるものが赤枠で囲んだもので，オリジナルの3次元モデルと計測結果の3次元モデルの双方で判別可能であることが分かる． また，長さ方向の計測結果では差があることが分かる． 計測結果からこのように3次元モデルを作成し，記録を残すことで摩耗の進展を目視で観察することに使用できる．

Fig. 3-8 はレーザー計測器によるプロファイル計測時の詳細な計測誤差を調査するために詳細部分を抜きだしたものである． 計測部を拡大すると Fig. 3-8 のスケールでの表示では滑らかな形状をしていても詳細部の計測データは誤差を含んで波打っていることが分かる． この波打ちは 0.1mm 以下の微小なものであるが，この誤差があるため欠陥の深さが0.1mm以下のものは計測が難しいものと判断される．

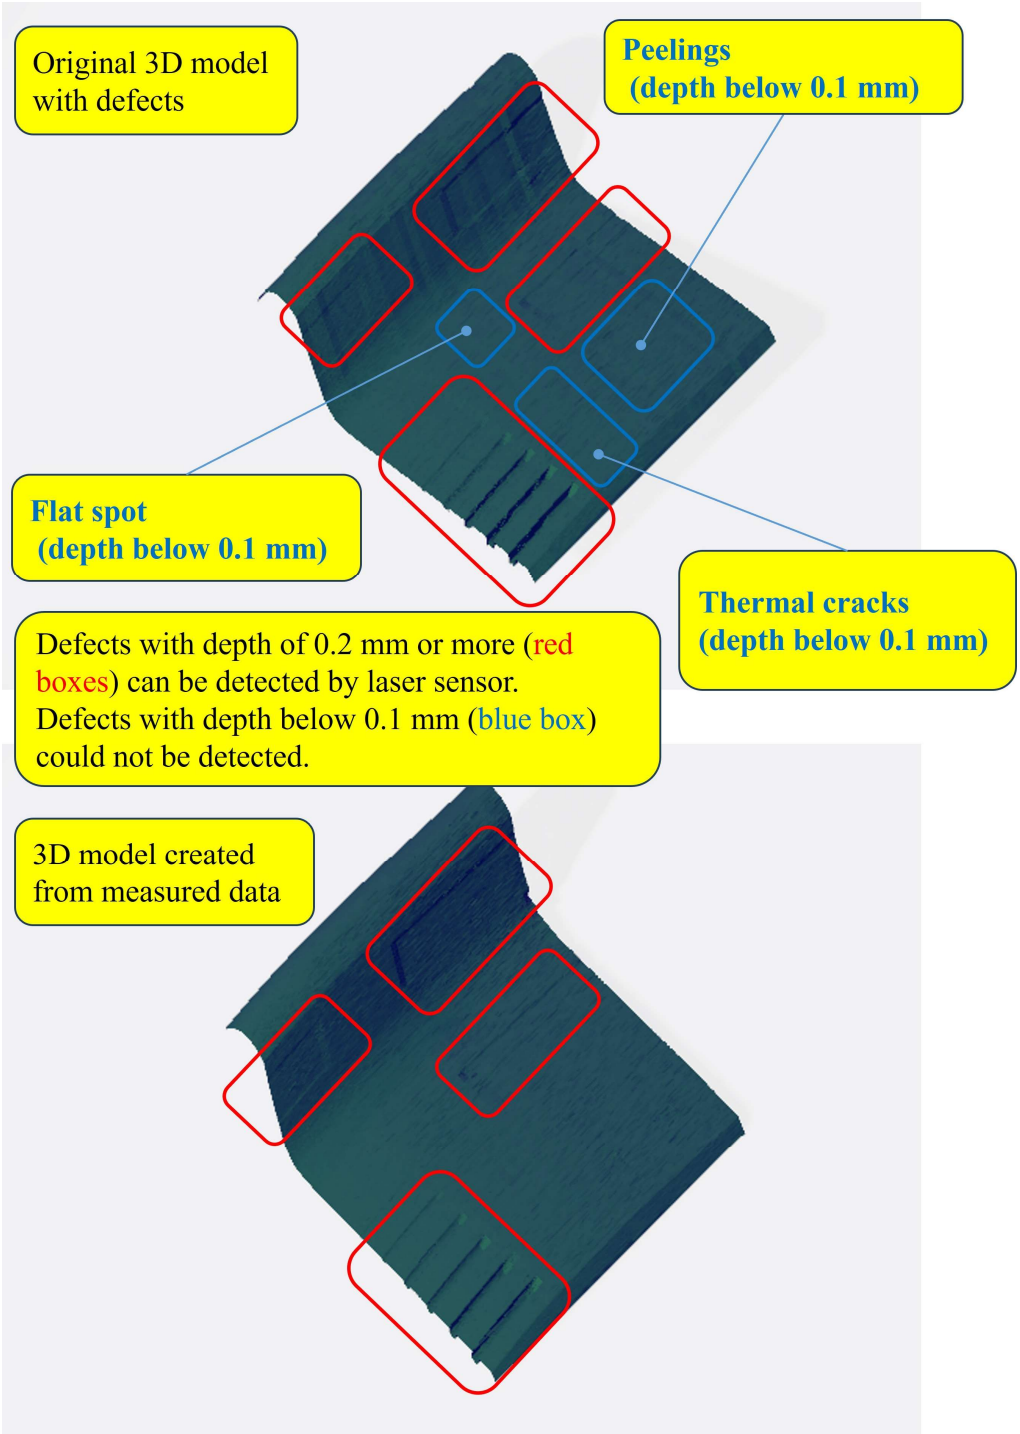



Fig. 3-7 計測結果より生成した 3 次元モデル

上段； 欠陥情報を含む 3 次元モデル，下段； 計測結果より作成した 3 次元モデル

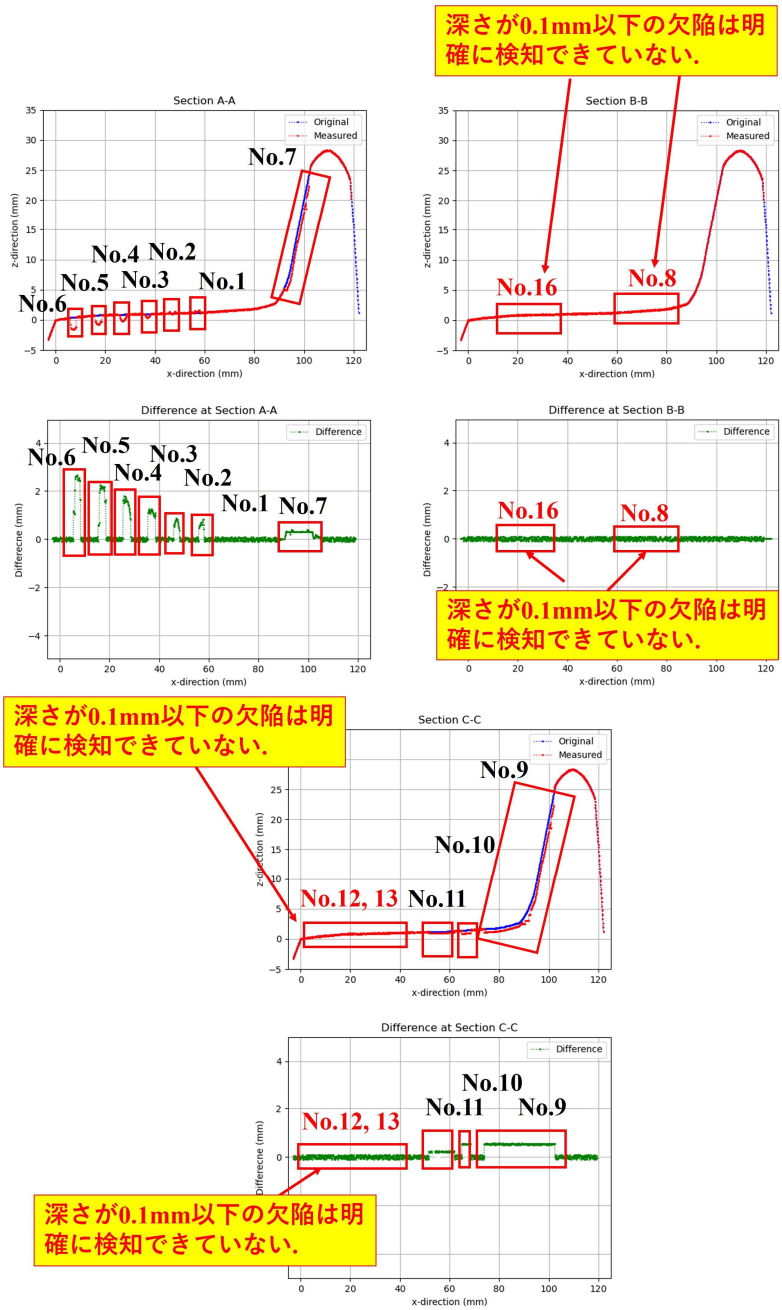



Fig. 3-8 プロファイル試験片の計測精度確認

上段；断面 A-A, B-B, and C-C における基準断面（CAD モデル上の断面）と計測結果の比較. 下段；基準断面（CAD モデル上の断面）と断面 A-A, B-B, C-C における計測結果との差.

※下段の図に示されるように微小な計測誤差があるため，0.1mm より小さな深さの欠陥を正確に検知するのは困難である.

### 3.5.2 試験片に付与した表面欠陥の AI モデルによる判定結果

3.4 節で作成した AI モデルを作成して表面欠陥の判定を行った．検出結果を Fig. 3-9 に示す．Fig. 3-9 に示されるように亀裂，剥離などの明確な外観的特徴がある摩耗については AI による判定ができている．フラットについても検知はできているが，Fig. 3-9 の右側に示すように光沢がある場合には誤検知してしまっていることが分かる．

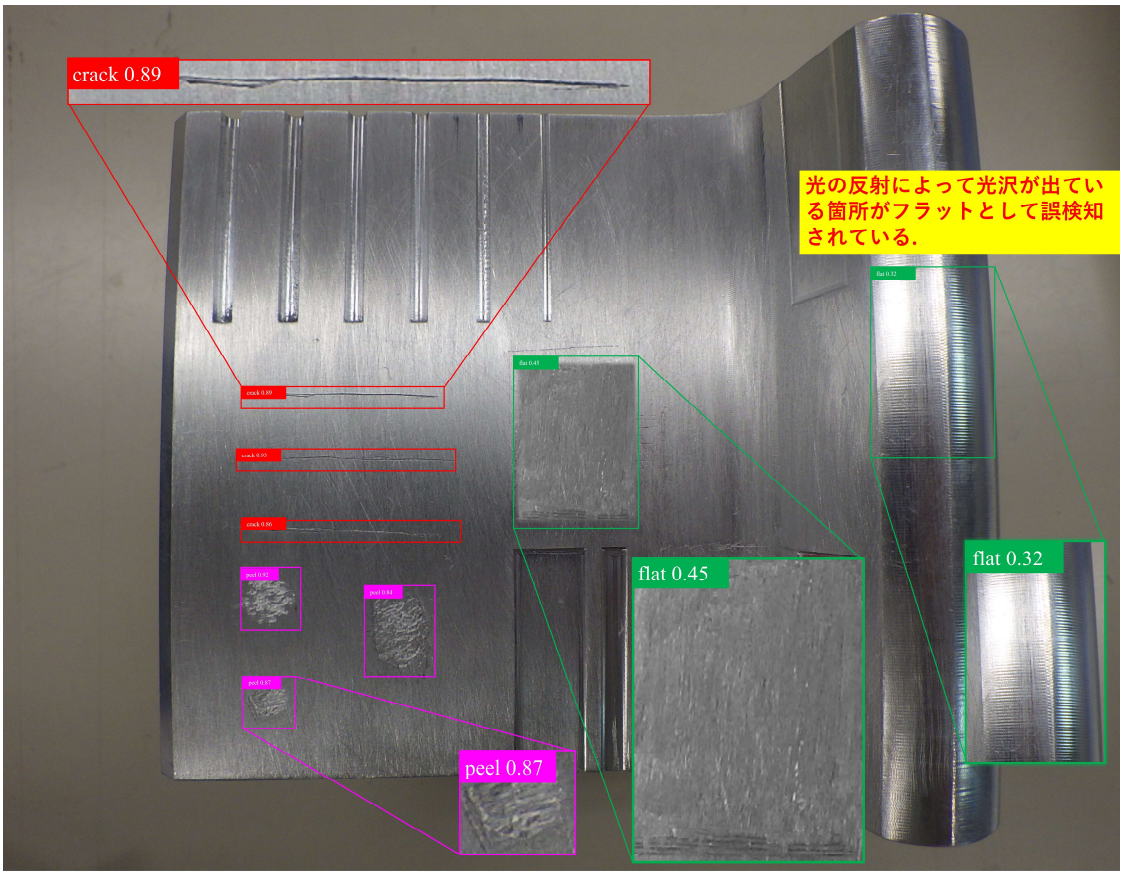



Fig. 3-9 車輪試験片の表面欠陥検知結果

## 3.6 考察

レーザー計測器とマシンビジョンにて車輪の表面欠陥の検出に関して今後期待される鉄道車両のメンテナンスへの実際の適用を考慮した視点での考察を述べる. Table 3-7 がレーザー計測器と AI による物体検出のそれぞれの検出可否を示す. レーザー計測器による計測ができなかったものは①熱亀裂，②剥離，③深さが 0.1mm 以内のフラットを含む摩耗，であった. しかし③深さが 0.2mm 以上のフラットや④フランジ摩耗，⑤踏面摩耗は計測可能である. AI では①熱亀裂，②剥離，また③のフラットでも外観的特徴が明確なものの検知は可能であるが，外観が明確でない摩耗の検知は困難であり，誤検知も発生している. このような結果から，レーザー計測器と AI による物体検知を併用することで①スクラッチ，③剥離，③深さが 0.2mm 以上のスポットや④フランジ摩耗，⑤踏面摩耗でも外観として特徴がある摩耗の検知は可能であるが，③深さが 0.1mm 以内のフラット，④フランジ摩耗，⑤踏面摩耗でも外観としての特徴に乏しい摩耗の検知は難しいことが分かった. しかしこれらの場合，欠陥の深さが 0.1mm 以下，外観に特徴がないことから検知ができない摩耗などは初期状態の表面欠陥であると考えられるので，たとえその時点で検知ができなかったとしてもただちに重大な事故に繋がることは考えにくい. 人による計測での計測精度が高々 0.5mm 程度であることを考慮すると，実験結果から欠陥の深さが 0.2mm 程度よりも大きければ検知ができており，作業者が人力で検査を行うよりも検知精度は高く，検知に要する時間も短くなるため十分な効果であると考える.

Table 3-7 表面欠陥検知結果

| 欠陥種類 | 検知方法 | | |
|---|---|---|---|
| | レーザープロファイルセンサー | AIによる物体検知 | 注記 |
| ① 熱亀裂 | × 検知不可 | ○ 検知可能 | |
| ②剥離 | × 検知不可 | ○ 検知可能 | |
| ③フラット | × 検知不可 | ○ 検知可能*1 | 深さ0.1mm以下は検知不可 |
| ④フランジ摩耗 | ○ 検知可能 | × 検知不可 | 深さ0.2mm以上は検知可能 |
| ⑤踏面摩耗 | ○ 検知可能 | × 検知不可 | 深さ0.2mm以上は検知可能 |
| ⑥深い傷 | ○ 検知可能 | ― 対象外*2 | |

*1；外観的特徴が見えるものは検知可能

*2；深い傷は実際の車輪には存在しないことが通常であり，レーザー計測器で容易に発見できる． そのため深い傷を発見するためのAIモデルは作成しなかった.

本研究における実験の結果から以下の考察が得られる.

レーザー計測器では亀裂などのように幅が 0.1mm 以下のものは計測ができないが, AI による物体検知ではそれらの欠陥の検知が可能である.

2 章で実施したエッジ検出と AI の組み合わせにより, 偽陽性/偽陰性を減らすことで品質管理が強化され, 欠陥検出の全体的な有効性が向上する. さらにこの統合により, 両方の技術の長所を活用し, それぞれの短所を補いあうことで, 欠陥検出のためのロバストで信頼性の高いシステムも実現が可能となる.

レーザー計測とマシンビジョンの組み合わせの例として剥離と踏面摩耗を含む車輪を計測した場合の結果を Table 3-8 に示す. 表面欠陥の検知にはビデオカメラを用いており, YOLO ではリアルタイムでの物体検知も可能である. また, レーザーによる計測とマシンビジョンによる撮影は時刻を同期させて実施されているため, 検出結果を Table 3-8 のように示し, メンテナンスの必要性を示すものとできれば, 有用なものとなる.

表面欠陥判定用 AI モデルを計測用車両試験片の表面欠陥判定用と実車両に発生している表面欠陥判定用の 2 種類を作成した. 実車両の表面欠陥を含む画像は AI による学習を行うだけの量の画像を入手するのが困難であることから, 本研究では AI の学習のための表面欠陥はアルミ板を用いて機械加工で付与したものを使用している. アルミ板に付与した表面欠陥として①熱亀裂, ②剥離, ③フラット（摩耗の代表として扱う）を用いて AI モデルを作成し, 欠陥判定を行うことができる AI モデルを作成することができた. 第 2 章, 第 3 章の実験でそれぞれ使用した AI モデルの分類について Table 3-9 に示す. アルミ板上に再現した欠陥でも AI モデルを作成して欠陥の検出を実施できている. しかし, 今

後は実車輪表面の欠陥画像を多数収集して実際の表面欠陥を検知できる AI モデルを作成する必要がある.

Table 3-8 欠陥検知例

| 欠陥種類 | 判定 | 備考 |
|---|---|---|
| 熱亀裂 | － | |
| 剥離 | △ | 検知数 ＝3 |
| フラット | － | |
| フランジ摩耗 | － | |
| 踏面摩耗 | × | 摩耗量 ＝3.0mm |

欠陥判定の例；“－“ 異常無し，“△”許容，“×”メンテナンス必要
※欠陥判定基準は各鉄道事業者によって異なる．

Table 3-9 AI モデルの分類について

| 使用された章 | 第 2 章 | 第 3 章 |
|---|---|---|
| 欠陥種類 | 実車輪データ | アルミ板に<br>再現したデータ |
| ① 熱亀裂 | － | ○ |
| ② 剥離 | ○ | ○ |
| ③ フラット | － | ○ |
| ④ フランジ摩耗 | － | フラットと同形状とした |
| ⑤ 踏面摩耗 | － | フラットと同形状とした |

※ “○” AI モデルを作成したもの． ”－“ AI モデルを作成しなかったもの．

フラットを含む摩耗に分類される表面欠陥については明確な外観的特徴を有するもののみが AI で検知が可能である． フラットや摩耗の発生直後で外観的特徴が明確であれば AI によって検出可能だが，フラット発生後に走行を続けることでフラットの境界部など外観的特徴がわかり辛くなると検出が困難になる．

このようにレーザー計測器，マシンビジョンそれぞれ有効に検出可能なものと有効でないものがあることを実験によって確認し，レーザー計測器とマシンビジョンを組み合わせて欠陥の検出を行うことが有効であることは実証できた．本研究では検出精度の限界値を確認したが，実際のメンテナンスではフランジ部分，踏面部分に関してそれぞれ摩耗量のクライテリアが設けられており，また剥離などの欠陥についても一定面積内での大きさや個数などのクライテリアが定められている．今後はこれらのクライテリアと検出結果の比較を行い，車輪削正の必要性を検知するようなシステムとする必要があると考える．

熟練作業員の手作業に強く依存している鉄道車両のメンテナンスにおいて，自動化，省力化は重要な課題のひとつであり，レーザー計測器とマシンビジョンを統合した検査手法が車両の運行に影響を及ぼす表面欠陥の検査に有効であることを確認できた．

次に本研究の成果と，将来の課題について述べる．

### 3.6.1 本研究の結果

本研究によって得られた成果を以下の通りまとめる.

- 0.2mm 以上の深さのある欠陥は検出可能である.
- 欠陥の深さが 0.5mm 以上ある欠陥であれば計測誤差 0.1mm 以内での計測が可能である.（この精度での計測は手動では不可能である）先行研究での計測精度と比較しても高い精度での計測が達成できており，本研究の優位性が認められる.
- レーザープロファイルセンサーと AI による物体検知を組み合わせた表面欠陥検出は同じ範囲をレーザーで計測し，AI との複合にて判定を行うことで，誤検知が低減できることを示した.
- AI を用いることで，Fig. 3-9 のように円形や楕円形の欠陥を検出することができる．本研究で作成した AI モデルの Precision は 0.974～0.996 であり，Recall は 1.000 であった．この結果は先行研究と比較しても高い精度での検出が実現できており，本研究の優位性が認められる.

### 3.6.2 将来の課題

本研究を実際の車輪の点検作業に応用するためには，以下の課題があり，将来解決する必要がある.

- 試験片には機械加工によって表面欠陥を付与しているため，数マイクロメートルサイズの小さな傷の再現はできていない.

- 直線状の傷や円形・楕円形の傷，また剥離，摩耗，フラット，熱亀裂など，様々なタイプの車輪表面欠陥に限定されず他のタイプの表面欠陥を検出する手法の検討が必要.
- 小さなスクラッチを含む画像データを用意して，それを判定可能な AI モデルを作成する必要がある.
- AI モデルは，車輪表面の自動検査を実現するために，継続的な学習を実行する必要がある．Table 3-7 に示すように, これらの摩耗に類する欠陥検出は，深さが 0.2mm 以上ある場合にはレーザーセンサーで検出ができる． しかし 0.1mm 以下の表面欠陥の場合には計測誤差との判別が難しくレーザーセンサーの測定精度のさらなる向上が望まれる.
- レーザー計測時のノイズ除去をノイズフィルターを用いて実施する検討が必要となる.
- AI モデルは, 追加の対象を検出するための継続的な学習を実行する必要がある． 今回検出対象としなかった踏面シェリング[4]なども画像データを集めることで判別可能になると考える.

自動検査システムとして，画像変換，エッジ検出，AI など，さまざまなマシンビジョン理論を組み合わせて使用することがそれぞれを個別で実施するよりも有効であると示すことができたと考える． 今回提案した手法は鉄道の安全を維持するのに有効であり，自動検査手法を導入することによって車両の状態を把握できるようになり，現在実施されている定期的な検査（Time-based

maintenance （TBM））から状態監視検査（Condition-based maintenance （CBM））への移行を可能とする手段[73]としての利用が期待される．

本研究では AI モデルを代表的な欠陥形状に対応できるように試験片に再現した表面欠陥を使用して AI を開発したが，今後は実際の欠陥形状の画像を可能な限り多く入手して熟練の検査員が目視で判別しているような欠陥を検知できるような AI モデルを作成する必要がある． 実際の表面欠陥検知の AI モデルとしては，今回は剥離のみについて実施したが，熱亀裂やフラットなどについても多くの画像を収集して AI モデルを作成する必要がある． 車輪表面の欠陥を判定するための AI モデルを作成するためには多くの画像データが必要となるが，本研究で示したように欠陥を人工的に創り出して，AI モデルを作成する手法は様々な検査手法から欠陥を検知する手段を見つけるために有効であると考えている．

## 3.7 結論

本章では車輪踏面形状を模擬した試験片を用いたレーザー計測と物体検知 AI モデルを用いた表面欠陥検出手法の判定を行い，レーザー計測とマシンビジョンそれぞれの欠点を補い，鉄道車両の安全な運用に影響を及ぼす表面欠陥の検出を行う手法が実施可能であることを示した． 本研究で実施した手法を基にして鉄道車両の安全な運用に影響を及ぼす表面欠陥の検知手法を確立し，鉄道車両を安全に運用するために有効なメンテナンス手法の研究に貢献する．

# 第 4 章　結論

第 2 章及び第 3 章で実施した研究結果から，本研究では，意図的な欠陥を有する試験片を用いて，動的条件下で車輪表面の欠陥を判定する自動検査システムの実現可能性を示した．　本研究では，車両の運行に影響する 5 種類の表面欠陥である①熱亀裂，②剥離，③フラット，④踏面摩耗，⑤フランジ摩耗に着目し，レーザー計測器と AI による物体検知それぞれによる計測可否を確認した．

その結果として AI では検知が難しい摩耗系の検知にはレーザー計測の方が適しており，その逆に亀裂などの線の幅が狭いものの検知には AI が適していることが分かった．　レーザー計測器と AI による物体検知をハイブリッドすることにより，それぞれの欠点を補いながら，5 種類の車両の運動に影響を及ぼす欠陥の検知を行う手法の提案を行い，レーザーセンサーとマシンビジョンを組み合わせた検査システムとして自動検査システムの一部として実施可能であることを示した．

熟練作業員の手作業に強く依存している鉄道車両のメンテナンスにおいて，自動化，省力化は重要な課題のひとつであり，本研究で提案する手法を取り入れることで，鉄道車両 1 両あたり数時間を要している車輪表面の検査を車両通過時の数秒で実施することが可能となり，大幅な省力化が可能になる．マシンビジョンにより，割損に発展する表面欠陥である熱亀裂や剥離を検知することが可能となるため，走行中の脱線を防止することが可能となる．本研究で研究した手法を更に発展させて鉄道車両の安全性確保とメンテナンスの効率化向上に貢献する所存である．

# 謝辞

この論文を完成させるまでに多大なるご支援，ご助言を頂きましたすべての方々に心よりお礼申し上げます.

最初に，私の指導教員である北海道大学大学院工学研究院の江丸貴紀准教授には，私を研究室に入れて頂きましたことを感謝致します． 研究の指針を示していただき，本論文の完成に至るまで，丁寧にレビューを頂きました． 先生の厳しくも温かいご指導のもと，研究を行うことができましたことを深く感謝しております.

また，苫小牧工業高等専門学校の小林幸徳校長先生は私が研究室に入るきっかけを創って下さり, 社会人博士を始めるにあたって多大なるアドバイスを頂くことができ，感謝しております． 小林先生が苫小牧高専に移られた後にも投稿論文について丁寧にレビュー頂き，コメントを頂き，研究指針を示していただいたことを感謝致します.

本研究を開始する際に研究指針を始めとしてアドバイスを頂きました東北大学大学院工学研究科 Ankit Ravankar 特任准教授に感謝致します． 実験の指針，論文のまとめ方について詳細にコメントを頂き，これまでの論文の執筆において多大なるご支援を頂きました． Ankit 先生が東北大学工学部に異動された後にも引き続きご支援を頂きましたことを深く感謝しております.

北見工業大学機械知能・生体工学コースの Abhijeet Ravankar 准教授にも大変お世話になりました． 特にマシンビジョンの研究を行うにあたり，使用するツールについてアドバイスを頂き，研究の方法について多大なるアドバイスを頂

くことができました． マシンビジョンを用いた画像解析を成し遂げることができましたのも Abhijeet 先生の多大な助けのおかげであり，深く感謝致します.

また, 私の所属しております川崎車両株式会社の皆様に深く感謝致します．私が社会人学生として研究を行うに際してサポート頂きましたことを深く感謝致します.

最後に，私が社会人学生として研究を行うことを温かく支援頂き，励ましてくれた家族に深く感謝致します.

このような多くの方の存在が無ければ，この論文を完成させることはできなかったと考えます.

最後に，本研究に関わられた全ての方々にお礼を申し上げます.

ありがとうございました.

令和 6 年 8 月 14 日

江本 剛

# 参考文献

[1] 村田 均，鉄道車両メンテナンスシステム，東芝レビュー，Vol. 55，No. 9，pp. 40-43 （2000）

[2] 石塚 弘道, 車両のメンテナンス, 第 20 回鉄道総研講演会, pp. 59-67（2007）

[3] 長峰 望，坪川 洋友，合田 航，前田 梨帆，加藤 爽，糸井 謙介，列車前方画像を用いた画像解析による軌道設備の検査，鉄道総研報告，Vol. 36，No. 12，pp. 7-12 （2022）

[4] 岡方 義則，鉄道用車輪設計技術の現状と今後の展望，新日鉄住金技報 第 395 号 （2013）

[5] 半田 和行, 車輪の安全性を支える技術, Railway Research Review, Vol. 68, No. 12，pp. 18-21 （2011）

[6] 半田 和行，車輪の損傷メカニズムに迫る，Railway Research Review，Vol. 53，No. 1，pp. 1-3 （2013）

[7] 石田 誠，レールと車輪の断面形状と応力，Japan Railway Engineering Association，2015，Vol. 58，No. 1，pp. 52-56 （2015）

[8] 中橋 順一，車輪とレールの接触位置を探る，鉄道総研レポート，Vol. 69, No. 4（2012）

[9] 山本 大輔，C. Hua，車輪踏面の微小凹凸が鉄道車両の走行安定性に及ぼす影響，日本機械学会論文集，第 79 巻，第 803 号，pp. 2338-2350 （2013）

[10] H. Ishida，M. Matsuo，“Safety Criteria for Evaluation of Railway Vehicle Derailment”， Quality Report of RTRI，Vol. 40，pp. 18-25 （1999）

[11] 中橋 順一，三宮 大輝，川上 正一郎，谷本 啓，車輪摩耗形状の生成メカニズムの基礎検討，鉄道総研レポート，Vol. 30，No. 11（2016）

[12] 半田 和行，牧野 一成，西森 久宜，小原 孝則，宮内 瞳爾，柿嶋 秀史，車輪踏面熱亀裂の実験的再現と生成条件，鉄道総研報告，第 24 巻，第 8 号，pp. 30-40（2010）

[13] 半田 和行，森本 文子，深貝 晋也，柿島 秀史，車輪踏面熱亀裂の発生メカニズムと対策法，鉄道総研報告，Vol. 25，No. 10 （2011）

[14] 山本 三幸，鉄道関連製品の疲労に関わる研究開発とその展望，新日鉄住金技報，No. 395 （2013）

[15] 真木 康隆，曄道 佳明，山本 勝太，池内 健義，車輪フラット端部形状が回転車輪と軌条輪との接触状態および衝突挙動に与える影響評価，日本機械学会論文集，85 巻，875 号 （2019），DOI: 10.1299/transjsme.19-00003

[16] J. Hua，X. Zhao，C. Su，R. Ren，“Study on the Mechanism of Wheel Corrugation Based on Experiment and Simulation”，IEEE 21st International Conference on Computer Supported Cooperative Work in Design（2017），DOI: 10.1109/CSCWD.2017.8066757

[17] A. K. Ng，L. Marta，G. Sun，“Dynamic Modelling and Acceleration Signal Analysis of Rail Surface Defects for Enhanced Rail Condition Monitoring and Diagnosis”，2019 4th International Conference on Intelligent Transportation Engineering （2019），DOI: 10.1109/ICITE.2019.8880246

[18] Japan Transport Safety Board，Report No. RA2009-3-1 （online），available from < https://jtsb.mlit.go.jp/jtsb/railway/detail.php?id=1747>，（accessed on 19 May，2024）.

[19] 高澤 克朗，鉄道用車軸と車輪の特性，鉄と鋼，第 72 巻，第 7 号，pp. 732-739 （1986）

[20] Yue Yang, Long Liu, Bing Yi, and Feng Chen, “An Accurate and Fast Method to Inspect Rail Wear Based on Revised Global Registration”, IEEE Access, Vol. 6, pp. 57267 – 57278 (2018), DOI: 10.1109/ACCESS.2018.2873903

[21] 笹間 宏, 鉄道における画像処理の応用, 計測と制御, Vol. 27, No. 12, pp. 1107–1114 (1988)

[22] 御堂 義博, 中前 幸治, 深層学習を用いた画像解析・異常検知に関する一考察, 日本信頼性学会誌, Vol. 40, No. 2, (2018), DOI: 10.11348/reajshirai.40.2_81 2018

[23] L. Jinlong, D. Fan, G. Xiaorong, “Wheel Profile and Tread Surface Defect Detection Based on Phase Measuring Profilometry”, 18th International Wheelset Congress (IWC), pp. 71-75 (2016)

[24] Yangkai, Gaoxiaorong, Dailixin, Xieliming, Zhangyu, Pengchaoyong, Pengjianping, “Research on the principle of railway wheel out-of-roundness on-line dynamic detecting system based on Laser measurement”,
IEEE Far East Forum on Nondestructive Evaluation/Testing, pp. 217-220 (2014)

[25] Q. Xu, Q. Zhao, G. Yu, L. Wang, T. Shen, "Rail Defect Detection Method Based on Recurrent Neural Network" 39th Chinese Control Conference (2020), DOI:10.23919/CCC50068.2020.9188823

[26] Z. Zhang, S. Shao, Z. Gao, "A Novel Method on Wheelsets Geometric Parameters on line Based on Image Processing", International Conference on Measuring Technology and Mechatronics Automation, pp. 257-260 (2010)

[27] W. Kaihua, B. Tao, "Optimal Threshold Image Segmentation Method Based on Generic Algorithm in Wheel Set Online Measurement", Third International Conference on Measuring Technology and Mechatronics Automation, pp. 799-802 (2011)

[28] S. M. M. Guzzardi, D. Younesian, M. Torabi, "A High Accuracy and High Speed Imaging and Measurement System for Rail Corrugation Inspection", IEEE Transactions on Industrial Electronics, Vol. 68, pp. 8894-8903 (2020), DOI: 10.11109/TIE.2020.3013748

[29] J. Duan, L. Luo, J. Li, X. Gao, W. Zhang, "Measuring of Train Wheel Surface Defect Based on Linear CCD Imaging", 18th International Wheelset Congress, pp. 65-70 (2016), DOI: 10.1109/IWC.2016.8068369

[30] K. Yang, L. Dai, J. Peng, H. Li, L. Xie, L. Jiang, "Railway Vehicle Wheel Profile Parameters Measurement under Incomplete Curves Conditions", 18th International Wheelset Congress (IWC), pp. 76-79 (2016), DOI: 10.1109/IWC.2016.8068371

[31] C. Alippi, E. Casagrande, F. Scotti, V. Piuri, "Composite Real-Time Image Processing for Railways Track Profile Measurement", IEEE Transactions on Instrumentation and Measurement, Vol. 49, No. 3, pp. 559-564 (2000)

[32] Xuefeng Ni, Hongli Liu, Ziji Ma, Chao Wang, Jianwei Liu, "Detection for Rail Surface Defects via Partitioned Edge Frame", IEEE Transactions of Intelligent Transportation Systems, Vol. 23, No. 6, pp. 5806-5822 (2022), DOI: 10.1109/TITS.2021.3058635

[33] X. Li, Z Cong, Y. Zhang, "Rail Track Edge Detection Methods Based on Improved Hough Transform", IEEE International Conference on Power Electronics, Computer Applications (ICPECA), pp. 12-16 (2021)

[34] G. Guo, J. Peng, K. Yang, L. Xie, W. Song, "Wheel Tread Defects Inspection Based on SVM", Far East NDT New Technology & Application Forum (FENDT) pp. 251-253 (2017), DOI: 10.1109/FENDT.2017.8584565

[35] T. Li, Z. Xing, S. Chen, “An Online Wheel Size detecting Technology Based on Laser Displacement Sensors for Urban rail Vehicles”, Proceedings of the 36th Chinese Control Conference , pp. 9983-9987 (2017) , DOI: 10.23919/ChiCC.2017.8028950

[36] F. Liu, L. Liang, C. Hou, G. Xu, D. Liu, B. Zhang, L. Wang, X. Chen, H. Du, “On-Machine Measurement of Wheel Tread Profile with the 1-D Laser Sensor”, IEEE Transactions on Instrumentation and Measurement, Vol. 70 (2021)

[37] X. Pan, Z. Liu, and G. Zhang, “On-Site Reliable Wheel Size Measurement Based on Multisensor Data Fusion”, IEEE Transactions on Instrumentation and Measurement, Vol. 68, No. 11, pp. 4575-4589 (2019)

[38] 阪急電鉄株式会社，公開特許 2009-023380，車輪形状測定装置（2010）

[39] 精研工業株式会社，公開特許 2015-215267，車輪形状測定方法と車輪形状測定装置 （2012）

[40] 日立交通テクノロジー株式会社，公開特許 2019-95228，車輪形状測定方法（2019）

[41] 株式会社日立プラントテクノロジー，公開特許 2006-226012，鉄道車両の車輪形状測定装置 （2008）

[42] 東日本旅客鉄道株式会社, 公開特許 2012-18060, 車輪形状測定方法（2012）

[43] Inspection of wheels by laser sensor website , https://hegenscheidt-mfd.com/wp-content/uploads/2011/07/Argus_II_dt.pdf （online), last accessed on May 19 (2024)

[44] M. Torabi, S. G. M. Mousavi, D. Younesian, “A High Accuracy Imaging and Measurement System for Wheel Diameter Inspection of Railroad Vehicles”, IEEE Transactions on Industrial Electronics , Vol. 65 (2018) , DOI: 10.1109/TIE.2018.2803780

[45] K. Yang, J. Peng, X. Gao, C. Peng, Y. Zhang, Z. Wang, Q. Zhao, L. Dai, “Research on the Detecting Method of CRH Wheel Flat at Low Speed”, 18th International Wheelset Congress (IWC), pp. 126-129 (2016)

[46] G. Krummenacher, C. S. Ong, S. Koller, S. Kobayashi, J. M. Buhmann, “Wheel Defect Detection with Machine Learning”, IEEE Transactions on Intelligent Transportation Systems, Vol. 19, No. 4, pp. 1176-1187 (2018)

[47] 葛田 理仁，車輪摩耗の進展状況測定技術の基礎検討，日本機械学会 第２５回鉄道技術連合シンポジウム講演論文集，No. 18-83，p. 3201 （2018）

[48] 梅原 康弘，宮原 宏平，車輪踏面形状３次元測定装置の開発，Vol. 25，No. 11，pp. 17-20 （2017）

[49] L. Fang，“Research on Image Enhancement Technology of Locomotive Wheelset based on Image Equalization and Fuzzy Theory”，IEEE 5th Image Enhancement Technology，Networking，Electronic and Automation Control Conference （ITNEC），pp. 1342–1345 （2021），DOI: 10.1109/ITNEC52019.2021.9587234

[50] H. Zhang，X. Jin，Q. M. J. Wu，Y. Wang，Z. He，and Y. Yang，“Automatic Visual Detection System of Railway Surface Defects with Curvature Filter and Improved Gaussian Mixture Model”，IEEE Transactions on Instrumentation and Measurement，Vol. 67，No. 7，pp. 1593-1608 (2018)

[51] L. Shang，Q. Yang，J. Wang，S. Li，W. Lei，“Detection of Rail Surface Defects Based on CNN Image Recognition and Classification”，International Conference on Advanced Communications Technology (ICACT)，pp. 45-51 (2018)

[52] H. Han, L. Tian, M. Li, X. Cui, C. Shang, S. Hou, "Design of Rail Surface Defect Detection System Based on LabVIEW Machine Vision", IEEE 6th Information Technology, Networking, Electronic and Automation Control Conference (2023), DOI: 10.1109/ITNEC56291.2023.100821424

[53] M. Nieniewski, "Morphological Detection and Extraction of Rail Surface Defects", IEEE Transactions on Instrumentation and Measurement, Vol. 69, No. 9, pp. 6870-6879 (2020)

[54] Z. He, Y. Wang, F. Yin, J. Liu, "Fast Surface Defect Detection Using Improved Gabor Filters", 2018 25th IEEE International Conference on Image Processing (2018), DOI: 10.1109/ICOP.2018.8451351

[55] J. Gan, Q. Li, J. Wang, H. Yu, "A Hierarchical Extractor-Based Visual Rail Surface Inspection System", IEEE Sensors Journal, Vol. 17, No. 23, pp. 7935-7944 (2017)

[56] V.R. Vijaykumar, S. Sangamithirai, "Rail Defect Detection using Gabor filters with Texture Analysis", 3rd International Conference on Signal Processing, Communication and Networking (ICSCN), pp. 76-79 (2015)

[57] H. Liu, F. Sun, J. Gu, L. Deng, “SF-YOLOv5: a lightweight small object detection algorithm based on improved future fusion mode”, Sensors Vol. 15, No. 22 (2022), DOI: 10.3390/s22155817

[58] L. Tang, L. C. Cai, K. Cheng, X. Wang, C. Luo, Y. Zhao, “Improved Yolov5n strip surface defect detection algorithm”, 2023 CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes (2023), DOI: 10.1109/SAFEPROCESS58597.2023.10295728

[59] X. Wang, J. Zhang, Y. Wang, M. Li, D. Liu, “Defect detection of track fasteners based on pruned YOLO V5 model”, 11th Data Driven Control and Learning Systems Conference (DDCLS), Chengdu, China, IEEE (2022), pp. 391–395, DOI: 10.1109/DDCLS55054.2022.9858442

[60] E. Resendiz, J. M. Hart, N. Ahuja, “Automated Visual Inspection of Railroad Tracks”, IEEE Transactions on Intelligent Transportation Systems, Vol. 14, No. 2, pp. 751-760 (2013)

[61] Y. Li, H. Trinh, N. Haas, C. Otto, S. Pankanti, “Rail Component Detection, Optimization, and Assessment for Automatic Rail Track Inspection” IEEE Transactions on Intelligent Transportation Systems, Vol. 15, No. 2, pp. 760-770 (2014)

[62] P. De Ruvo, A. Distante, E. Stella, F. Marino, “A GPU-based Vision System for Real Time Detection of Fastening Elements in Railway Inspection”, 16th IEEE International Conference on Image Processing (ICIP) (2009)

[63] W. Li, Z. Shen, P. Li, “Crack detection of track plate based on YOLO”, 12th International Symposium on Computational Intelligence and Design (ISCID), Hangzhou, China, 2019, pp. 15–18 (2019), DOI: 10.1109/ISCID.2019.10086

[64] H. Zhang, Y. Song, Y. Chen, H. Zhong, L. Liu, Y. Wang, “MRSDI-CNN: Multi-Model Rail Surface Defect Inspection System based on Convolutional Neural Networks”, IEEE Transactions on Intelligent Transportation Systems, Vol. 23, No. 8, pp. 11162–11177 (2022), DOI: 10.1109/TITS.2021.3101053

[65] H. Yang, Y. Wang, J. Hu, J. He, Z. Yao, Q. Bi, “Deep learning and machine vision-based inspection of rail surface defects”, IEEE Trans Instrumentation and Measurement, Vol. 71, pp. 1–14 (2021), DOI: 10.1109/TIM.2021.3138498

[66] L. Liu, B. Zhou, G. Liu, D. Lian, R. Zhang, “YOLO-Based Multi-Model Ensemble for Plastic Waste Detecting along Railway Lines”, IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium (2022), DOI: 10.1109/IGARSS46834.2022.9883308

[67] Q. Li, and S. Ren, "A Real-Time Visual Inspection System for Distance Surface Defects of Rail Heads", IEEE Transactions on Instrumentation and Measurement, Vol. 61, No. 8 (2012)

[68] T. Emoto, A. A. Ravankar, A. Ravankar, T. Emaru, Y. Kobayashi, "Automatic Inspection of Railcar Wheels Using Laser and Image Sensor", 2021 60th Annual Conference of the Society of Instrument and Control Engineers of Japan, pp. 1282-1287 (2021)

[69] T. Emoto, A. A. Ravankar, A. Ravankar, T. Emaru, Y. Kobayashi, "Automatic Dimensional Inspection System of Railcar Wheelset for Condition Monitoring", 2022 61st Annual Conference of the Society of Instrument and Control Engineers of Japan, pp. 899-904 (2022)

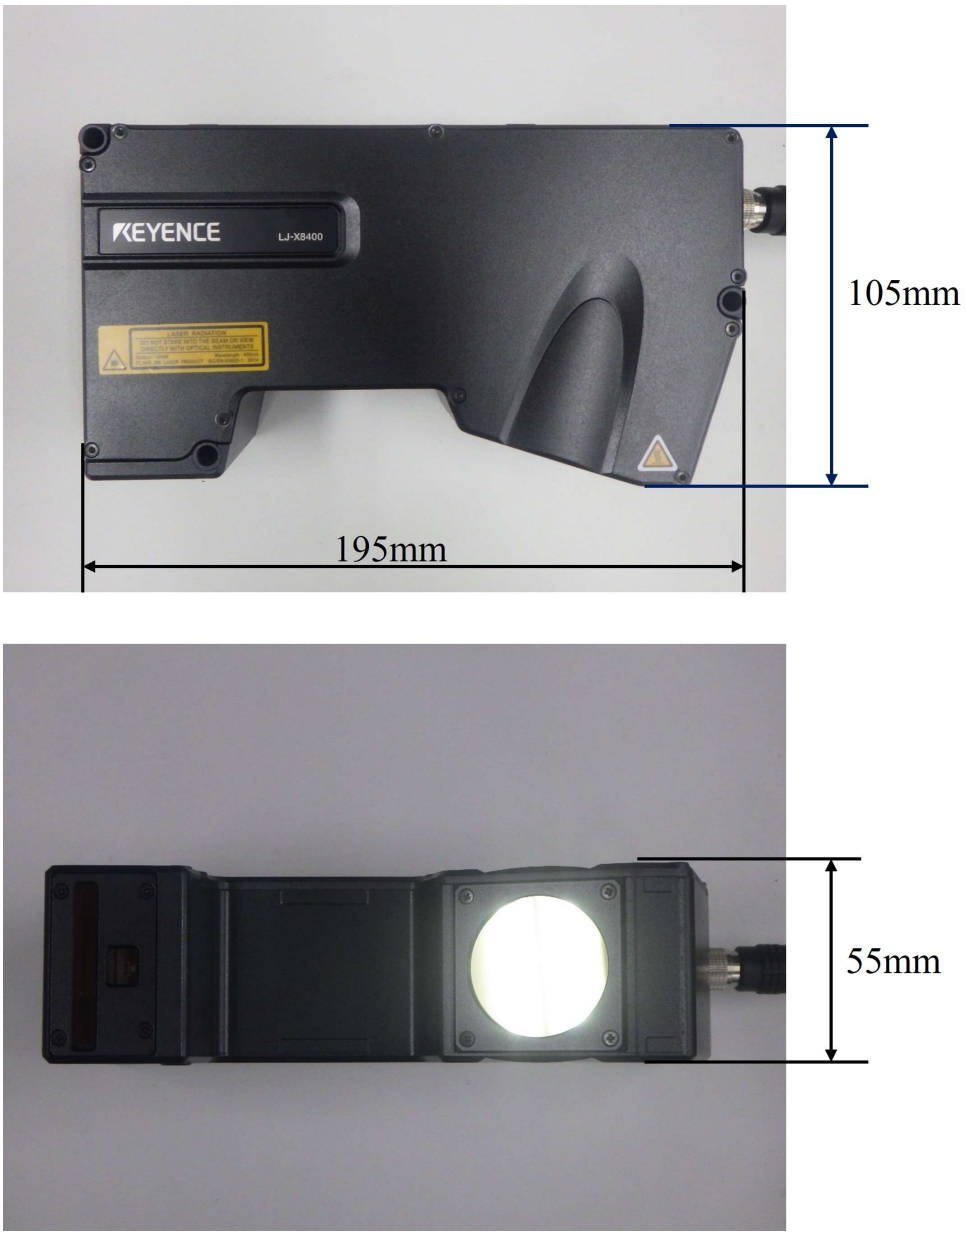
[70] T. Emoto, A. A. Ravankar, A. Ravankar, T. Emaru, Y. Kobayashi, "Wheel surface defect detection method using laser sensor and machine vision", 62nd Annual Conference of the Society of Instrument and Control Engineers of Japan, pp. 1166–1171 (2023)

[71] T. Emoto, A. A. Ravankar, A. Ravankar, T. Emaru, Y. Kobayashi, “Automatic inspection of wheel surface defects using a combination of laser sensors and machine vision”, SICE Journal of Control, Measurement, and System Integration. Volume 17, pp. 57–66 (2024), DOI: 10.1080/18824889.2024.2314800

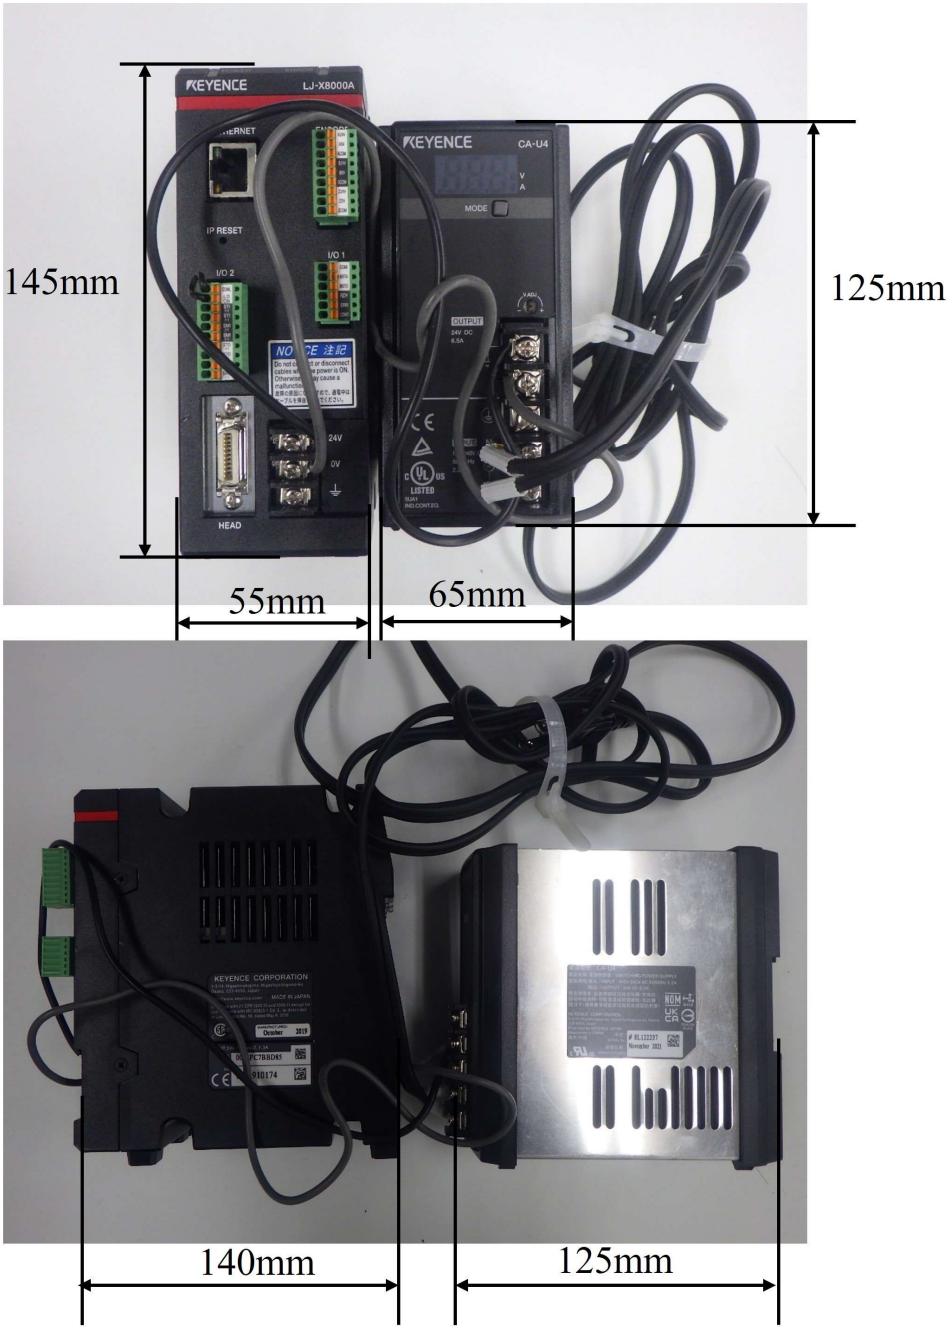
[72] T. Emoto, A. A. Ravankar, A. Ravankar, T. Emaru, Y. Kobayashi, “A method for detecting wear and damage on railcar wheel tread surface using a combination of laser measurement and machine vision”, Mechanical Engineering Journal, ISSN-L: 2187-9745 (2024) Bulletin of the JSME, Vol. 11, No. 3, DOI: 10.1299/mej.23-00352

[73] H. Yoshida, S. Yamamoto, Y. Komatsu, H. Kaneko, S. Motohyoshi, T. Konishi, “Research and Development for Further Utilization of Track Facility Monitoring Device”, JR EAST Technical Review, No. 9, pp. 27-32 (2020)

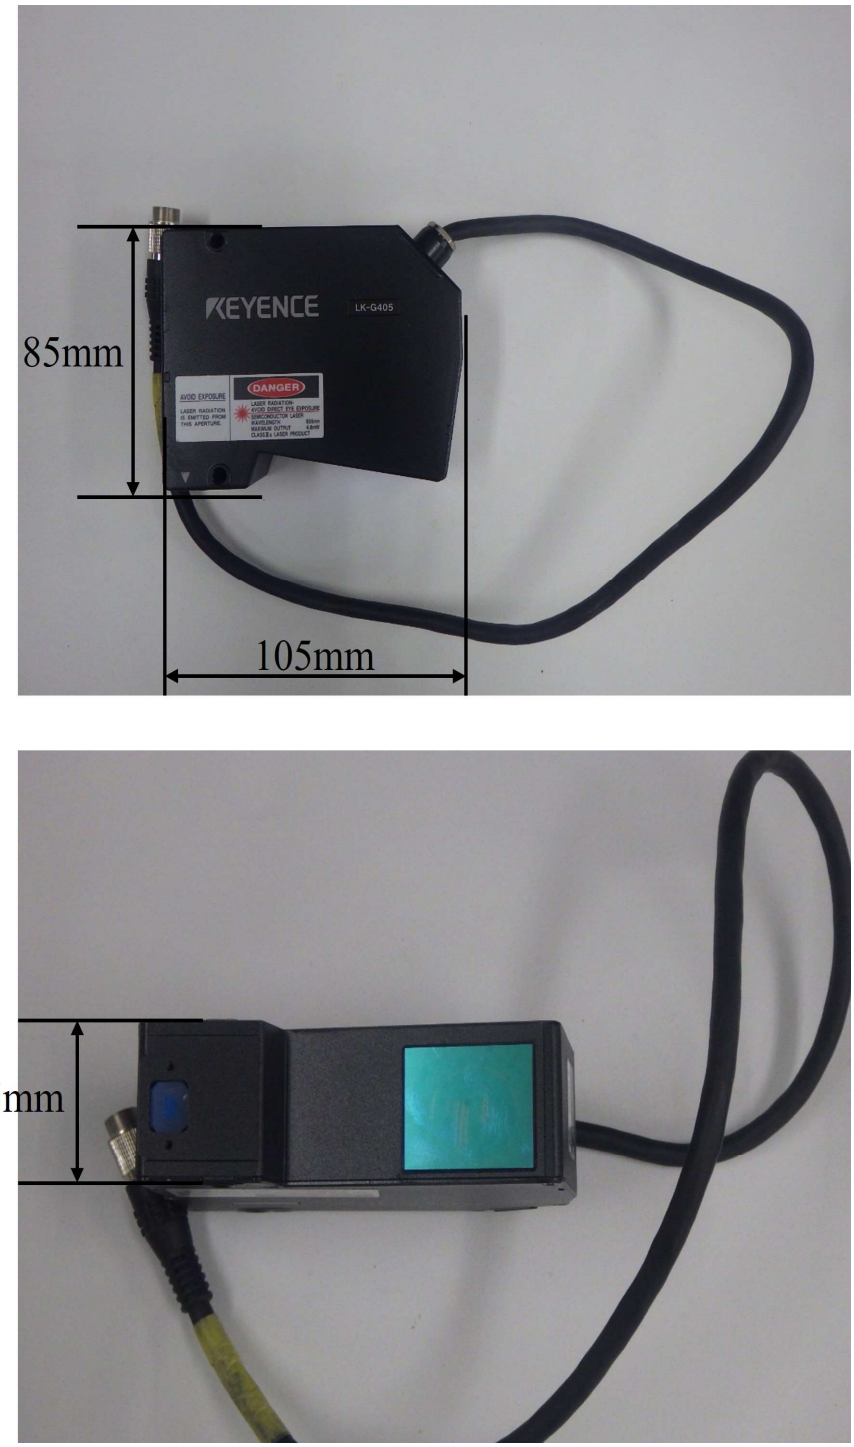
# Appendix A実験に用いた器具の写真



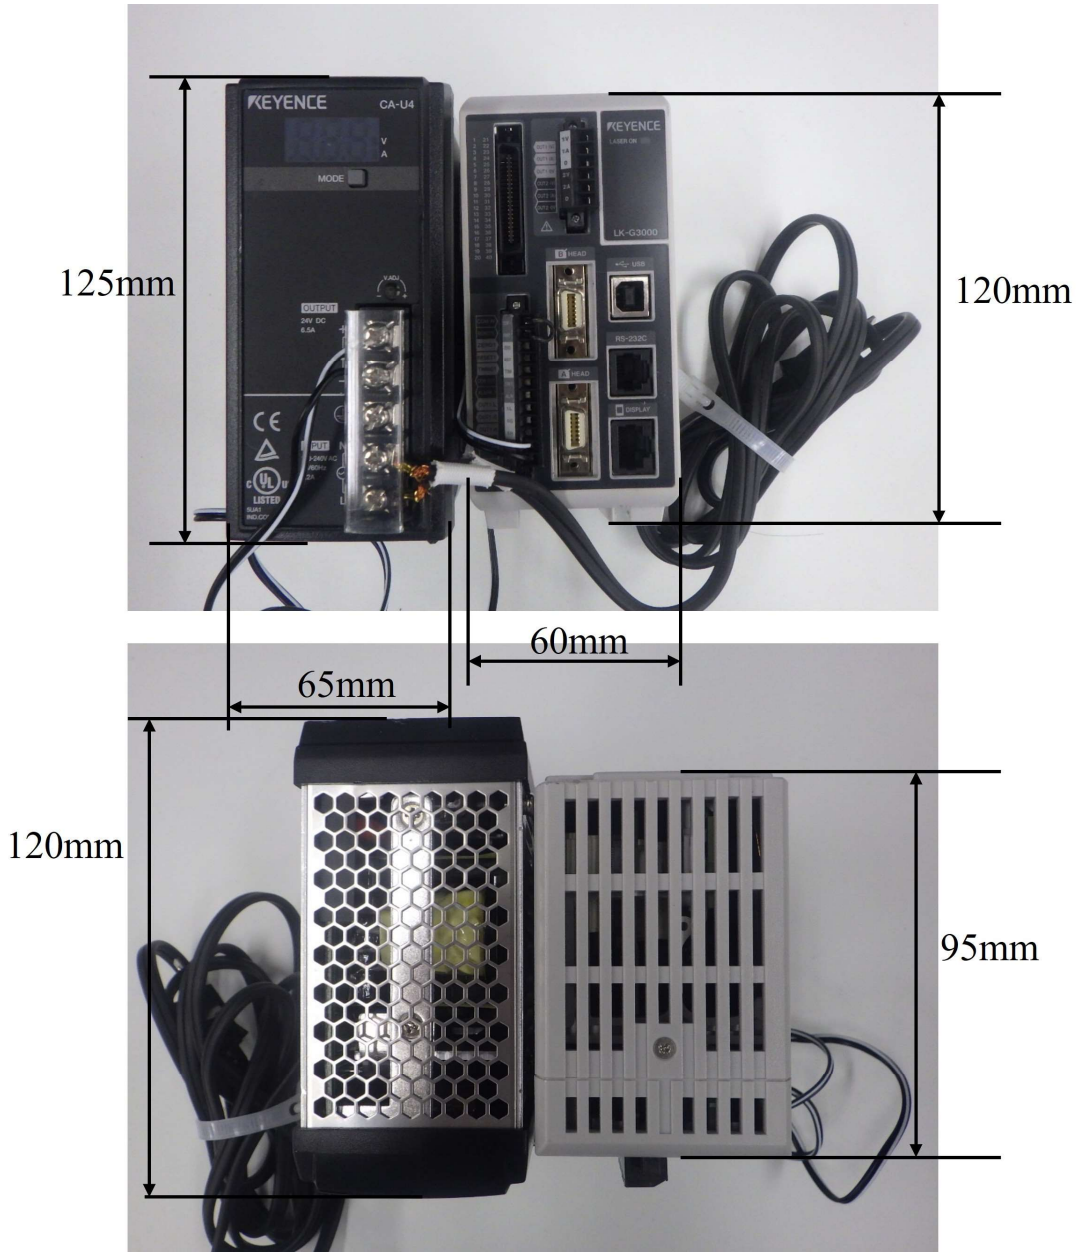

Appendix A Fig. A-1 レーザープロファイルセンサー LJ-X8400



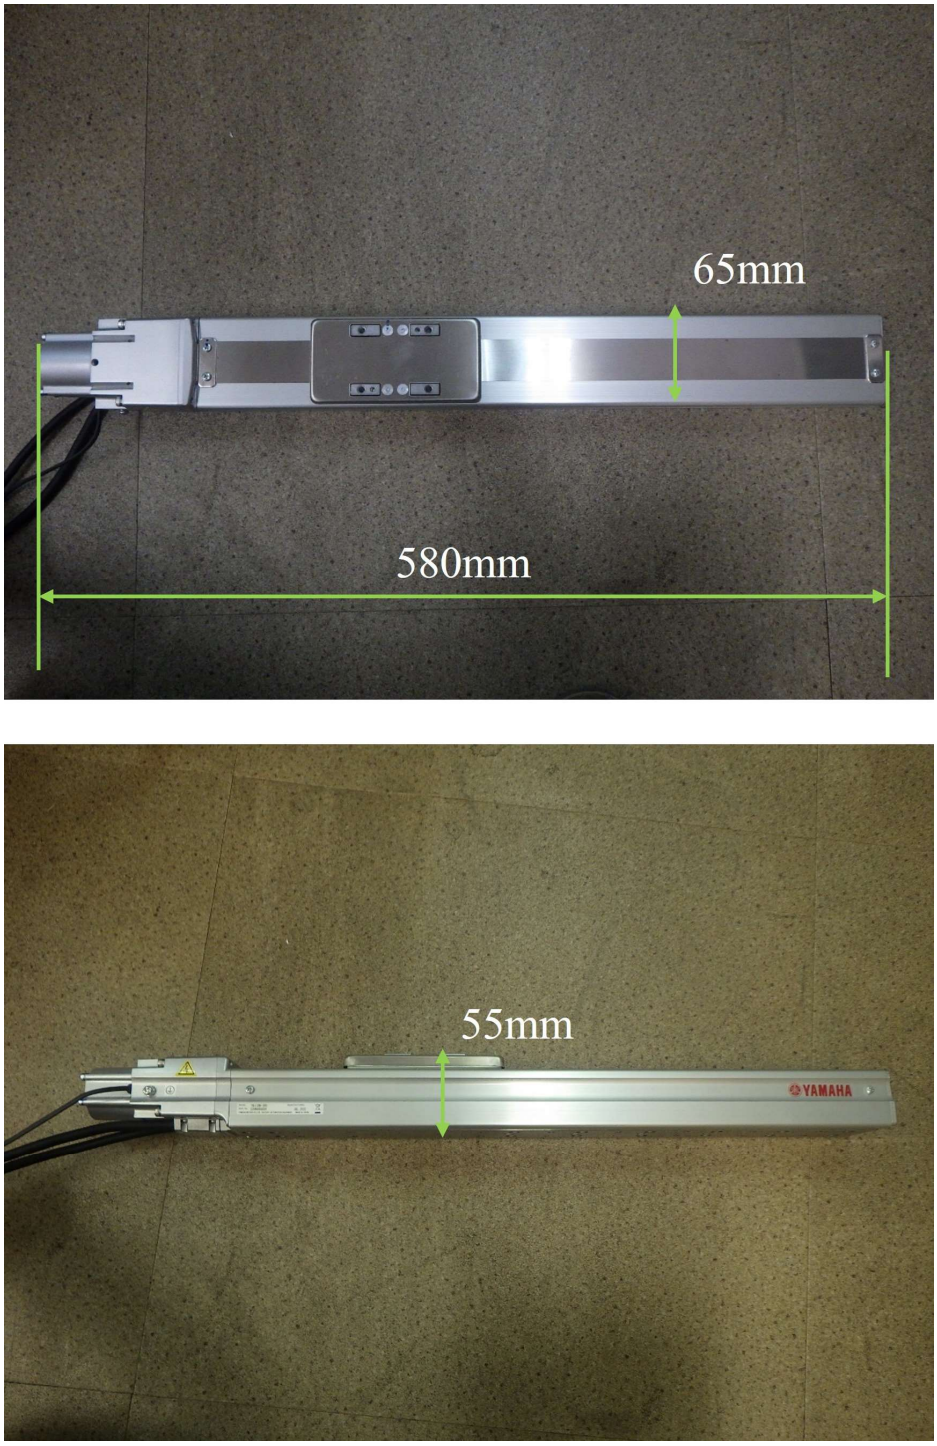

Appendix A Fig. A-2 レーザープロファイルセンサーコントローラ LJ-X8000A




Appendix A Fig. A-3 レーザー距離センサー LK-G405




Appendix A Fig. A-4 レーザー距離センサーコントローラ LK-G3000




Appendix A Fig. A-5 試験片移動用スライダ

# Appendix B 実車輪のプロファイル寸法計測

車両ピットではレーザー計測器を車輪踏面に対して垂直に設置することができないため，Fig. B-1に示すように計測は斜め方向からとなる．2022年に実車輪のプロファイルを計測した際の結果の処理について述べる．

ステップ 1; Fig. B-2 に示すように計測結果から点 $P_1$ ($x_1$，$y_1$)および $P_2$ ($x_2$，$y_2$)を抜き出す. この $P_1$, $P_2$ は車輪の垂直面に位置する点から選択する. そして点 $P_1$ および $P_2$ の角度 $\theta_5$ および回転角度 $\theta_6$ を三角形の内角の和の公式より求める.

ステップ 2; 点 $P_3$ ($x_3$，$y_3$)および点 $P_4$ ($x_4$，$y_4$)の位置を次の計算式で点 $P_1$ ($x_1$, $y_1$) および点 $P_2$ ($x_2$，$y_2$)を回転させて求める:

$$x_3 = x_1\cos\theta_6 - y_1\sin\theta_6, \tag{B1}$$

$$y_3 = y_1\cos\theta_6 + x_1\sin\theta_6, \tag{B2}$$

$$x_4 = x_2\cos\theta_6 - y_2\sin\theta_6, \tag{B3}$$

$$y_4 = y_2\cos\theta_6 + x_2\sin\theta_6. \tag{B4}$$

ステップ 3: 回転後の位置点 $P_6$ をオリジナルの CAD データ位置から求め，点 $P_5$ が点 $P_6$ に一致するように移動させる.

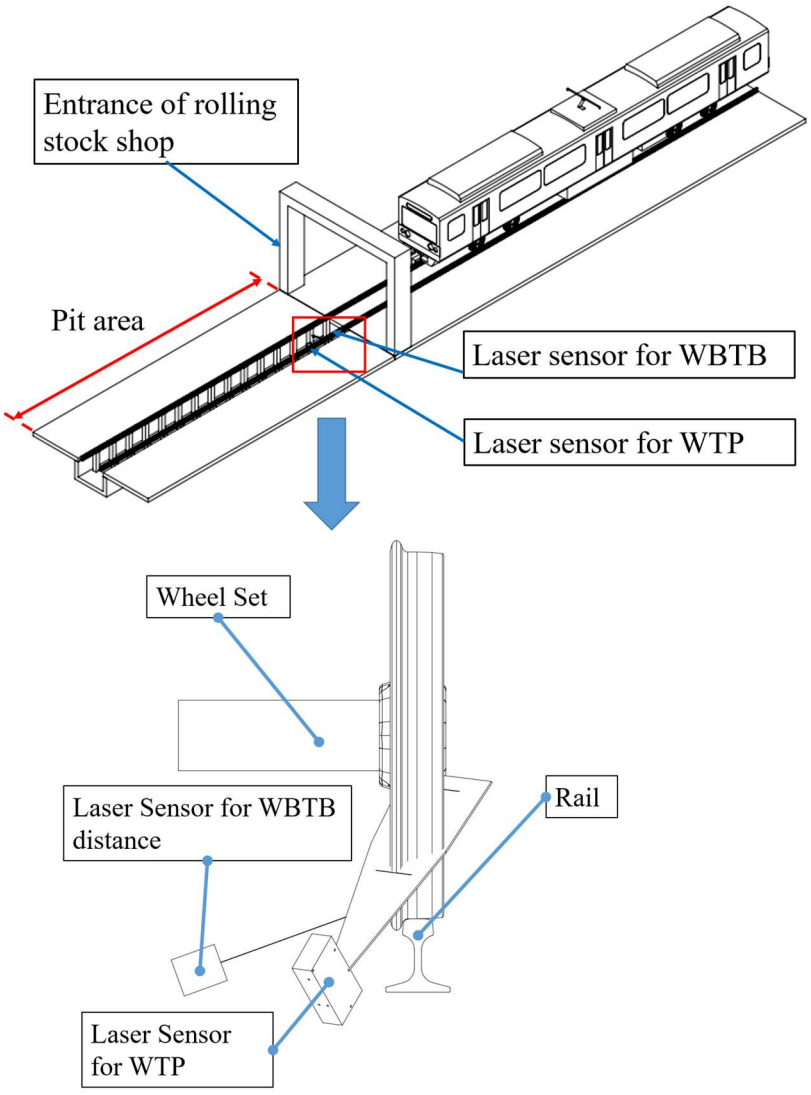
ステップ 4: ステップ 1 から 3 の方法を各計測について実施する.

参考例を以下に示す.
点 $P_1$ ($x_1$，$y_1$)および $P_2$ ($x_2$，$y_2$)がそれぞれ(20，$-127.09$)，(30，$-153.96$)の時
$P_1$ ($x_1$，$y_1$) = (20，$-127.09$),
$P_2$ ($x_2$，$y_2$) = (30，$-153.96$),

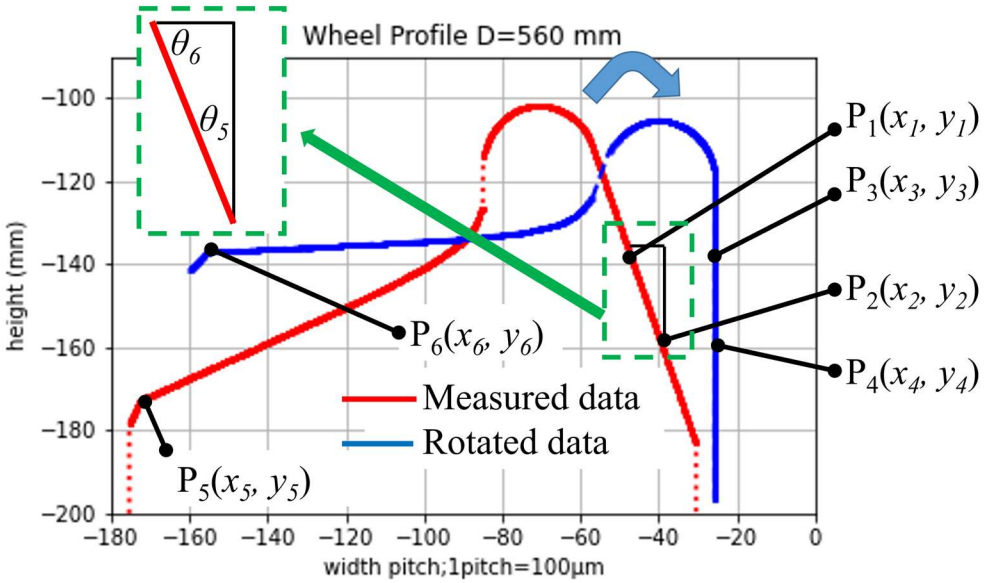
$\theta_5 = -69.59°$,　$\theta_6 = (180 - 90 - \theta_5) = 20.44°$がそれぞれ算出される.

その結果，点 $P_3$ ($x_3$，$y_3$)および $P_4$ ($x_4$，$y_4$)がそれぞれ以下となる.
$P_3(x_3, y_3) = (-25.58, -126.08)$,
$P_4(x_4, y_4) = (-25.58, -154.76)$.

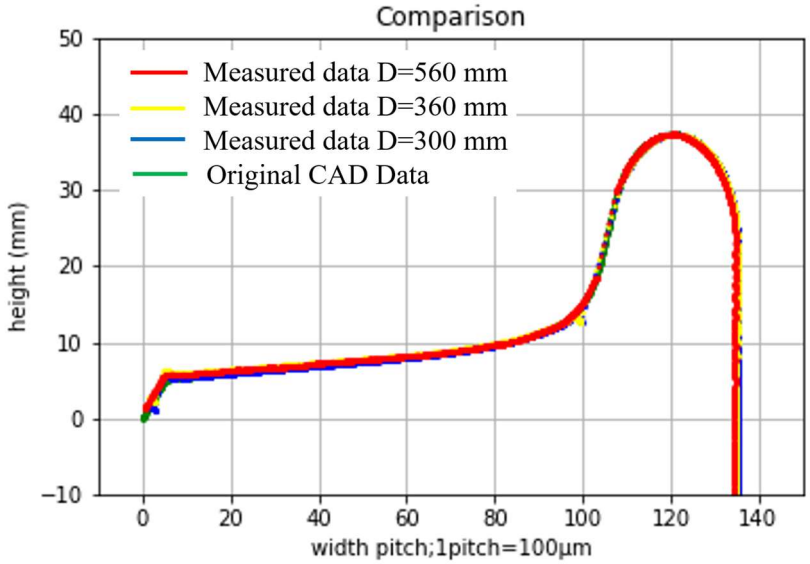
Fig. B-3 にレーザープロファイルセンサーと車輪表面の位置 D がそれぞれ $D =$ 300, 360, および 560mm の時の計測結果を示す. 計測結果はオリジナルの CAD データと比較される. 計測された車輪はほぼ新品であったため，プロファイルの計測結果に差は見られなかった.




Appendix B Fig. B-1 車両ピット内での撮影イメージ




Appendix B Fig. B-2 実車輪プロファイルデータの変換

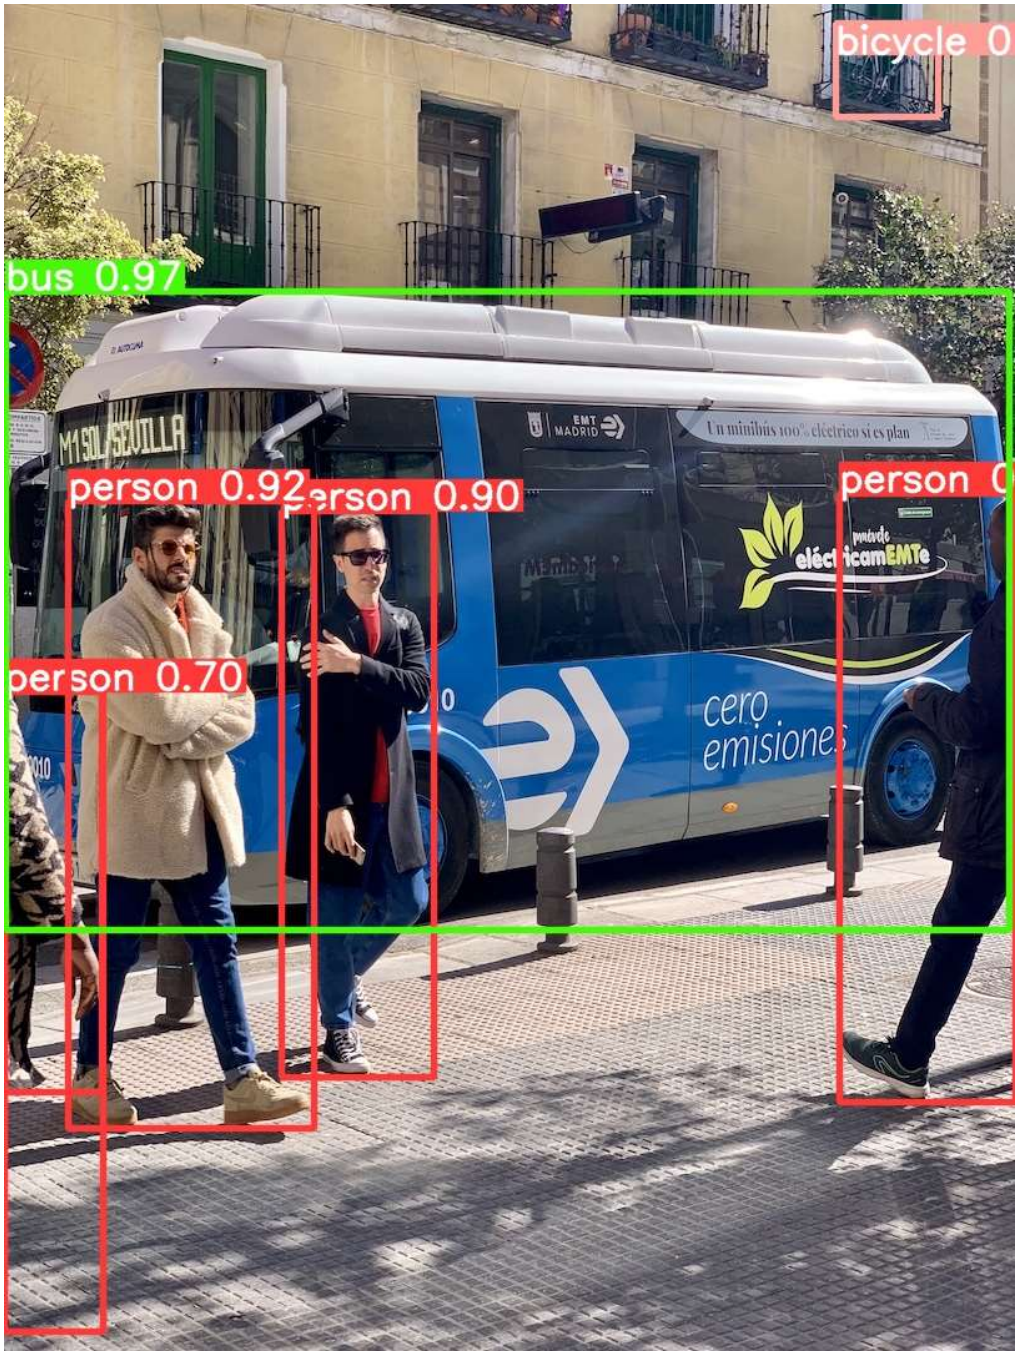



Appendix B Fig. B-3 実車輪プロファイルデータ変換結果

# Appendix C 物体検出における YOLO の特徴について

YOLO を用いた物体検出では，画像や動画内に映る検知対象(人や車，動物など)とその画像内の位置を検知することができる．取得したイメージデータやビデオデータを YOLO の学習済みモデルに流すことで，画像内の複数の物体検出を行うことが可能となる．処理速度が速いことも YOLO の特徴であり，YOLO のプログラムを動作させて PC に接続した外部カメラ画像を学習済モデルに流すことでリアルタイムでの物体検知を行うことが可能となる． YOLO で物体検知を実施した例として Fig. C-1 に示すように画像内のバスや人，スケートボードなどが検出されている．このように画像を入力することで検出された物体がバウンディングボックス（それぞれの物体を囲む枠）で囲まれ，そのバウンディングボックスの画像内におけるピクセル情報を出力することができるので，画像内における各物体の位置検出が可能となる.YOLO の特徴として，学習済のモデルを元にして，少ない学習用データを用いて学習モデルを作成することができることである．

YOLO には多くの version があり，2024 年 6 月 10 日時点での最新の version は v8 となる．最初のリリースは 2016 年 5 月にリリースされた v1 であり，検出精度の向上と処理速度の高速化や GPU への対応がされてきた．本研究で使用された v5 は 2020 年にリリースされ，2022 年 6 月の v6 のリリースまで最新であったものとなる．




Appendix C Fig. C-1 YOLO による物体検出例

（出典: https://qiita.com/hkwsdgea_ttt2/items/e20234f3c4c0a012c492）