

論文・解説

22

## AI を用いた検査工程の精緻化・合理化への取り組み Refinement and Optimization of Inspection Process Using AI

生田目 琢哉<sup>\*1</sup> 堀元 直生<sup>\*2</sup> 大谷 崇<sup>\*3</sup>  
Takuya Namatame Nao Horimoto Takashi Otani  
岩永 健太<sup>\*4</sup> 西野 恭弘<sup>\*5</sup>  
Kenta Iwanaga Yasuhiro Nishino

### 要 約

近年、労働人口減少による人手不足や、自動ブレーキ等の先進安全技術の普及による検査項目の増加などから、自動車業界において検査工程を省人化、効率化することは喫緊の課題となっている。本稿では、マツダが参画した国立研究開発法人新エネルギー産業技術総合開発機構（NEDO）の調査事業「AIを活用した自動車の完成検査の精緻化・合理化に係る調査」<sup>(1)</sup>におけるマツダの取り組み内容と、AIを用いた自動化システム開発・導入のガイドラインを紹介する。

### Abstract

Saving man-power and improving efficiency at inspection process have recently become urgent issues in the automobile industry due to labor shortage caused by a decline in working population and an increase in inspection items by the spread of advanced safety technologies such as automatic braking. This report describes Mazda's activity and automation system guidelines by using AI, regarding the NEDO<sup>(a)</sup> research business ("Project on the refinement and optimization of automobile completion inspections using AI") that Mazda has participated in.

(\*a) NEDO: New Energy and Industrial Technology Development Organization

**Key words** : AI, Deep Learning, Automation, Inspection, Tire

## 1. はじめに

近年、少子高齢化により、国内の労働人口は年々減少しており、2040年には2020年比で約20%の労働人口が減少することが予測されている。また、自動車業界では自動ブレーキ等の先進安全技術の普及や、CASEと呼ばれる新しい領域での技術革新による車両のコネクテッド化など車両機能の高度化が進んでおり、車両の品質保証の重要性が高まっている。

マツダの生産技術では、今後の労働人口減少や車両機能の高度化を見据えて、ロボットやIoT（Internet of Things）、AI（人工知能）などの最新技術を取り入れた高効率でフレキシブルな生産工程の実現を目指しており、その中でも近年発展の目覚ましいAIを用いた技術開発によって人の作業の自動化を進め、現業工数と間接工数の

効率化に取り組んでいる。

本稿では、NEDO調査事業「AIを活用した自動車の完成検査の精緻化・合理化に係る調査」におけるマツダのリードテーマ「タイヤ仕様検査の自動化」の取り組みと、AIを用いた自動化システム開発・導入のガイドラインについて紹介する。

## 2. NEDO 調査事業

### 2.1 NEDO 調査事業について

本調査事業は、内閣府主導の「未来投資会議」の1テーマで、AI等のデジタル技術の活用によって「完成検査を人から機械へ置き換える可能性」を実証調査することが目的である。

実証調査は、デロイトトーマツコンサルティング合同会社、トヨタ自動車(株)、日産自動車(株)、本田技研工

\*1～3 車両技術部  
Painting, Trim & Final Assembly Engineering Dept.

\*5 品質本部  
Quality Div.

\*4 品質保証部  
Quality Assurance Dept.

業(株)、マツダ(株)の5社共同の体制で、完成検査項目の自動化の可否及び自動化に必要な要件について、各社でテーマを分担し実施調査を行った。

## 2.2 完成検査について

現行の自動車の完成検査は、国土交通省が定める自動車型式指定制度に基づき国に代わって自動車メーカーが行うもので、現行の法令<sup>(※1)</sup>(自動車型式指定規則第7条)では、完成検査は完成検査員が実施することとされている。マツダの完成検査工程においても、教育・訓練された高い能力(視覚、聴覚、触覚、判断力等)の検査員で完成車両の仕様検査、機能検査、外観検査等を行っており、極めて高い検査精度が担保されている。

※1 現行の法令  
2021年8月現在

## 2.3 完成検査自動化の課題

現行の検査員による完成検査は、生産工程で発生するさまざまな変動にもフレキシブルに対応し、高い検査精度を担保している。当然ながら、自動検査システムが不具合品を誤って良品と判定し、市場流出させることはあってはならないため、完成検査自動化の大きな課題として「検査員と比較して同等以上の検査精度の達成」がある。

## 2.4 完成検査自動化の考え方

本調査事業においては、前述の「検査員と同等以上の検査精度」を「合理的に想定される範囲において機械と検査員(人)で不具合品の流出防止を確実に保証するもの」と定義した。これは機械だけで100%の検査精度を追求するのではなく、AI判定が少しでも曖昧な判定結果の場合には人に判断を委ねて、検査員が実物状態を確認することで不具合品の流出を確実に防止する考え方である。

この考え方に基づき自動検査システムの判定精度の達成目標を以下とした。

- (1) 不具合品の流出率=0%
- (2) 判別の誤謬率=0%となる適切な分類閾値設定
- (3) 検査精度の維持管理に必要な項目の要件化

下記に「流出率」、「誤謬率」、「不明」の定義を示す。

【流出率】検査システムが不具合品を誤ってOK判定する確率(実物の状態と不一致の判別数÷全サンプル数×100)

【誤謬率】検査の判別結果(不明を除く)が「実物の状態」を誤って判別する確率(実物の状態と不一致の判別数÷(全サンプル数-不明数)×100)

【不明】検査の判別結果を分類した結果、閾値未満のもの

## 2.5 NEDO 調査事業の取り組みテーマ

本調査事業では、完成検査ラインの全検査項目(172件)より、AI等のデジタル技術を活用した自動化に対して技術的に見込みがある検査項目(72件)を分類し、更に中長期にわたり効果が見込めると想定される10テーマを選出した(Fig.1)。

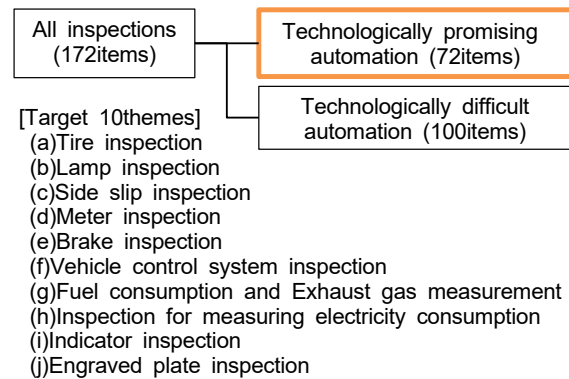


Fig. 1 NEDO Themes

この中で、マツダは「タイヤ仕様検査の自動化」の実証調査を担当し、自動化の実現可能性、自動化に求められる要件、及び想定効果の検証を宇品第2工場完成検査ラインにて行った。

## 3. タイヤ仕様検査の自動化

### 3.1 タイヤ仕様検査について

現行のタイヤ仕様検査は、自動車の4輪に対して、完成検査員が足腰を曲げた屈み作業で、目視によりタイヤに刻印された仕様(メーカー・シリーズ・タイヤサイズ)が型式指定制度に基づいた届出申請書と相違がないか確認している(Fig.2)。

この検査においても検査員は、ゴム刻印の僅かな段差(約0.5mm)からマークや文字を読み取り、メーカーごとに異なる字体や、水滴や異物の付着など、さまざまな変動に対して、人の高い補正能力(視覚、記憶、判断)でフレキシブルに対応している。




Fig. 2 Tire Inspection

### 3.2 タイヤ仕様検査自動化の課題

タイヤ仕様検査の自動化において、検査員と同等以上の検査精度を実現するためには、人の精緻な視覚認識や状況判断を自動検査システムに組み込まなければなら

い。また、一般的な画像処理技術による目視検査自動化の事例は多数あるが、人の視認と判断のルール（画像処理）を設計する必要があり、導入後に新しく検査対象が追加されるとフレキシブルに対応できず、ルールの再設計や維持管理のための間接工数が増加してしまう課題がある。

これらの課題「検査員の精緻な能力の代替」、「自動化による間接工数増加の抑制」に対して、本取り組みでは、以下の開発コンセプトで課題解決に取り組んでいく。

- ・精緻なセンシング技術を用いて、外乱光などの変動に強い安定した画像取得（人のフレキシブルな視覚認識の代替）
- ・AI技術を用いて、生産工程のさまざまな変動に中長期にわたり対応できる自動検査システム（人のフレキシブルな状況判断の代替、間接工数増加の抑制）

### 3.3 タイヤ仕様の自動検査システムの開発

#### (1) タイヤ仕様（刻印）の画像化

本取り組みでは、精緻なセンシング技術を用いた画像取得で「人のフレキシブルな視覚認識の代替」を目指す。

タイヤ側面に刻印されているメーカー、シリーズ、タイヤサイズ（Fig. 3）の画像化は、タイヤと判別対象の刻印が同じゴム素材である。そのため、黒背景に黒文字となり、一般的な照明とデジタルカメラでは、画像化の難易度が高く、また外乱光の影響を受けやすい。そこで、本取り組みではタイヤ仕様（刻印）の凹凸形状に着目した画像化処理方法（タイヤ側面の形状計測による画像化）を考案した。




Fig. 3 Camera Image (Tire)

この画像化処理方法は、タイヤを回転させながらレーザー変位計でタイヤ側面の形状を計測し、タイヤ全周の3次元形状データを、基準面に対する高さで256階調の濃淡データに変換し画像化する方法である。（基準面を128、基準面から-1.5mmを255、基準面から+1.5mmを0）

この方法によって、外乱光などの設置環境の変動に依存せず、タイヤ仕様（刻印）を鮮明に画像化できた（Fig. 4, 5）。

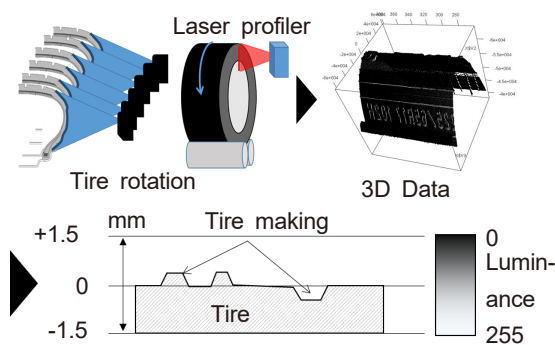


Fig. 4 Tire Side Measurement and Imaging



Fig. 5 Tire Specification Image

#### (2) AIを用いたタイヤ仕様判別

本取り組みでは、AIの深層学習の1つ「畳み込みニューラルネットワーク（CNN）」を用いた自動検査システムで「人のフレキシブルな状況判断の代替、間接工数増加の抑制」を目指す。

CNN判別モデル<sup>(※2)</sup>を用いた仕様判別をタイヤメーカーの事例（Fig. 6）で説明すると以下のとおりである。

- ①生産工程で取得したタイヤ画像を判別モデルに入力
- ②判別モデルは学習済タイヤメーカー全てのスコアを出力
- ③最も高い出力スコアのタイヤメーカーを判別結果とする




Fig. 6 CNN Model (Manufacturer)

なお、出力スコアは、AIが自信をもって判別しているかの指標となり、出力スコアの差が僅かであれば曖昧な判別といえる。

また、CNN判別モデルは、仕様判別のためのルール（判別の特徴量、特徴量の演算式）の設計が不要で、検査対象画像を準備するだけで学習による判別モデルの構築が可能である。

そのため、従来の画像処理では必須であったルール設計のための間接工数を抑制することができる。

※2 CNN判別モデル

本取り組みではOxford大学の研究グループが提案した16層からなるCNNモデル（VGG16）を使用する

(3) 仕様判別モデル構築の効率化

一般的なAIの使い方では、全ての事象を網羅した学習を行うアプローチで、膨大な学習データ（数千から数万）が必要であり、生産工程への適用は、膨大なデータ蓄積や学習の手間等の間接工数を考慮すると現実的ではない。そこで、本取り組みでは、CNN判別モデルの効率的な構築（AI学習の効率化）を目指す。

本取り組みでは、以下①～④のとおり、予見される学習画像の変動を画像処理で再現し、あらかじめ学習データに織り込むことで、少ない基本学習データでも効率的なモデル構築を行った。

- ①基本学習データを準備：統計的な分布が確認可能な30枚のタイヤ仕様画像を準備
- ②タイヤ仕様画像の変動（明暗差）の影響因子を抽出：ここではタイヤ製品面のうねり、タイヤ回転軸角度のバラツキ等を含んだタイヤ横振れ量（タイヤとセンサー間の距離変動）が影響因子
- ③影響因子の物理現象を網羅する画像を準備：タイヤ横振れ量の寸法公差を網羅するように基本学習データ画像を10倍（10段階/枚）にデータ拡張<sup>(※3)</sup>（Fig. 7, 8）
- ④生産工程の変動を織り込んだ判別モデルの構築：網羅的な学習データ（330枚）でモデル構築を効率化

※3 データ拡張  
学習画像を反転や回転、輝度変化等の画像処理を用いて学習データを増やすこと




Fig. 7 Data Augmentation




Fig. 8 Data Augmentation Image

(4) 適切な閾値設定による不具合品の流出防止

本取り組みでは、生産工程のさまざまな変動に対応できる自動検査システム（人のフレキシブルな状況判断の代替）を目指しているが、「2.4 完成検査自動化の考え方」に従って、判別結果（出力スコア）が少しでも曖昧な場合は全て「不明」とする適切な閾値設定を行い、不具合品の流出防止を保証する。

生産工程で取得したタイヤ画像（約2000本分）の仕様判別結果を以下（Fig. 9～11）に示すが、出力スコアの

平均、標準偏差（Table 1）から、AI判別の出力スコアが95点未満であれば「不明」と判定する閾値設定とした。なお、本取り組みのタイヤ仕様判別モデルは、正しい判別（Positive）と誤判別（Negative）の出力スコアが大きく乖離しており、高い精度で仕様判別ができていといえる。




Fig. 9 Result of Manufacturer Discrimination




Fig. 10 Result of Series Discrimination




Fig. 11 Result of Size Discrimination

Table 1 Score Average and Standard Deviation

	Positive Score		Negative Score	
	Avg.	Standard deviation	Avg.	Standard deviation
Manufacturer	99.998	0.00053	0.00112	0.00053
Series	99.999	0.00380	0.00004	0.00143
Size	99.992	0.22171	0.00196	0.10129

(5) タイヤ仕様の自動検査方法

本取り組みの自動検査システム（Fig. 12）を生産工程に設置し、以下の方法でタイヤ仕様自動検査の精度検証を行った。

- ①対象車両の車幅・車高に合わせて計測器を移動



- ②タイヤを回転させながらタイヤ全体画像を取得
- ③タイヤ全体画像からテンプレートマッチング<sup>(※4)</sup>でメーカー、シリーズ、タイヤサイズの画像を抽出(1つでも画像を抽出できない場合は「不明」と判定)
- ④対象画像を3つの判別モデル(メーカー、シリーズ、タイヤサイズ)にインプットしAI判別結果(最高スコア)を出力(1つでも閾値未満の場合は「不明」と判定)
- ⑤AI判別仕様(最も高いスコアの仕様)を生産情報サーバーの型式仕様情報と照合(1つでも不一致の場合はNG判定)

※4 テンプレートマッチング  
あらかじめ登録した代表的な画像との一致度から対象画像の位置を抽出する処理

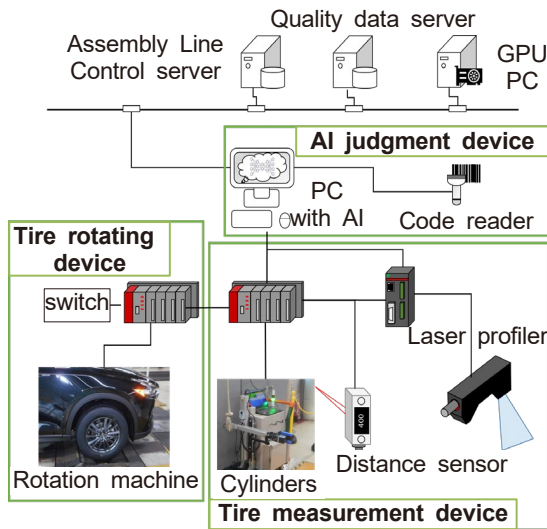


Fig. 12 Tire Inspection System

3.4 タイヤ仕様の自動検査システムの精度検証

自動検査システムの精度検証として、実証調査の実施期間中(約2ヶ月間)の昼夜勤生産車両約1000台のタイヤを用いて、通常生産における判定精度の検証を行った。判別結果(Fig. 13)と精度は以下のとおりで、判定精度の目標(流出率、誤謬率ともに0%)を達成し、通常生産において高い判定精度であることを確認した。

【タイヤ仕様判定精度】:流出率=0%, 誤謬率 0% (0本/2334本), 不明率 0.09% (2本/2336本)




Fig. 13 Result of Normal Production

次に、生産工程で検証すべき対象物と環境の変動を網羅的に抽出するために、タイヤ仕様自動検査システムの

工程 FMEA<sup>(※5)</sup> を実施した (Table 2)。

※5 工程 FMEA  
Failure Mode Effect Analysis の略。システムの故障や不具合を、合理的な想定範囲において網羅的に検証する手法

Table 2 Tire Inspection Process FMEA (Sample)

Process	Function	Potential Failure Mode	Potential Effects of Failure	Potential Cause of Failure	5M+1E
ALC matching	VIN label reading and ALC matcing	VIN label reading failure	The Sensor cannot be changed. Specifications cannot be judged.	Forget to read the label	human
				label reader failure	machine
				Poor wiring	machine
		Cannot access the ALC terminal	Specifications cannot be judged.	Poor wiring	machine
				ALC terminal stop	machine
Sensor position change	Move from specification information to sensor measurement position	Cylinder does not work	The device cannot take images of manufacturer, series name, and size	Cylinder is not turned on	human
				Cylinder failure	machine
				Poor wiring (cylinder-PLC)	machine
				Channel not set	human

工程 FMEA 結果をまとめると、人(ヒューマンエラーに起因)、設備(設備故障・異常に起因)、対象物(車両やタイヤの変動に起因)、環境(検査環境の変動に起因)の4つに分類される。

対象物と環境の変動に対して、以下の(1)~(4)サンプルデータを用いて生産工程での精度検証を行っていく。

なお、人と設備の変動に対しては、異常状態の確実な検出で自動停止させるシステム設計と、自動検査システムの保守管理要領等による維持管理で対応している。

(1) 車幅とタイヤインチ変動のタイヤ (12本)

多種多様なクルマに対しても判定精度を確保するため、実証検証を行った完成検査工程では生産していない車幅(1695mm~1735mm)、タイヤインチ(14インチ~17インチ)での車両タイヤ12本で検証を行った。

なお、本検査装置における車両停止位置のバラツキを考慮し各タイヤ5水準の停止位置(計測範囲内)で検証を実施した。

判定結果(Fig. 14)と精度は以下のとおりで、車幅、タイヤサイズの影響を受けないことを確認した。

【タイヤ仕様判定精度】:流出率=0%, 誤謬率 0% (0本/12本×5水準), 不明率 0% (0本/12本×5水準)




Fig. 14 Result of Other Models




Fig. 16 Result of Bad Condition

(2) 刻印不良のタイヤ (12本)

装着されたタイヤの刻印にキズ等が入っている場合に、正しく判定を行うか、不明と判定するかを確認するために、キズの入った刻印タイヤでの検証を行った。

判定結果 (Fig. 15) と精度は以下のとおりである。

【タイヤ仕様判定精度】：流出率=0%，誤謬率 0% (0本/11本)，不明率 8% (1本/12本)

刻印段差が無くなる激しい損傷で形状を読み取れない場合は「不明」と判定し検査員に判断を委ねることで流出防止できることを確認した。

なお、刻印の一部の欠け、擦れ、0.1mm幅以下の線キズは、画像で形状が読み取れるため「正しく判定」する結果となった。




Fig. 15 Result of Defective Marking Tire

(3) 環境不良のタイヤ (10本)

生産工程での製造過程で発生する可能性がある汚れ、異物の付着、充填エア量の変動、タイヤ濡れの影響を確認するために環境不良タイヤ (Table 3) での検証を行った。

判定結果 (Fig. 16) と精度は以下のとおりで、測定原理から想定したとおり、刻印を隠す異物、濡れたタイヤは不明と判定した。

【タイヤ仕様判定精度】：流出率=0%，誤謬率 0% (0本/10本)，不明率 40% (4本/10本)

Table 3 Bad Condition Sample Images

Test mode	Image	Sensor Image	Judge
Dirt			Positive
Foreign Material			Unknown
Air Pressure Drop			Positive
Wet			Unknown

(4) 未学習のタイヤ (12本)

新しいタイヤ仕様の設定忘れや、製造されないタイヤ仕様が装着された場合においても、検査システムは不具合品の流出防止を担保しなければならないため、未学習タイヤでの検証を行った。

判定結果 (Fig. 17) と精度は以下のとおりで、全て「不明」とし検査員に判断を委ねることで不具合品を流出防止できることを確認した。

【タイヤ仕様判定精度】：流出率=0%，誤謬率 0% (0本/0本)，不明率 100% (12本/12本)



Fig. 17 Result of Unlearned Tire

4. まとめ

4.1 自動化の実現可能性

本取り組みのタイヤ仕様自動検査システムは、合理的に想定される生産工程でのさまざまな変動に対して、フレキシブルに対応し、機械と人で不具合品の確実な流出防止ができるため、自動化の実現可能性があることが分かった。

4.2 自動化に求められる要件

本取り組みから得られた自動化の導入要件は、以下のとおりである。

【システム開発時】

- ・開発段階において、精緻なセンシング技術を用いて、外乱光などの変動に強い安定した画像取得を行うこと
- ・AI判別モデルの構築では、学習画像の変動に影響する物理現象を網羅する学習データをあらかじめ準備すること (正しい判別と誤判別のスコア分布が、それぞれ大きく乖離していること)
- ・AI判別結果 (出力スコア) の分類閾値は安全方向に設定し、曖昧な判別結果は全て「不明」とする適切な閾値設定をすること

【システム導入時】

- ・導入対象の生産工程において、タクトタイム内での安定した稼働を検証すること

- ・生産工程での精度検証は、工程 FMEA で合理的に想定される対象物と環境の変動を網羅したサンプルデータを用いて行うこと（一定のトライアル期間を設定して実施する）

なお、これら NEDO 実証結果を踏まえ国土交通省は「完成検査の自動化ガイドライン」<sup>(2)</sup> を策定した。今後、AI 等を活用した自動検査システムの開発・導入の促進が期待できる。

#### 4.3 自動化による想定効果

本取り組み結果のタイヤ仕様自動検査システムの導入による想定効果は以下のとおりである。

現業工数：インライン検査作業▲ 8.4 秒／台、屈み作業（約 2000 回／日）が無くなり検査員の負荷軽減

間接工数：▲ 75H（▲ 93%）仕様追加時の画像処理ルールの変更に伴う間接工数増加を抑制

## 5. おわりに

常にお客様に満足していただける車を提供していくことがマツダの使命である。今後は、本取り組みの成果（AI を用いた自動化システム開発・導入のガイドライン）を活用して自動化を推進し、生産工程の精緻化と合理化を進めていく所存である。

### 参考文献

- (1) 新エネルギー・産業技術総合開発機構（NEDO）：「2020 年度成果報告書 規制の精緻化に向けたデジタル技術の開発／AI を活用した自動車の完成検査の精緻化・合理化に係る調査」，報告書管理番号 20210000000327，<https://seika.nedo.go.jp/pmg/PMG01C/PMG01CG01>
- (2) 国土交通省：「完成検査の自動化のガイドライン」，<https://www.mlit.go.jp/report/press/content/001393148.pdf>（2021）

### ■ 著 者 ■



生田目 琢哉



堀元 直生



大谷 崇



岩永 健太



西野 恭弘