

AI 検査システムの開発

豊田 竜也^{*1}

Development of AI Inspection System

Tatsuya Toyoda^{*1}

1. はじめに

近年、少子高齢化の影響を受けて働き手が少なくなる中、製造業では工場の自動化に対する取り組みが盛んに行われている。中でも、人の目視検査に変わる検査機の需要が高まっており、社内でも内製開発に取り組んでいる。

また、技術の進歩に伴い検査機に AI (Deep Learning) を適用するケースが増えつつある。これは、従来の画像処理では困難であった検査が、AI を用いることで解決できる可能性があるためである。

本稿では、内製開発した AI 検査システムとその適用事例について紹介する。

2. 対象製品

豊田合成では、燃料タンクからエンジンに燃料を移送する部品として、燃料チューブ (図-1) を生産している。本製品は成型後にマーク、テープ、キャップを組み付け (図-2)、目視検査を経て出荷している。今回、人保証からハード保証 (検査の機械化) を目的に検査機の導入を図る。




図-1 燃料チューブ



図-2 組付け部品

3. 検査機の導入課題

先ず初めに、一般的な画像処理による検査機の導入を検討した。しかし、製品形状やセットのばらつきによって製品の位置ズレや見え方の変化が大きく (図-3)、良品を不良品と判断する誤検出が多いことから、目標とする検出精度を得ることができなかった。




図-3 誤判定要因
(左:位置ズレ, 右:見え方変化)

検出精度を得るには製品の位置決め治具が必要であったが、製品の脱着時間や段替え時間、治具費、保管スペースに問題があり、検査の治具レス化が課題となっていた。

4. 対策方針

検査の治具レス化には上記ばらつきの方策が必要だが、一般的な画像処理での対策は困難である。そこで、近年画像認識の分野で検出精度の高い CNN (Convolutional Neural Network) を用いた検査システムの開発を試みた。CNN では、画像認識に重要でない対象物の位置や画像の見え方の変化などの情報を上手く取り除くことができるため、本課題に適用できると判断したためである。

図-4 に CNN を用いた画像検査の導入ステップを示す。ステップ1. モデルの作成では、良品と不良品の画像を AI モデルに学習させ、学習済モデルを作成する。本検討では AI モデルとして VGG16¹⁾ を利用した。ステップ2. 評価では、評価用の画像データを学習済モデルに入力し、その予測結果と実際の結果を比較評価する。そして、評価結果に問題がなければ、ステップ3. 導入にて学習済モデルを検査機として運用する。

*1 マシンエンジニアリング部 設備開発室

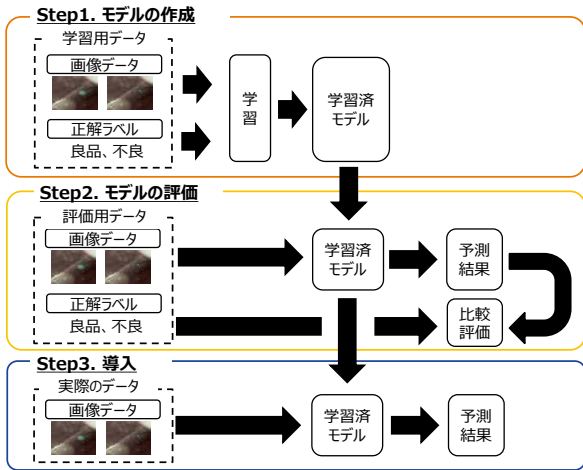


図-4 CNNを用いた検査機の導入ステップ

5. 対策実施

5-1. モデルの作成

CNNを用いた画像検査では大量の画像データが必要不可欠である。そのため、良品と不良品のサンプルを作成し、撮影することで画像データを集めた。また、撮影画像の中から検査対象（マーク、テープ、キャップ）の映る部位を切り取り、検査対象毎にAIモデルを作成する方法（図-5）を採用した。これにより、様々な視点の画像をAIモデルが学習することで汎化性能（未知の画像データへの対応力）の向上を狙っている。

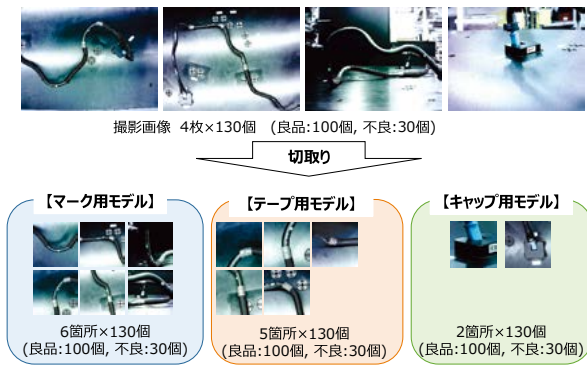


図-5 AIモデル作成方法

更に、今回モデル学習時にはデータ拡張（Data Augmentation）手法を取り入れた。本手法は、学習画像を平行移動や回転、反転させる（図-6）ことで、従来手法で課題となっていた位置ズレや見え方に変化のある画像を学習することができ、検出精度の向上が期待されるためである。



図-6 データ拡張（Date Augmentation）

5-2. モデルの評価

作成した各検査項目の学習済モデルに対する評価結果を表-1に示す。全モデルにて高い検出精度（精度100%）が確認された。

表-1 各モデルの評価結果

【マーク用モデル】				【テープ用モデル】			
良品：1020枚	予測			良品：850枚	予測		
不良：180枚	良品	不良		不良：150枚	良品	不良	
実際	良品	1020	0	実際	良品	850	0
	不良	0	180		不良	0	150

【キャップ用モデル】			
良品：340枚	予測		
不良：60枚	良品	不良	
実際	良品	340	0
	不良	0	60

また、各モデルでの判定の確からしさを確認するため、Grad-CAM²⁾による画像解析を行った。Grad-CAMは、学習済モデルが画像のどの部位を見て予測結果を出力したかを見える化する手法であり、赤色に近づくほど予測結果の影響度が強い部位を示している。本手法にて解析した結果を図-7に示す。各学習済モデルにて検査対象の部位を赤色で示しており、正しい部位で良品と予測していることが確認できた。




図-7 Grad-CAMによる解析結果

5-3. 導入

今回作成した学習済モデルを検査機に導入するにあたって、過去に豊田合成が内製開発した欠品検査ソフト TG-Vision への組込みを行った。TG-Visionは世界各国での導入実績（約800台）を持つことから、今回開発したAI検査システムを組込むことで開発L/Tを短縮し、早期横展に繋げることを目指した。

現在は、開発したAI検査システムを量産運用しながら精度検証しており、'21/6より不良検出率100%を継続中である。

6. まとめ

本稿では、開発した AI 検査システムとその適用事例について紹介した。また、検査に AI 技術を用いることで高い検査精度（精度 100%）が得られることを示した。

今後は、開発した AI 検査システムを横展すると同時に、AI 技術の普及と AI 人材の育成に取り組んでいく。

参考文献

- 1) Karen Simonyan and Andrew Zisserman, Very Deep Convolutional Networks for Large-Scale Image Recognition, International Conference on Learning Representations (ICLR2015), (2015)
- 2) Ramprasaath R. Selvaraju et al., Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization, Proceedings of the IEEE International Conference on Computer Vision (ICCV 2017), P618-626, (2017)

著 者



豊田竜也