

汎用性の高いAI外観検査ツールの開発

伊藤 由希子・西垣 一弘

1 はじめに

生産ラインでは、製品外観の良否を目視で検査している工程があり、検査作業の省力化や検査ミス防止による品質保証度の向上が求められている。目視検査の自動化においては、近年、ルールベース方式（人間が設定した特定のルールや条件に従って判断する手法）から、AI（Artificial Intelligence：人工知能）を活用した技術への移行が進んでいる。これまでカヤバでは、AIを活用し、製品の個体差や検査環境の変化に強い検査技術や、AIモデル精度の維持・管理を効率的に実施する仕組みであるMLOps^{注1)}の開発と導入を進めてきた¹⁾。しかし、これまでは専門スキルを有する人材による対象特化型のシステム開発であり、生産ラインにおける様々な外観検査自動化の要求にタイムリーに応えることが困難であった。この課題解決のために、工場の担当者が検査対象に応じて検査システムを構築できる汎用性の高い外観検査ツールを開発した。

本報では、当社の生産ライン向けに開発したシステムと適用事例について紹介する。

注1) AIを円滑に進めるための取り組み。AI Machine Learning (ML) と、ソフトウェア分野での継続的な開発手法であるDevOpsとを組み合わせた造語。

2 開発の概要

2.1 検査対象に応じた柔軟なシステム構築

検査対象に応じて柔軟に検査システムを構築するため、検査ソフトウェアの各機能を独立したモジュールとして設計し、Docker^{注2)注3)}を用いて実装した。Dockerを利用することで、アプリケーションと実行環境をコンテナとしてパッケージ化できるため、開発から運用までの環境構築が不要となり、開発期間の短縮が可能となる。また、各モジュールは独立した環境で動作するため、相互の依存関係が解消され、維持管理の容易化を実現している。

開発したモジュールは以下の2種類に分類される。

①デバイスモジュール

カメラやPLCなどのデバイスを制御する機能を提供する。デバイスモジュールは一度、開発すれば、様々な対象に転用可能な汎用性を備えている。工場のニーズに対応するため、カメラは廉価なWebカメラからFA用途の高性能カメラまで幅広く対応可能とした。また、PLCについては、工場で使用される複数メーカーの通信方式に対応できるよう設計している。

②検査モジュール

カメラから取得した画像に対して、前処理、AI処理、後処理を行う機能を提供する。検査モジュールはハードウェアモジュールと異なり対象に応じて個別開発が必要である。しかし、図1に示す検査フローのように、共通性の高いフローはテンプレート化し、導入時には必要な設定を編集することで対応可能とした。今後は、適合しない検査についても、随時テンプレートを拡充していく。

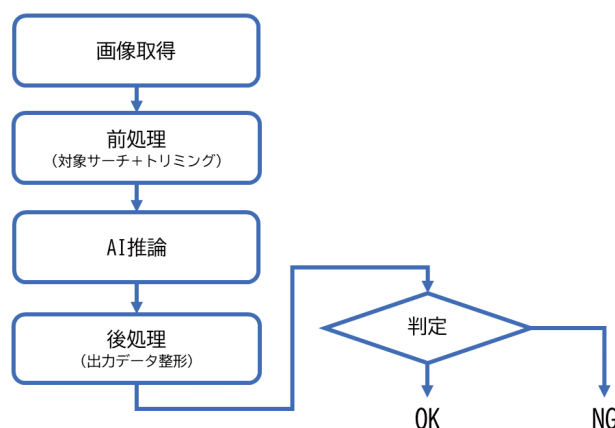


図1 検査フロー

以上、開発したモジュール群から検査対象に応じて、必要な機能を選択し、Docker Compose^{注4)}を用いて検査システムを構築する（図2）。これにより、従来は開発者が一から検査システムを構築していた場合

と比べて、構築時間の80%以上の短縮を実現した。

注2) DockerはDocker, Inc.の登録商標。

注3) アプリケーションをモジュールとしてパッケージ化し実行するためのプラットフォーム。

注4) 複数のモジュールを連携、管理するためのツール。

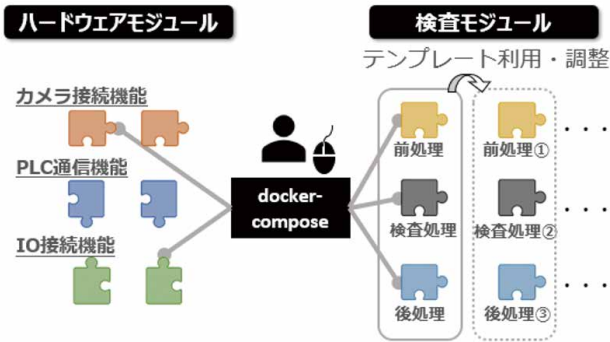


図2 検査システム構築方法

2.2 ノーコードツール

AI判定モデルは、検査対象の画像データ収集、学習、精度評価の手順を経て作成される。要求精度を達成した場合、モデルは検査機に組み込まれる。これらの作業は検査機の導入時のみならず、運用過程で製品や環境の変化によりデータ分布が変化した場合にも実施が必要である。

従来は、開発者が対象に応じて専用の学習プログラムや精度評価プログラムを準備し、試行錯誤を重ねながら対応していた。本開発では、工場の担当者にて同品質の作業を実現できるよう、画像データの前処理、学習、精度評価、モジュールに読み込み可能なモデル変換までを一つのツールに統合し、マウス操作のみで実行可能なノーコードツールを開発した。以下に、本ツールの機能について説明する。

2.2.1 利用可能なAI手法

本ツールでは、工場における様々な外観検査の要求に対応するため、図3に示す4種類のAIモデルをサポートしている。また、近年はAI性能の競争が激化し、継続的に新しいモデルがリリースされている。この状況を踏まえ、当社の生産ラインにおいて性能向上が期待されるモデルに対しても、ツールで対応可能となるよう機能のアップデートを継続的に実施している。

画像分類	物体検出
何が映っているか 部品A or 部品B	いくつ、何がどこに映っているか
領域検出	異常検知
どの範囲に映っているか	いつもと違いはあるか OK or NG

図3 対応しているAIモデル

2.2.2 モデル精度向上の機能

高精度なモデルを作成するため、以下の3つの機能を実装した。

①画像拡張

元画像に対して意図的にノイズを付与し、人工的に画像を生成する機能。学習データの多様性を確保することで、生産ラインの様々な変動に対してロバスト性の高いAIモデルを構築可能。

②ファインチューニング

事前学習済みモデルを基に、対象の画像データを用いて再学習する方法。少量の学習データでも高精度なモデルの作成が可能。

③学習パラメータ最適化

学習時のハイパーパラメータ設定はAIモデルの判定精度に大きく影響する。本機能では、様々なハイパーパラメータの組み合わせを効率的に探索し、最適なモデルを獲得可能。

図4に開発したノーコードツールの画面を示す。本ツールを利用することで簡単に高精度なAIモデルの作成が可能となり、工場での展開が容易になる。



図4 ノーコードツールの画面

3 事例紹介

開発したツールを当社の生産ラインに適用した事例を以下に示す。その中から本報では③について紹介する。

- ①製品に組付ける部品の有無や種類の判別
- ②製品に貼付ける仕様ラベルの有無や種類の判別
- ③加工機や治具へのワークのセット良否の判別

3.1 背景

当社の主力製品であるショックアブソーバの構成部品であるピストンロッドには、耐摩耗性および耐食性を確保するため、図5に示す範囲に硬質クロムめっきが施されている。




図5 ピストンロッドのめっき範囲模式図

図6に示すようにピストンロッドは、コンベヤに連結された「めっきハンガ」と呼ばれる治具に自動機でセットされ、めっき処理工程まで搬送される。セット時の動作は、ピストンロッドの上部をクランプした後、マスクング治具が上昇し、ロッド下部の非めっき範囲を覆う機構となっている。

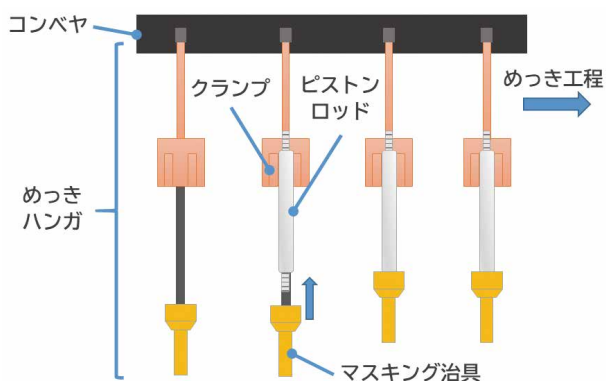


図6 めっきハンガへのピストンロッドの取付方法

しかし、図7に示すようにマスクング治具が上昇する際、ロッド下部と治具の接触抵抗によりピストンロッドのクランプ位置がずれる不具合や、マスク

ング治具が所定の高さまで上昇しない不具合がある。このような不具合が発生すると、めっき範囲が製品仕様を満たさず、不良品となる。

現状では、近接センサによるセット不良検知システムは導入されているものの、セット不良を完全に検出することができず、めっき処理後に全数目視検査で保証している。検査本数が非常に多く、検査員の負担が大きいため、自動化による省力化と品質保証レベルの向上が強く求められていた。




図7 ピストンロッドセット状態の良否

3.2 システム構成

システム構成を図8に示す。本システムは、2.1節で説明した機器モジュールに対応したハードウェアで構成されている。検査機の使用環境を考慮し、カメラにはFA用カメラを採用した。また、バー照明を利用することで、対象物の明るさ変動による影響を抑制している。

検査機でセット異常と判定された場合、めっき設備制御用PLCに信号を出力し、設備を停止した上で、ラインオペレータにより処置を行う。

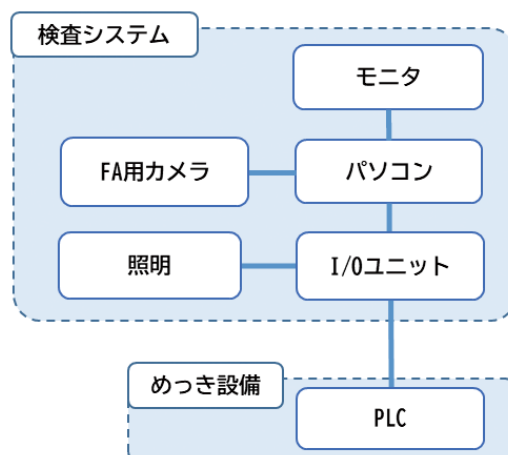


図8 システム機器接続構成

3.3 検査方法

図7に示したようにピストンロッドの上端とマスクング治具の下端を正確に測定することで、セット状態の良否判定が可能である。しかし、マスクング治具はめっき液に曝されることで徐々に変色や劣化が生じ、治具ごとに使用期間が異なるため、外観は様々である。したがって、マスクング治具の外観個体差に影響されず、端点座標を正確に検出する必要がある。

従来のルールベース方式では、安定した端点検出が困難であった。そこで、本開発では端点検出の前処理として領域検出AIを活用し、使用レベルの異なるマスクング治具画像を学習させることで、検出の安定化を図った。さらに、AIが検出した領域を白黒画像に変換することで、ルールベース方式による端点検出を容易にした(図9)。

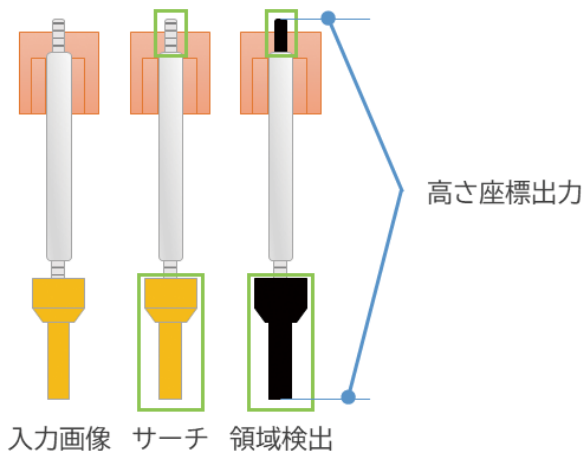


図9 AIによる領域検出模式図

3.4 結果

量産ラインに導入し、通常稼働状態での連続運転を対象に評価を実施した。

不良品を良品と判定する確率である誤判定率は0%、良品を不良品と判定する確率である過検出率

は0.1%未満となった。本システムは量産ラインにおいて安定稼働し、品質保証度向上に有効であることが確認できた。

4 まとめ、今後の展望

工場の担当者が検査対象に応じて柔軟にシステム構築が可能な汎用性の高い外観検査ツールを開発した。さらに、内製化により市販のAIセンサと比較して低コストで導入できる環境を整備し、工場での適用性を向上させた。

一方、検査精度の向上には、AIモデルの性能だけでなく、学習に用いる画像データの品質が重要である。例えば、対象に応じた撮影条件の最適化や学習データの多様性確保などが挙げられ、これらには高度なノウハウが求められる。

今後は、検査機の導入・運用を通じてノウハウの蓄積とツール活用人材の育成を進め、誰でも容易に高性能な検査機を構築できる環境を整えることで、品質保証レベルのさらなる向上を目指す。

5 おわりに

本開発により、モジュール化による柔軟なシステム構築と、ノーコードツールを活用したAIモデル開発を実現し、品質保証レベルの向上と工場全体への迅速な展開を可能にする検査基盤を構築することができた。

最後に、本開発にあたり多大なご支援とご協力を賜りました関係部署の皆様へ、心より感謝申し上げます。

参考文献

- 1) 光尾, 鈴木, 宮内, 菊池: AIを用いた刻印検査技術の開発とMLOps基盤の構築, カヤバ技報第69号, (2024年10月)

著者



伊藤 由希子

2018年入社。技術本部生産技術研究所第二研究室所属。検査、計測技術の開発に従事。



西垣 一弘

2023年入社。技術本部生産技術研究所第二研究室所属。検査、計測技術の開発に従事。