

AI技術“Maisart”を活用した 外観検査自動化への取り組み

松本浩輝*
Koki Matsumoto
今野有作*
Yusaku Konno
峯澤 彰†
Akira Minezawa

飯島昌平†
Shohei Iijima
式田秀男‡
Hideo Shikida

Efforts to Automate Visual Inspection Using AI Technology "Maisart"

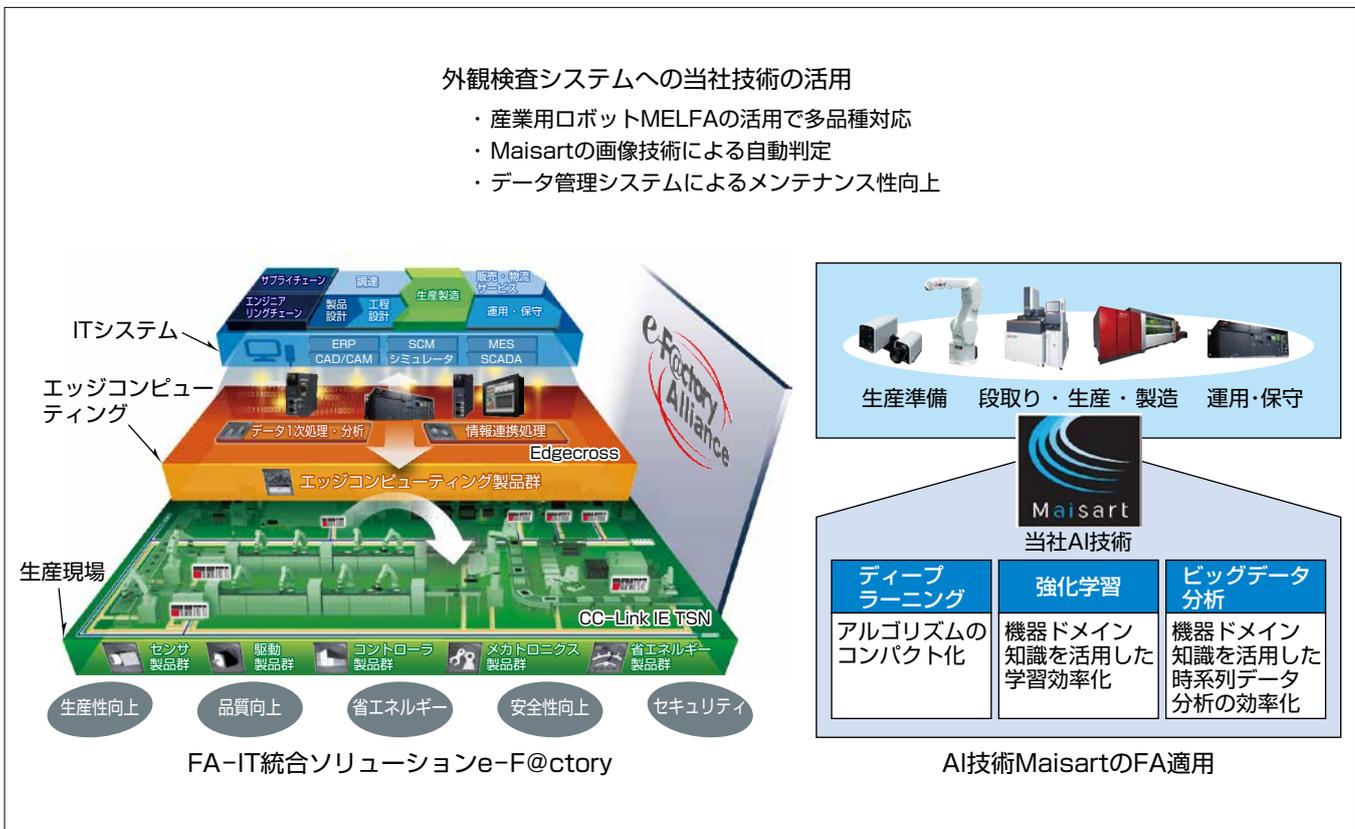
要 旨

三菱電機は、FA-IT統合ソリューション“e-F@ctory”のコンセプトに基づきIoT(Internet of Things)化を推進する製品を多数市場に供給してきた。また、“生産準備”“段取り・生産・製造”“運用・保守”といった各プロセスに合わせたFA向けAI(Artificial Intelligence)技術を開発している。顧客の生産現場の自動化・IoT化推進を支援する上で、AI技術活用の効果の検証と課題抽出も重要である。

今回、当社のAI技術“Maisart(Mitsubishi Electric’s AI creates the State-of-the-ART in technology)”を搭載し

た外観検査システムを開発し、電磁開閉器を生産する当社名古屋製作所可見工場で稼働を開始した。

検査工程は品質管理の基本であることはもとより、生産効率や品質改善のための分析データを収集可能にするIoT化の重要工程である。特に、検査工程の中でも目視検査は、全人作業工程の7%(社内調査)を占め、その自動化は生産規模変動に対する人材確保という経営的課題に対しても重要である。



FA-IT統合ソリューション“e-F@ctory”とAI技術“Maisart”のFA適用

e-F@ctoryは、生産現場を基点とした経営改善を目指して“人・機械・ITの協調”によるフレキシブルなものづくりによって、企業のTCO (Total Cost of Ownership)削減と企業価値向上を支援する。Maisartは当社AI技術の総称であり、FA分野では、“生産準備”“段取り・生産・製造”“運用・保守”の様々なシーンに適用され、作業者の技能に影響されない柔軟で効率的な生産現場を実現する。今回開発した外観検査システムでは、当社の産業用ロボット“MELFA”、Maisartの画像技術及びデータ管理システムを活用している。

1. ま え が き

労働人口減少等の社会環境変化によって、工場内の人作業の自動化が推進されている。しかし、組立て等の人作業を自動化できても、組立て後のワークの人による目視検査等の自動化は断念することが多かった。一方、人による目視検査は判断基準のばらつきやヒューマンエラーによる見逃しリスクが付きまとう。さらに、多品種生産の自動化は投資コストがかかって自動化困難な場合が多い。

今回、多品種生産の人による目視検査の自動化をAI技術の活用で実現した外観検査システムを開発し、当社名古屋製作所可見工場に導入した。

本稿では、外観検査システムと多品種生産への自動化アプローチ等について述べる。

2. 開発の背景と要件

可見工場は、電磁開閉器の製造工場であり、その生産量の多さから自動化率の高い工場である。図1に示すように電磁開閉器の品種は様々で、さらに顧客対応でオプション部品の追加等が必要な場合があり、人作業による組立て・検査工程が存在している。

それらの工程に対しては品質管理を徹底しているもののヒューマンエラーのリスクは残存している。そのため目視検査の自動化を実現することにした。

従来画像処理を活用した外観検査装置による自動化によって、人件費、ヒューマンエラー抑制の取組みはなされている。しかし、品種ごとに検査パラメータを調整する必要があり、しかもその調整には画像処理のノウハウが必要になる。そこでAI技術を活用して学習サンプルを準備するだけで自動化を実現し、画像処理のノウハウを習得する必要なく多品種対応の自動化を実現することにした。特に多品種生産では品種ごとに学習用不良品サンプルを収集することが困難なため、正常データだけで判定できるAI技術が必要である。

検査工程を自動化するために、次の3点の開発を行った。

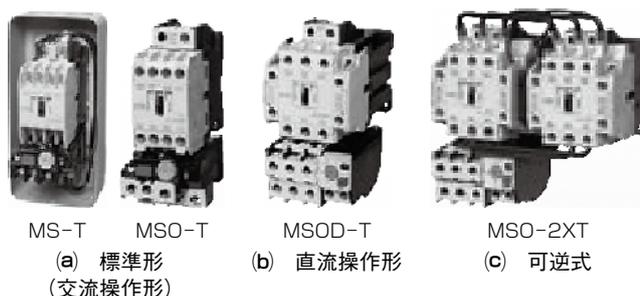


図1. 電磁開閉器の品種例

- (1) 外形寸法が異なるワークに対する撮影の自動化
- (2) AIによる判定の自動化
- (3) 多品種に対するデータ管理システム

3. 撮影の自動化

開発した外観検査装置は生産のボリュームに合わせ、1人又は2人の作業者が個別にワークを組み立て、その後ワークを各々検査装置に投入できるように、二つの検査ラインを持つ(図2)。多品種対応のため複数の外形寸法、検査面を撮影する必要があり、中央に位置する1台の産業用ロボットMELFAのアーム先端にカメラとLED照明を搭載して移動しながら撮影する構成にした(図3)。

QRコード^(注1)リーダーで製品仕様を確認し、検査面を撮影する。撮影した画像はAIによって自動判定され、正常品と不良品は別の排出口に搬送される。また、外観検査装置の表示器に、異常箇所と異常度スコアを表示することで作業による異常原因診断を支援する。QRコードで品種を読み取ることで異なる外形寸法の品種が連続で流品されても自動で撮影される。

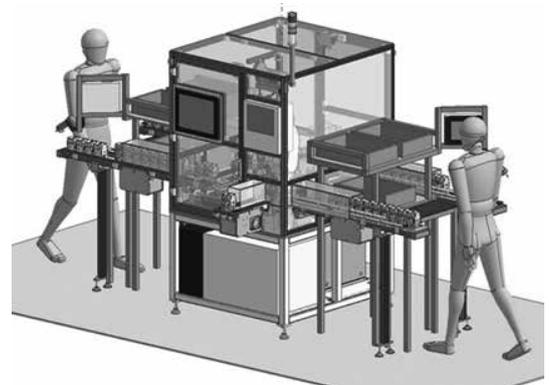
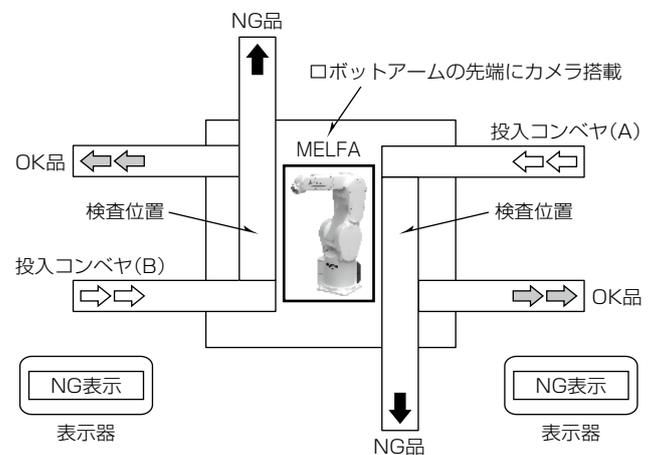


図2. 外観検査装置のイメージ



AとBの二つのラインがある

図3. 外観検査装置の構成(上面図)

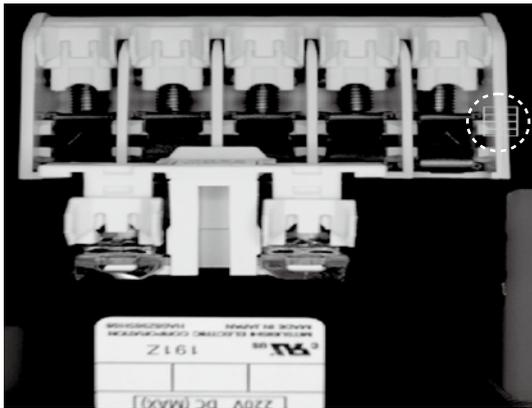


図4. 背景の誤判定の例

メンテナンス性も配慮し、他の製造装置と同様に、装置全体の制御にはシーケンサを用いた。

光学系とライン間差という撮影上の2点の課題に対して次の対応を行った。

(1) 光学系の改善

電磁開閉器の金属部品の光沢のばらつき抑制のために、偏光板挿入による乱反射光のカット、照明用LED照度、カメラ露光時間調整を実施した。図4に示すように電磁開閉器の形状の特性上、背景が映り込むために検査品とは無関係な過検出が発生してしまう。このため、映り込みの影響を除去するために撮影時に黒色のスクリーンを自動挿入することで過検出を抑制した。

(2) ライン間差の解消

二つの検査ライン間で撮影の位置誤差があるため、それぞれで学習モデルを作成すると時間がかかる。そのため、ロボットを用いて撮影誤差相当のばらつき画像を自動で撮影し、画像処理によって位置ずれ画像の水増しをすることで学習モデルをライン間で共有した。

(注1) QRコードは、(株)デンソーウェーブの登録商標である。

4. AIによる判定の自動化

画像自動判定の性能を評価するには限度見本になる不良品のサンプルを用意する必要がある。図5に不良品画像の

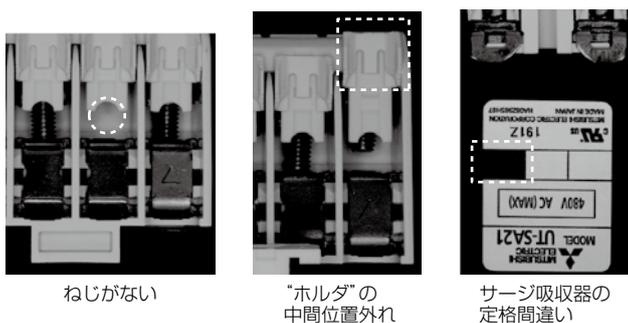


図5. 不良品画像の例

例を示す。ここにあるようにねじや部品の付け忘れや取付け部品の定格間違いなどが不良要因としてある。このAIは品種ごとに撮影した良品の画像を全て学習し、検査時に学習済みの良品からの差異を異常として求める方法(良品学習による検査)を用いている。

4.1 AIによる学習と検査のフロー

図6にAIによる学習と検査(推論)の処理フローを示す。

まず、学習段階では事前に撮影したばらつきを含む正常画像群を学習する。学習は入力に対して出力が同一になるように学習モデルを更新し、全ての正常画像群を記憶した学習モデルを構築する。

次に検査段階では撮影した検査画像を学習済みモデルに入力する。出力画像として正常品(既知のばらつき範囲内)の場合は、入力と同じ出力画像が生成される。一方、不良品(既知のばらつきの範囲外)の場合は、入力と異なる出力画像が生成される。未知の不良品が学習モデルに入力されると画像合成に失敗するためにそこに差異が生じる。入力画像と出力画像を比較することによって不良品の場合だけ差異を不良品として検出することが可能になる。

4.2 学習と性能評価の条件

学習には正常品ワークの個体差や撮影環境などのばらつきを含む画像データが多数必要であり、今回は20個体に対して、撮影条件を変えた100枚の画像データを学習してモデルを生成した。評価には学習に用いていない品種の良品画像と不良品画像をそれぞれ20枚用意した。

4.3 学習精度の検証方法と追加学習の方法

検査結果の評価方法として、表1に混同行列を示す。

縦軸に入力内容、横軸に検査結果を示している。ケース

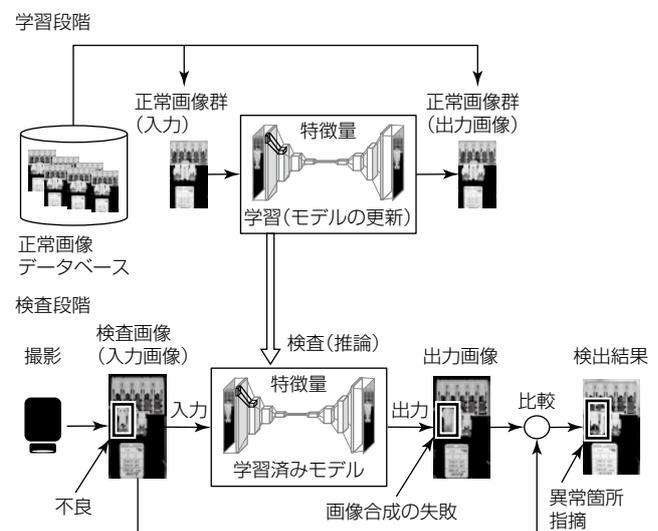


図6. AIによる学習と検査(推論)の処理フロー

表1. 検査結果に対する処理

		検査結果	
		良品	不良品
入力内容	良品	(a)正常処理	(b)異常処理 →追加学習の対象
	不良品	(c)異常処理 →学習モデルの見直し	(d)正常処理

(a), (d)のように良品を良品, 不良品を不良品と判定した場合は正常処理を行う。ケース(b)のように良品を不良品と判定する場合は, 過検出になり, このデータに関しては追加学習の対象になる。ケース(c)のように不良品を良品と判定する場合は異常処理として学習モデルの見直しが必要になる。具体的にはこのケースは学習用正常画像群に不良品が含まれていることが考えられ, 学習画像群の見直しが必要になる。

4.4 マスクによる検査領域の指定

部品位置のばらつきや, 製品番号などの変化文字は事前にデータを準備するのが困難な場合がある。運用上ばらつき箇所が検査ポイントでない場合は, その領域をマスクして検査領域から外すことにした。これによって結果的に学習に必要なデータ数が少なくて済み, 装置の稼働を早めることができた。

4.5 評価結果

4.2節で用意した評価用の良品20個体については過検出率0(0/20枚)%, 不良品20個体については見逃し率0(0/20枚)%を達成できた。

さらに試稼働開始後に正常品にも関わらず異常判定したデータを収集して追加学習することで運用しながら検出精度の向上を可能にする。

5. データ管理システムの構築

外観検査装置の導入目的は, 省力化や生産規模変動への対応力向上であるが, それ以外にも検査仕様や検査対象物, 検査結果がデータベース化されることによって期待される効果がある。例えば, 多品種対応の容易化, 不良発生工程の特定と改善, トレーサビリティの実現, AIの精度向上である。

これらの実現に向けて, この検査装置のデータ管理システムでは, 表2に示すように①レシピ, ②画像, ③検査結果の三つの管理データを体系的に管理する構造にした。

これらのデータは識別子(ID)で関連性を把握できるため容易に検索や分析が可能になる(図7)。具体的には, 不良判定が多い機種の特定期だけでなく, 不良判定箇所から不良発生工程や原因を推測できる。

表2. 検査装置が管理するデータ

管理データ	説明
①レシピ	検査装置に設定する検査仕様情報。学習・撮影・検査のパラメータを規定のフォーマットでまとめたもので検査設計の担当者がワーク種別ごとに設計・設定する。検査装置はレシピを読み込み仕様に従って検査する
②画像	(1)学習画像: 学習モデルを生成するための正常品の画像。稼働前に学習に必要な量をワーク種別ごとに撮影する (2)学習済みモデル: 検査に使用するモデル。ワーク種別ごとに学習画像からAIが生成する (3)検査画像: 検査時にワークを撮影した画像。レシピに設定された仕様で撮影されワークごとに保存される
③検査結果	検査結果にかかわる情報。使用したレシピや画像, 検査結果や異常判定箇所等をまとめたもので検査装置が自動で生成する

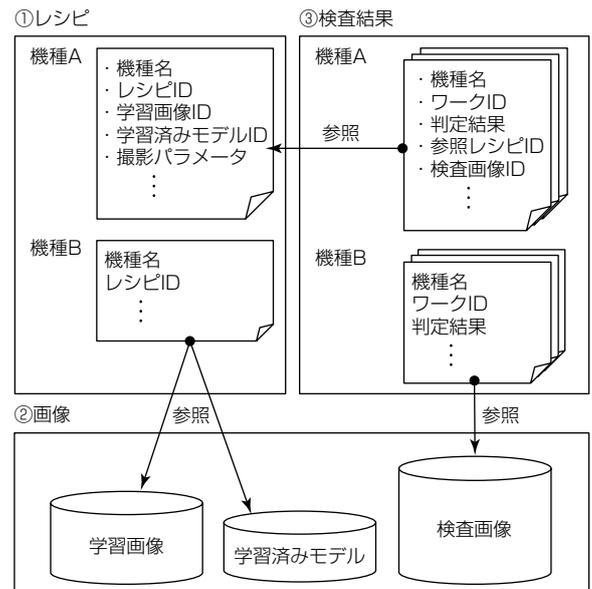


図7. 体系的なデータの管理

また, 稼働中に取得した正常品の検査画像を再学習に活用することで検査精度を向上させることができる。さらに不良判定画像を再学習時の評価に用いることで性能劣化の検証も可能になる。

6. むすび

AI技術Maisartを活用した電磁開閉器の外観検査システムについて述べた。AI機能を外観検査システムに組み込み, 目視検査の自動化や, 品質改善に向けたアプローチに対する課題を分析して対応した。これらはAI技術Maisartや, ロボットによる自動化技術, e-F@ctoryというIoT技術を総合的に持つ当社ならではの取組みである。

外観検査システムの適用には学習用画像の効率的な収集や追加学習による検査性能の確認などいまだ多くの課題が残っているため, 電磁開閉器向けのシステムを改善すると同時に, 社内の多くの目視検査の自動化を推進することで, 更に効率的な開発や運用を可能にする改善を進めていく。最終的には, 工場全体の省人化や無駄のない工場管理の実現を目指す。