技術解説

AIを用いた刻印検査技術の開発とMLOps基盤の構築

Development of Stamp Inspection Technology Using AI and Construction of MLOps Platform

光尾　崇・鈴木健斗・宮内悠樹・菊池貴好
MITSUO Takashi・SUZUKI Kento・MIYAUCHI Yuuki・KIKUCHI Takayoshi

要　旨

製品外観の目視検査の自動化においては，近年，ルールベース（人間が設定した特定のルールや条件に従って判断すること）のアプローチからAI（Artificial Intelligence：人工知能）を活用した技術へ移行している．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の開発を目指している．

当社の主力製品であるショックアブソーバー（以降，SA）では，刻印検査を全数目視で実施しているため，検査作業の省力化や検査ミス防止による品質保証度向上が求められていた．そこで，AIを適用することでロバスト性の高い刻印検査技術を開発し，省力化や品質保証度向上を目指す．

AIを用いた検査ではモデル構築後の時間経過に伴った環境変化によって，AIモデル（データを分析し，予測や判別を行うための仕組み）が劣化し，検査精度が低下する．精度維持には定期的な再学習が必要となる．日々の結果の集計，AIモデルの再評価などをすべて手作業で行う手法では，管理者の負担が大きい．また，検査データやAIモデルの管理方法が標準化されていないため，結果の一貫性や再現性に問題があった．そこで，管理者の負担軽減とデータ運用・管理の効率化を目的としたシステムを新たに構築した．

本報では，開発した刻印検査技術および新たに構築したシステムについて解説する．

Abstract

In recent years, the automation of visual inspection of product appearance has transitioned from a rule-based approach to a technique utilizing AI（Artificial Intelligence）. Kayaba aims to utilize AI to develop inspection technology that is robust against individual differences in products and changes in the inspection environment.

Shock absorbers, our main product, are inspected visually for all stamps, so there is a demand for labor-saving inspection work and improved quality assurance by preventing inspection errors. Therefore, by applying AI, we aim to develop a highly robust stamp inspection technology, thereby reducing labor and improving quality assurance.

In inspections using AI, changes in the environment over time cause the AI model to deteriorate and inspection accuracy to decrease. Regular relearning is necessary to maintain the system, but doing it manually places a heavy burden on administrators. In addition, there have been problems with the consistency and reproducibility of the results. Therefore, we have newly built an operation management system aimed at reducing the burden on developers and improving the efficiency of data management and operation.

This paper describes the development of the stamp inspection technology and the newly constructed system.

1　緒言

カヤバでは，SAにおいて製品を識別するための刻印品番を全数目視検査しており，品質保証の向上と省力のために自動化が求められている．ルールベース方式による自動化では，製品の個体差や検査環境の変動による画像の輝度（明暗）の変動などにより，一貫した検査性能を維持することが困難だった．この問題を解決するためにAIを適用し，ロバスト性[注1)]の高い刻印品番認識技術を開発した．

AIを用いた検査技術を工場に展開後，効率的に運用するためには，AI実行サイクル（データ収集・学習・精度評価・モデルデプロイ[注2)]）の効率化やデータの管理・運用を適切に行い，AIの品質を高水準に保つことが必須である．そこで，MLOps[注3)]を実現するための基盤を構築した．

各章では開発した刻印検査技術およびMLOps基盤について解説する．

注１）外的要因による変化に対して特性が安定していること

注２）機械学習モデルを既存の本番環境（設備）へ統合すること．

注３）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　刻印検査技術開発

2.1　検査対象

検査対象はSAの円筒外周上に刻印されている品番文字である（写真１）．刻印された番号に誤りがないか，かすれがないかを確認するために，塗装後の最終工程で検査を行う．

写真１　検査対象

2.2　刻印検査機構成

開発した刻印検査機の構成を図１に示す．検査対象を回転させながら，ラインセンサカメラ（ライン状に連続撮影し，処理することで写真２のような画像が取得できる）にて撮影を行う．取得した画像から刻印品番を認識し，刻印の合否を判定する機構となっている．

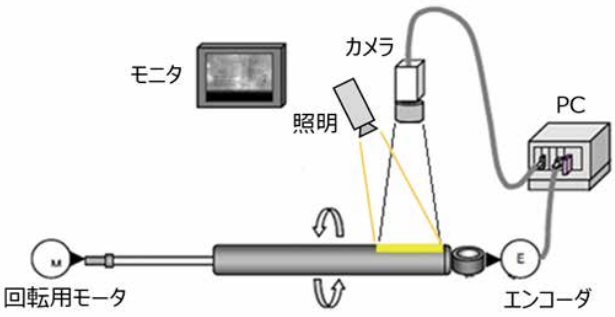

図１　刻印検査機構成

写真２　撮影画像

2.3　要件

効率的かつ精度の良い刻印検査技術を開発するための要件を以下に示す．

①効率的な学習画像の準備方法の確立

②不正解率を低く抑える文字認識アルゴリズムの確立

2.4　刻印検査技術概要

2.4.1　効率的な学習画像の準備方法の確立

高い文字認識精度を有するAIモデルの構築にあたっては，製品の個体差や検査環境の変動を含んだ様々な特徴を持った画像を学習させる必要がある．これら学習画像を開発初期段階で収集するにあたり，以下，２つの問題があった．

①認識させる文字は数字・アルファベット・記号を合わせて全36種類あるが，実製品の刻印品番には偏りがあるため，36種類の学習画像を短期間で均等に収集することが難しい

②塗装の表面状態による画像の輝度や刻印ピース（刻印品番を打刻する際に使用する治具）の摩耗状態による文字太さが異なる画像を短期間で収集することが難しい（写真３）

これら問題点を解決するために，CADで描画した図面（図２）に対して，文字の太さや色ムラ等の様々なノイズを加えた架空の品番画像（以降，人工画像）（図３）を36種類の文字に対して均等に生成した．これにより，数万枚の人工画像と，実製品を撮影した少量の画像を組み合わせた学習画像で高精度なAIモデルの作成が可能となり，初期の開発期間の短縮を図る効率的な学習画像収集方法を確立した．

写真 3　刻印品番の見え方が異なる画像

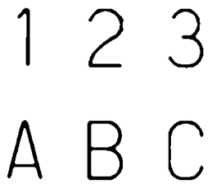

図 2　フォントデータ（サンプル）

図 3　人工画像（サンプル）

2.4.2　文字認識アルゴリズム

単一のAIモデルによる刻印品番識別結果では，再学習[注4)]手法を取り入れても工場側と取り決めた目標を満足することができなかった．そこで，再学習に加えてアンサンブル手法も取り入れた．アンサンブル手法とは，図４のような複数のAIモデルを使用して得られた結果の多数決によって，最終的な結果を出力する手法である．今回はYOLO[注5)]・CNN[注6)]・作業者の目視確認による多数決判断を行う．（図５）．

判定方法は，YOLOとCNNにて刻印品番を認識し，与えられた正解刻印品番と一致するかで判断する．AIモデルの認識した文字がどちらも正しい場合は良品（OK品），どちらも認識間違えがある場合は異常品（NG品），どちらか片方に認識間違えの場合は作業者による目視確認（Gray品）を行い，良否を判定する．このアルゴリズムによって，異常品を見逃すことなく，不正解率を低く抑える方法を確立した．

注４）過検出した製品の画像を学習データに加えて再度学習する手法

注５）You Only Look Onceの略で，「画像内に何がどこに写っているのか」を特定する用途で使用されるアルゴリズム．

注６）Convolutional Neural Networkの略で，「画像内に何があるのか」を特定する用途で使用されるアルゴリズム．

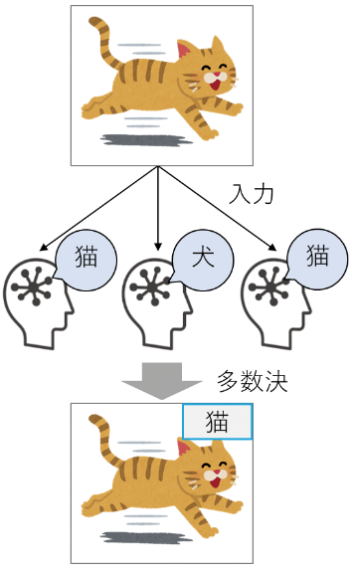

図 4　アンサンブル手法

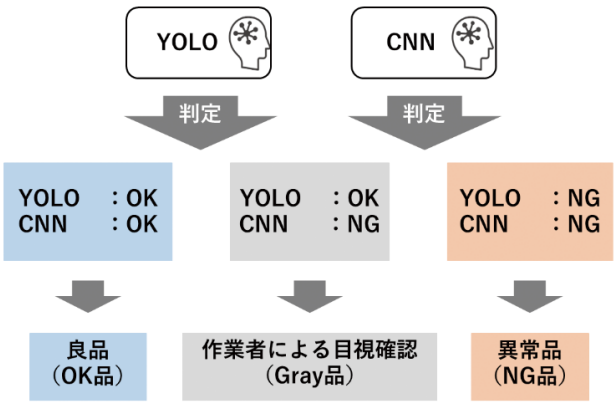

図 5　文字認識と判定のフロー

3　MLOps基盤の構築

3.1　MLOps基盤の必要性

前章までに技術構築した機械学習モデルを運用管理する上で，機械学習を行うために必要なプログラミング環境の構築といった「環境構築の複雑さ」，機械学習モデルの管理が利用者に依存してしまい，機械学習モデルの品質管理が困難になるといった「品質管理の難しさ」，機械学習モデルの運用管理における管理者の工数が大きくなるといった「運用管理工数の肥大化」などの課題が挙げられた．これらの問題を解決するために，機械学習を取り入れたシステムを効率的に運用できるMLOps基盤が必要となった．

また，MLOps基盤を構築する上で，大きくオンプレミス[注7)]とクラウドの選択肢がある。これまで，オンプレミスで運用をしていたが，検査結果の集計やAIモデルの再評価といった「モデル精度の維持管理工数の増加」，結果の一貫性や再現性が担保できないといった「データやAIモデルの管理方法の不明確さ」といった点が課題となった．これらを踏まえ，機能の拡張性や保守管理，今後の展開性や運用性などの面からクラウドにてシステムを構築するほうが優位と考え，データ収集～モデルデプロイまでMLOps一連の仕組みをAWSクラウド上に構築した．図６に構築したMLOps基盤の概略図を示す．

注７）ソフトウェア・ハードウェアを自社で保有・管理し，システムを自前で構築する運用方式．

3.2　要件

MLOps基盤を運用するための要件を以下に示す．

①刻印検査機以外への展開を見据えた柔軟性のあるシステムであること

②人間の判断が不要な定型作業を自動化し，運用工数を大幅に低減すること

③次ステップへの移行を判断する担当者への承認プロセスが自動化されていること

3.3　エッジ推論～データ保存

本基盤では再学習に必要なデータ（AIモデルによって認識間違いが発生した推論画像），推論ログ等様々なデータを使用する必要があり，それらのデータは画像やcsvなどデータフォーマットが多種多様である．加えて本基盤は刻印検査機以外への展開も見据えており，将来的には現時点で収集していないフォーマットのデータ収集を行う可能性があることから拡張性も求められる．これらの背景を考慮し，データ保存には多様なフォーマットを保存できるAmazon S3[注8)]を採用することとした．

エッジ端末[注9)]側で発生したデータは直接Amazon S3へアップロードするのではなく，中継サーバを経由することとした．理由としては以下の２点となる．

①社外ネットワークへの通信懸念（不安定さ）

②エッジ端末の動作安定性（生産に未影響）

この際，中継サーバにはAmazon S3へのアップロードに必要な権限を付与する必要がある．権限管理にはAWS IoT Core[注10)]を使用する形式とした．これにより，AWS上に登録されたデバイス（中継サーバ）のみが一時的な権限を使用してセキュアにデータアップロードすることを可能としている．

注８）タイプや容量に制限を受けることなくデータを保存，保護可能なストレージサービス．

注９）ネットワークに接続され，データの収集や処理を行う端末装置のこと．刻印検査ではカメラでの撮像～AIモデルでの刻印判定といった一連の処理を担う．

注10）IoTデバイスをAWSの各種サービスに接続するサービス．

3.4　データ処理～性能監視

従来はAIモデルの再学習要否判断を管理者が定期的に手動確認する形で運用していた．この運用では管理者負担が大きく，加えて今後対象設備が増えていくことで運用が回らなくなる恐れがある．そこで，AIモデルの性能低下を自動判定する仕組みを構築した．判定単位は以下２つとしており，設定した閾値を下回ったかを判定する．①は突発的なAIモデルの性能低下，②は時間推移に伴うAIモデル

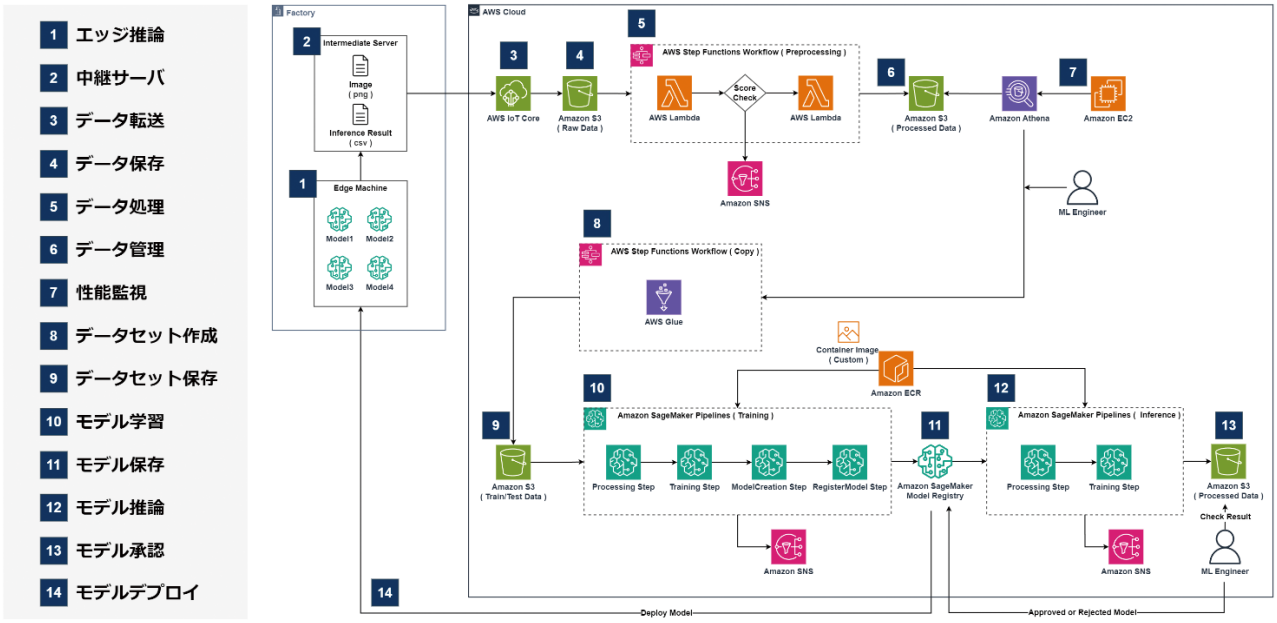

図６　MLOps基盤の概略図

の性能低下を検知する目的がある．

①処理日のモデル性能評価（日次判定）

②直近５稼働日のモデル性能評価（週次判定）

判定結果はAmazon SNS[注11)]を経由し，Microsoft Teamsのチャットに通知される（図７）．管理者は本通知で再学習要否を把握することができるようになり，運用負荷を大幅に低減することができる．

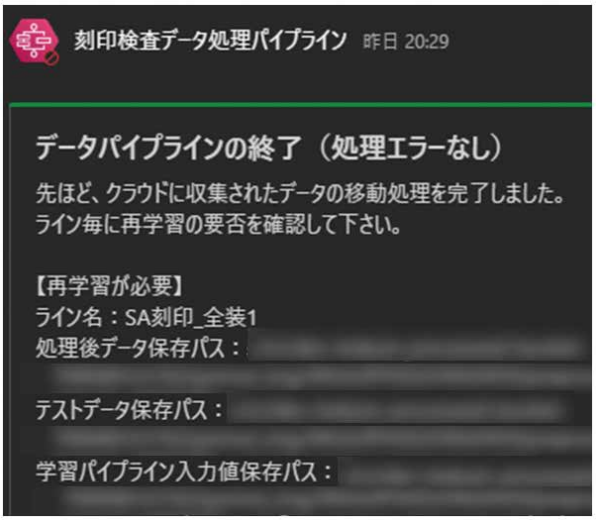

図７　データ処理完了時の通知例

更に，日常的なAIモデル性能や稼働状況把握を目的とし，BIツール[注12)]を用いたダッシュボードを作成した（図８）．BIツールは全社横断でデータ分析環境として提供しているTableau[注13)]を使用しており，構築したダッシュボードを用いることで前述したAIモデルの性能や稼働状況把握はもちろん，簡易的なアドホック分析[注14)]を行うこともできる．

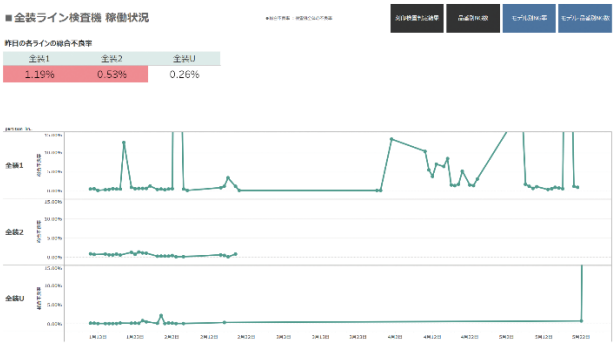

図８　AIモデルの性能監視ダッシュボード

注11）アプリケーションとAWSの各種サービス間でメッセージを送受信することができるサービス．

注12）企業に大量に蓄積しているデータから必要な情報を集約・分析し，経営や業務に活用できるようにするツール．

注13）複雑かつ大量のデータをビジュアル化することに特化したアプリケーション．

注14）分析項目や内容が決まっておらず，その都度，単発的に実施されるデータ分析のこと

3.5　データセット作成～モデルデプロイ

MLOps基盤の肝となるデータセット作成～モデルデプロイについては大きく以下の流れで実施する．

①学習/テストデータセットの作成

②モデルの再学習および承認

③モデルのデプロイ

3.5.1　学習/テストデータセットの作成

3.4節の機能でモデルの再学習が必要と判断した場合，データセット作成処理を実行する．データセットの作成には作成元となるデータセットに人の手によるアノテーション[注15)]作業を実施したデータを追加する必要があった．これを実現できるように，作成元となるデータセットの準備までを自動化し，完了したことをMicrosoft Teamsのチャットに通知する．通知を受けた管理者が，アノテーション作業を実施したデータを追加するだけで，データセット作成の処理が完了するような仕組みを構築した．

注15）AIモデルを学習させる際に必要な正解となる情報を付与する作業．

3.5.2　モデルの再学習および承認

実装環境としてはフルマネージド[注16)]かつ高速に学習・推論が行えるためAmazon SageMaker[注17)]を活用している．また，今回はMLOps基盤を構築して管理者の運用負担を低減することが目的であることから，Amazon SageMakerの一機能であるAmazon SageMaker Pipelines[注18)]を採用し，MLパイプライン[注19)]を構築することとした．パイプライン化することにより，モデルの学習，テスト，登録，デプロイといったMLOps一連の処理フローを比較的簡単に自動化することができる．

刻印検査システムは前処理含め，全部で４つのAIモデルを用いたシステムとなっている．本システムではMLパイプラインによって，４つあるモデルのうち，１つでも再学習された場合は，システム全体の推論結果を確認する必要があるため，図９のように推論パイプラインの中で４種類の性能評価を行うこととした．これによって，AIモデル単体の性能改善だけでなく，システム全体としての評価が可能とする仕組みを構築できた．

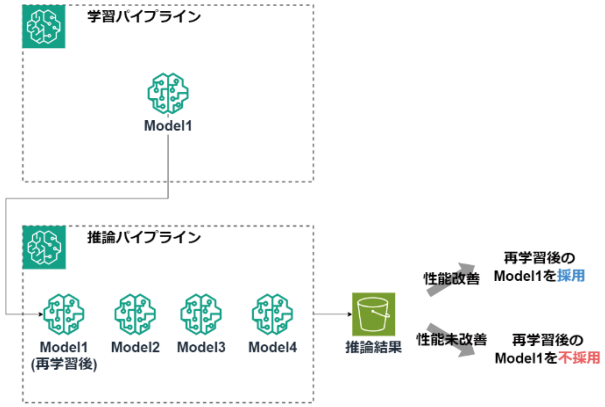

図9　学習および推論パイプラインの処理フロー

推論結果の出力まで完了すると，Microsoft Teamsのチャットに推論結果の確認依頼を通知する様に構築している（図10）．これにより，性能改善された場合は「再学習モデルを採用」，改善されなかった場合は「再学習モデルを不採用」を選択といった様にMicrosoft Teams上のUI操作のみでAIモデルの採否を決定することができる．採用されたモデルはAmazon SageMakerの一機能であるAmazon SageMaker Model Registry[注20)]上に登録され，その後Amazon S3へ保存され，エッジデバイスへのモデルデプロイが可能な状態となる．

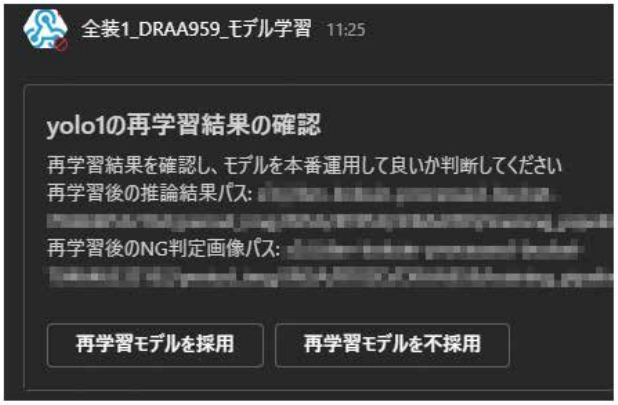

図10　推論結果の確認依頼通知

注16）ユーザがサービスを利用する際に，「コンピュータ障害監視・バックアップ・ソフトウェアのバージョンアップ」など「運用に関わる作業」を業者が行ってくれる形態．

注17）AIモデルを高速に開発，学習，配布するための環境を提供するサービス．

注18）MLOpsの各ステップを自動化するワークフローオーケストレーションサービス．

注19）データの前処理からモデルのトレーニング，評価，デプロイメントまでの一連の手順やプロセスをワークフロー化したもの

注20）AIモデルの管理とデプロイを支援するサービス．

3.5.3　モデルのデプロイ

3.3節に記載したデータアップロードの懸念と同様の理由で，モデルのデプロイも中継サーバを経由して適用させることとした．日次で中継サーバ側からAmazon S3上のモデル保存先を確認し，最新モデルが存在した場合は一時的に中継サーバにダウンロード，生産に影響がないタイミングでエッジ端末へデプロイという仕組みで実装している．

3.6　再学習時の手順

3.5節にて解説した再学習の流れを実施するには，管理者がAmazon S3からデータのダウンロード等をコマンドベース（CUI[注21)]）で実行する必要があった．それらの作業を簡略化するため，図11のようなGUI[注22)]上で操作可能なアプリケーションを作成し，容易に再学習を実施することを可能とした．これにより再学習に必要な手作業工数を低減することができた．

図11　再学習用GUI

これらの仕組みを構築し，AWSクラウドを利用することで，AI実行サイクルの効率化やデータの運用・管理を適切に行い，AIの品質を高水準に保つことが可能となった．

注21）ユーザがテキストコマンドを入力してコンピュータと対話（操作）する方法．

注22）ユーザがアイコンやメニューなどの視覚的な要素を使用してコンピュータと対話（操作）する方法．

4　今後の展望

刻印品番識別技術は，2024年6月1日時点で1拠点，4つの量産ラインに導入している．加えて，刻印品番を全数目視で読み取る量産ラインは多数存在

するため，今後も本技術の水平展開を実施し，作業者の省力や品質保証の向上に貢献していく．

AIモデルの維持管理システムを構築したことで，AIモデルの再学習に費やす工数の削減や稼働状況を容易に確認することができる．現時点では，運用期間が短く，大きな成果は今後の期待だが，量産運用を重ね，信頼性が得られてきた．本システムを効率的に展開していくためには，工場の各部署との協力が必要不可欠である．本システムの運用面について導入部署と協議し，導入を推進していく．

刻印検査以外の工程についてもAIを用いた検査技術を採用予定であり，それら工程へMLOps基盤の展開を推進し，生産性向上や品質向上に貢献していく．

5 結言

本開発により，刻印検査における省力および品質保証度向上を実現することができた．

最後に，本開発にあたり多大なるご支援，ご協力を頂いた関係部署の方々に，この場をお借りして厚く御礼申し上げる．

著　者

光尾　崇

2006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．

鈴木　健斗

2016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．

宮内　悠樹

2017年入社．デジタル変革推進本部 デジタル戦略室所属．
クラウドを活用したシステム構築に従事．

菊池　貴好

2014年入社．デジタル変革推進本部 デジタル戦略室所属．
クラウドを活用したシステム構築に従事．