

AI ピッキングシステム

The AI picking system

山本 惇史 有田 航 齊藤 嵩 駒池 国宗

Abstract

The AI picking system is a bulk bin picking system (the work of picking parts from the parts box which is filled with randomly piled parts) that uses an image processing AI method. This system is currently being brushed up to be used as a facility, and is undergoing the proof of concept in the kitting process where automation has not progressed in the Robotics Division (see Fig. 1). Here, we introduce technical topics related to this concept.

1 はじめに

AIピッキングシステムとは、画像処理AIによるバラ積みビンピッキング(バラ積み部品を部品箱から取り出す作業)のことである。本システムはロボティクス事業部内で自動化が進まないキットング工程において実証実験を進めつつ、設備としてのブラッシュアップを図っている(図1参照)。ここでは、その技術トピックを紹介する。

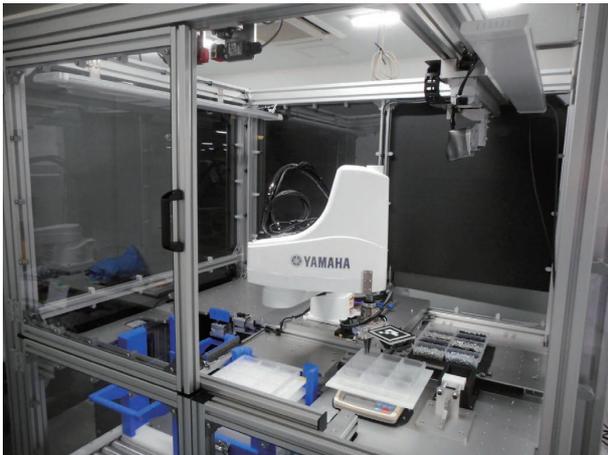


図1 設備外観

2 AI ピッキングシステム

2-1. 開発背景と課題

近年の省人化・自動化の流れを受けて、各業界で様々な取組が進んでいる。ロボティクス事業部内でも自動化を推進しているが、困難な工程として組立部品の小分け作業『キットング工程』が挙げられている(図2参照)。一般的に、この工程を市販のビンピッキングパッケージで作り込む場合、担当者が関わる作業は設備設計だけでなく、実際にピッキングに必要な部材の準備や実運用、品質維持の仕組みづくり等、負荷は膨大なものとなり、結果としてうまく利用できない状況に陥ることが多々ある。現場の生産技術やSIer(システムインテグレーター)の担当

者が、ピックシステムの準備にかかる工数の低減を図ることが急務な課題であった。

2-2. システム概要

本システムの動作原理を示す(図3参照)。システムの流れとしては、マスタキットの把握(自動)から始まり、その入力条件に従い、供給ビン(部品箱)から適切な部品種を員数だけ、トレーにピックアップする。この作業を実現するのは時間も労力もかかるため、特別なプログラム作成が不要なこと(表1参照)を目標に開発した。この要素技術の1つが把持位置推論AIである。

また、実証実験を進めながら、設備性能を維持する上で重要な機能:品質AIも独自開発してきた。ここでは、本システムを支えるAI技術として、把持位置推論AI(詳細は3章参照)と実証実験からのフィードバックである2つの品質AI(詳細は4章、5章参照)について紹介する。

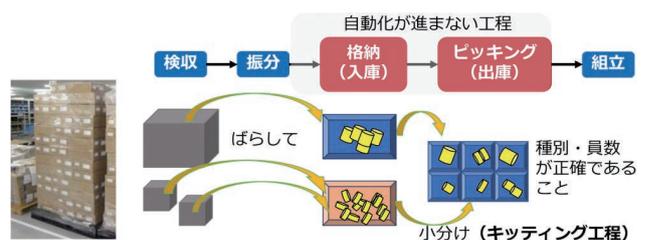


図2 自動化が進まない工程

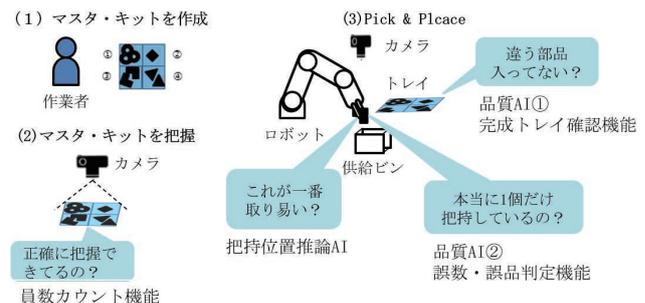


図3 AI ピッキング動作原理

表1 プログラミングを不要とするための技術

特別なプログラミング(手順)	従来	本システム
	下記の通り必要	下記の通り不要
把持するまでの準備	パーツライブラリで部品毎に認識方法や制御方法の設定と下記把持位置指定が必要である。	あらかじめCADを用いた深層学習で把持可能となるため特別な設定不要である。
把持位置の設定	部品のどこを把持するか指定が必要である。AIを用いる場合でも部品姿勢毎の学習が必要な場合がある。	上記学習で把持可能と判断した位置を掴むため作業による指定は不要。
マスタキット状態のシステムへの入力	手作業	カメラで撮像し自動設定(開発中)

3 把持位置推論 AI

3-1. 既存技術

ピンピッキングでは箱の中にランダムに入れられたバラ積み部品の中から、最も取りやすい部品を選び出す必要がある。取れそうな部品を選択するアルゴリズムとして、一般的には点群テンプレートマッチングが用いられることが多い。この手法では図4のように事前登録された部品のCADの点群(テンプレート)を用意し、バラ積みしたビンの中からそのテンプレート点群と類似した箇所を探索し部品として選択する。

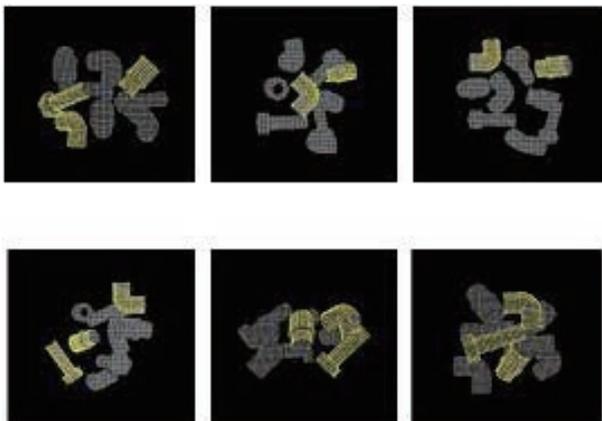


図4 テンプレート部品をバラ積みされた部品の中から検出する様子^[1]

3-2. 開発した手法について

しかしこの手法では、部品のCADデータを事前登録する必要がある。また、ネジなどでは太さ違いや長さ違い、ヘッドの形状の違いなど類似した部品が多く、それぞれに登録し直す必要がある。そこで、今回採用したのは深層学習による認識である。深層学習により、点群テンプレートマッチング時に使用する特徴量よりも柔軟な特徴量を見つけ出し、把持位置を検出させる。

深層学習の学習データの収集には物理シミュレーションも併用する。この物理シミュレーションでは部品の形状、配置、摩擦

係数が調整できる。条件を多様化させるためにランダムに部品を配置させ、ピンピッキングを行う。図5にデータ収集の様子を示す。バラ積み部品が格納された容器の画像をx,y方向に一定サイズに切り取る。この時、容器の画像も回転させた後に同様の処理を行う。この回転角度はハンドの回転角度に一致する。このようにして切り取られた画像から方策に従って1枚選び、物理シミュレーションでピッキングを行い、把持が成功したかどうかのデータ収集を行う。これを繰り返すことである程度まとまった学習データセットを準備し、その後に学習を行う。

シミュレーション画像での学習が完了した後、必要であれば、実機での画像を追加学習させる。こうして作成した深層学習モデルを用いてバラ積みビンの中から把持できそうな部品の場所を画像から推論することができる。

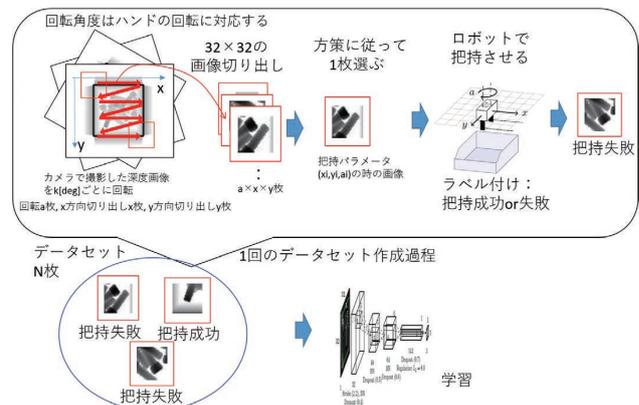


図5 ピッキングデータ収集の様子

3-3. 効果確認

本開発で作成した深層学習モデルを用いてピッキングを行った結果を示す(表2参照)。類似のねじに関してはサイズ違いであっても同程度の把持成功率を実現できている。

表2 部品ごとの把持成功率

把持成功率80%	把持成功率80%
把持成功率73%	把持成功率67%

4 品質 AI①: 誤数・誤品判定機能

4-1. 目的・機能概要

今日の製造現場では、締結部品の締め忘れや締結箇所間違いなどを防ぐため、必要な部品を必要な個数だけ小分けするボルトキットを作成し作業することが一般的である。

この判定機能はトレーへ部品を入れる際に作業者が目視などで部品の個数・種類を確認する作業を代替するものである。本機能で対象とする入力画像を図6-1に示す。本機能では部品を供給ピンからトレーへ運搬する過程でロボットハンドが部品を掴んでいる状態を撮像し、その画像をもとに部品の種類や個数を判定するものである。

4-2. 既存技術

画像分類を行う手法は数多く存在するが、近年では深層学習ベースの手法が多く開発されている。深層学習ベースの手法には、いくつかの課題が存在する。そのうちのひとつが判断基準の難解さである。一般的に深層学習においては損失の値や注目領域の可視化により、その手法が何を基準に判定を下したかの説明を行う。しかしながら、誤判定した画像に関しては有意な説明が得られないことが多い。

こうした課題がある一方で、深層学習ベースの手法ではルールベースに比べ、入力画像に対するロバスト性が高く撮影条件の多少の変化や部品の姿勢などには柔軟に対応できるなどの優位性が挙げられる。今回のターゲットとなる状況では、図6-1に示すように把持される部品の姿勢が様々である。それゆえ今回の開発手法では深層学習ベースの距離学習^[2]を用いた。



図6-1 本機能の対象とする入力画像

4-3. 開発した手法について

距離学習では、図6-2に示すように入力画像を二次元の特徴量空間に落とし込み、同じクラスの画像の特徴点同士を近づけ、異なるクラスの画像の特徴点を遠ざけるように学習する。推論時には、入力した画像の特徴点と学習時の各クラスの中心点との距離を算出し最も距離の近いクラスを推論結果として判定する手法である。この手法では二次元の特徴量空間での各画像の位置関係を可視化できるため、深層学習ベースの手法では難解である判定基準についても理解が容易であることも利点である。

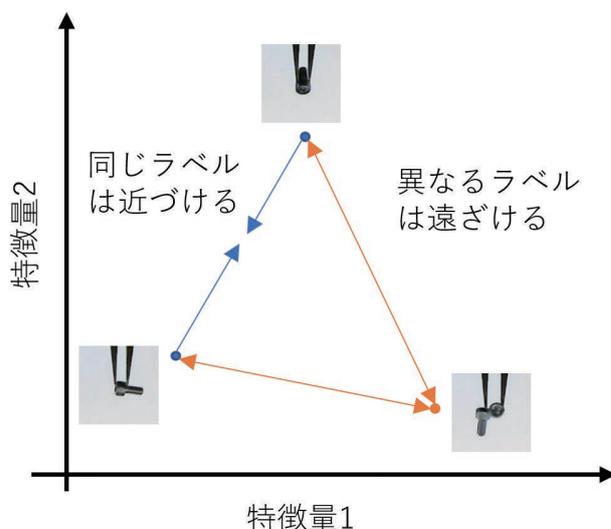


図6-2 本機能で用いられる距離学習の仕組み

4-4. 効果確認

図6-1で示した部品の画像1000枚に対し、ルールベース、一般的な深層学習モデル (ResNet50)、本手法での比較を行った。

表3に示すようにルールベースに比べ、深層学習ベースの本手法や ResNet50では学習データの枚数に大きく差がある。この学習に必要なデータ数の多さは深層学習ベースの手法の課題であり、今後の改善が必要である。しかしながら、正解率では深層学習ベースの手法がルールベースに比べ高く、特に本手法の精度が一番高い結果となった。

表3 本手法とルールベース、ResNet50の効果比較

手法	学習データ枚数	正解率
本手法	1500枚	99.9%
ルールベース	100枚	85.0%
ResNet50	1500枚	98.8%

5 品質 AI②: 完成トレー確認機能

5-1. 目的・機能概要

ピッキング後のプレス時に、部品のピンへの入れ間違いや移動途中の落下などにより、トレーのセルに入った部品の種類・員数間違いが発生することがある。そこで、実際の生産現場ではキッキング後に人間による目視確認が行われる。本機能はその作業を自動検査により代替することを目的としている。

本機能でターゲットとする状況を図7-1に示す。複数個の部品が未整列、平置き状態となっている。また、部品背景には識別用の印字があったり、部品の隣接などの発生により部品の輪

郭の特徴が変わったり、部品の向きによって見え方が変わったりする。そのため、画像による認識には、これらの特徴の変化を許容できる手法を採用する必要がある。

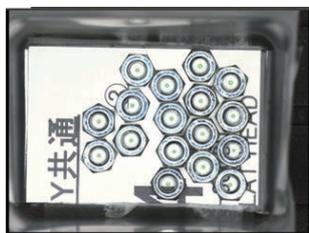


図7-1 セル内の部品の例



図7-2 尤度マップ

5-2. 既存技術

部品を認識する手法は多数存在する。大きく分けて2つのカテゴリに分類できる。1つは手続き的な処理によって構成されたルールベース、もう1つは経験から学習して処理を決定する機械学習を用いた手法である。ルールベースでは、テンプレートマッチング、キーポイントマッチング等が存在し、産業界で数多くの実用例が存在する。一方で、認識対象物やカメラ・照明条件に合わせてパラメータ調整など作り込みが求められる、高精度を実現するためには高度な技術力が必要である。本製品の狙いとして、お客さまが専門技術を持たなくても利用できることが求められるため、本手法をそのまま適応することは難しいと考えた。

他方、機械学習を用いた手法では、近年は Deep Learning (DL) ベースが興隆を見せ、主なものとして Object Detection (OD) モデルを用いたものが挙げられる。こちらも産業界で実例が多数存在する。しかしながら、DL ベースの手法では、パラメータが多いことが起因し、高精度を実現するためには大量の学習用データが必要といわれている。実運用を想定した時、学習用データを作るために大量の画像の収集と、画像上の部品位置をデータ化するアノテーション作業が必要となるが、お客さまが作業することは工数的にもスキルのにも難しい。その負担を解消するための、学習用データを減らす研究が進められており、例えば、少ないデータから効率的に学習する few-shot learning などが存在する^[3]。しかし、いずれも部分的には強力な効果を発揮するものの、他方では効果が弱まるなど、タスクに合わせた慎重な手法の選択と検証が必要となる。

5-3. 開発した手法について

今回開発した手法では、ルールベースと機械学習を組み合わせた。これにより、ルールベースと機械学習の長所を生かし、短所を打ち消すことを狙った。

ルールベースをベースとした手法に対して機械学習的に精度を上げていくフローを作成した。これにより精度を確保するとともに、データセット作成工数の課題を解決する。その他にも、機械学習モデルのみを採用する場合よりも、判定ミスをした際の原因究明や改善も実施しやすくなるという優位点を併せ持つ。

本手法では部品が存在する尤もらしさをマップ化した尤度(ゆうど)マップを作成し、尤度が高い位置を部品位置と判定する。一例として、図7-1を対象としたときの尤度マップを図7-2に示す。

5-4. 効果確認

形状が類似した部品が混入した場合を想定したケースにて、ルールベース、OD、本手法の比較を行った。図8に画像の例を示す。



図8 対象画像の例

M4長さ8mm ボルト4本の中に、M4長さ10mm ボルト1本が混入した状況を想定した。現場での運用を想定し、以下の条件の下で、各手法の比較を行った。

- 学習用データに関して、段取り替えの際に不都合のない程度の工数としてアノテーションが10分以内で完了する分量を想定した。実測の結果、画像20枚分を実施した。
- ルールベースに関して、現場に画像処理の専門家がいるとは限らないため、パラメータ調整を行わない。

結果を表4に示す。ODでは学習用データが足りず、正解率を高めるレベルまで学習が完了できなかった。ルールベースでは、ODよりも正解率が高いものの、生産現場で利用するには難しい。一方で、本手法では少ないデータ数でも高い正解率を確保することができた。

表4 完成トレー確認機能 手法による精度の比較

手法	学習用データ	精度
ルールベース(ZNCC)	1枚	70%
OD(yolo v5 fine-tuning)	20枚	0%
本手法	20枚	96%

6 おわりに

今回、本システムの基本機能である把持位置推論 AI、設備性能の維持を目的とした2つの品質 AI について紹介した。本システムは、2022年国際ロボット展に参考出展し、好評を得たことで、ソリューション展開の必要性をより一層実感した。現在は、外販に向けた商品企画を策定中である。お客さまに、『こんな設備が欲しかった』と言ってもらえるように現場と一丸となって設備のブラッシュアップを進めていく。

■参考文献

- [1] K.-T. Song, C.-H. Wu, S.-Y. Jiang; CAD-based Pose Estimation Design for Random Bin Picking using a RGB-D Camera; 2015
- [2] Y. Wen, K. Zhang, Z. Li, Y. Qiao; A Discriminative Feature Learning Approach for Deep Face Recognition; 2016
- [3] Q. Sun, Y. Liu, T. Chua, B. Schiele; Meta-Transfer Learning for Few-Shot Learning; Computer Vision and Pattern Recognition; 2019

■著者



山本 淳史
Atsushi Yamamoto
ソリューション事業本部
ロボティクス事業部
先行開発部



有田 航
Wataru Arita
ソリューション事業本部
ロボティクス事業部
先行開発部



齊藤 嵩
Takashi Saito
ソリューション事業本部
ロボティクス事業部
先行開発部



駒池 国宗
Kunimune Komaie
ソリューション事業本部
ロボティクス事業部
先行開発部