

インスタンスセグメンテーションを用いた組立進捗推定

○ 湯本茂樹[†], 橘川拓実[†], Sarthak Pathak[‡],

Alessandro Moro[‡], 梅田和昇[‡]

○ Shigeki YUMOTO[†], Takumi KITSUKAWA[†], Sarthak PATHAK[‡],

Alessandro MORO[‡], Kazunori UMEDA[‡]

[†]: 中央大学大学院理工学研究科精密工学専攻, yumoto@sensor.mech.chuo-u.ac.jp

[‡]: 中央大学理工学部精密機械工学科

[§]: RITECS Inc.

<要約> 本論文では, 深層学習を用いて工場での製品を組み立ての進捗判定を行う手法を提案する. インスタンスセグメンテーションを用いて, 部品を検出し, 検出した部品の数や種類により進捗推定を行う

<キーワード> 工場, 深層学習, インスタンスセグメンテーション

1. 序論

近年, 画像処理技術や AI, IoT 技術の発展により工場のスマートファクトリー化が進められている. スマートファクトリー化によって製造業における人手不足の解消や生産効率の向上が期待されている. 中でも進捗管理の自動化は業務の効率化や作業の問題発見など重要な課題である.

しかし多品種少量生産型の工場では人手による作業が中心になるため作業員自身が進捗管理を紙に記すなどの方法で行っていることが多い. また人手による作業が中心になっている既存の工場にはロボットや IoT を活用した大規模なシステムを導入するのは困難であると考えられる.

そのため工場内の定点カメラから取得した映像を活用した手法が有効であると考えられる. 関連研究[1][2]では, 組立製品を検出し, 切り出した領域に対してクラス分類を行うことで進捗の推定を行っている. しかし製品全体を見てクラス分類を行うため, 誤った組立をした場合, 異常と判断することが難しい.

本研究では組み立てる製品の部品に着目し, 組立作業の進捗を推定する手法を提案する. 具体的にはインスタンスセグメンテーションにより部品を検出し, これを使ってクラスを判定する. 製品全体では

なく部品に注目することで進捗推定に加え, 誤った組立の判断することができると考えられる.

2. 提案手法

2.1 提案手法概要

提案手法概要を図 1 に示す. まずモデルに部品画像を学習させる.




図 1 提案手法概要

次に学習したモデルに画像を入力し, 検出結果を出力する. 検出結果から進捗の推定を行う.

インスタンスセグメンテーションには YOLACT[3]を使用する. YOLACT は高速なインスタンスセグメンテーションが可能なモデルである. 学習済みモデルをファインチューニングし, 使用する.

2.2 進捗の推定手法

進捗の推定は、インスタンスセグメンテーションによって検出結果を利用する。検出された部品の種類や数によって予め定義した進捗を推定する。検出結果が定義されていない組み合わせの場合はエラーとする。また組立作業中に図2のような作業者によってオクルージョンが発生する可能性がある。一部の部品が隠れてしまうと進捗の誤判定につながると考えられる。そのため作業者を検出し、検出中は進捗推定を行わないようにする。



図2 オクルージョンの例

3. 実験

3.1 実験1概要

提案手法を用いて組立進捗の推定実験を行った。実験1ではエラー推定及び作業者の検出は行わずに組立進捗の推定のみを行う。実験環境を図3に示す。実験の対象としてデスクトップパソコンを使用した。天井に設置したwebカメラにより作業動画を取得する。使用したカメラはアイ・オー・データ機器社のネットワークカメラ Qwatch の TSWR-LP を利用し、画素値は1980×1080に設定した。推定する進捗の定義を図4に示す。進捗は0から6の7工程とした。

学習データは84枚、テストデータは49枚、学習回数は5085epoch、バッチサイズは4とした。検出する部品はケース、電源ユニット、マザーボード、CPUファン、GPU、HDD、ケースカバーとした。テストデータに対して正しく進捗の推定ができるかを評価する。



図3 実験環境




図4 進捗の定義（実験1）

3.2 実験1結果

実験結果を図5に示す。用意したテストデータ49枚に対して全て正しいステップに分類することができた。図6と図7を見ると部品の検出についても正しい位置で検出ができ、マスクも概ね正しい位置に表示できていることがわかる。




図5 実験1結果



図6 部品の検出結果 1




図7 部品の検出結果 2

3.3 実験 2 概要

提案手法を用いて組立進捗の推定実験を行った。実験 2 では組立進捗を追加し、さらにエラー推定および作業者の検出も行う。実験環境および組立対象は実験 1 と同様のものを用いる。推定する進捗の定義を図 8 に示す。進捗は 0 から 8 の 9 工程に加えて作業中は「Work」、誤った組立の場合は「Error」、何も検出されない場合は「None」とする。

学習データは 165 枚、テストデータは 93 枚、学習回数は 4600epochs、バッチサイズは 4 とした。検出する部品はケース、電源ユニット、マザーボード、CPU、CPU ファン、メモリ、GPU、HDD、ケースカバーとした。また加えて作業中であるかを判定するために作業者の検出も行う。テストデータに対して正しく進捗の推定ができるかを評価する。




図8 進捗の定義 (実験 2)

3.4 実験 2 結果

実験結果を図 9 に示す。用意したテストデータ 93 枚に対して正解率は 89.2%と高い精度で進捗推定ができていたことを確認した。図 10 を見ると部品の検出についても正しい位置で検出ができ、マスクも概ね正しい位置に表示できていることがわかる。また図 11 では電源ユニットの次に設置するマザーボードの代わりに HDD を設置した誤った組立である。誤った組立のため「Error」と正しく判断できていることがわかる。図 12 では、作業者の検出ができていたことがわかる。一方で図 13 を見るとメモリを検出できておらず本来 5 と判定される進捗が 4 と誤判定されてしまっている。このことから小さい部品の検出には難しいと考えられる。




図9 実験 2 結果




図10 部品の検出結果




図 11 誤った組立の検出




図 12 作業者の検出




図 13 進捗の誤推定の例

参考文献

- [1] 橘川拓実ら：“Deep Metric Learning を用いた組立作業の進捗判定”，2022 年度精密工学会秋季大会学術講演会講演論文集
- [2] 大島宏友ら：“深層学習を用いた製品状態の推定に基づく作業進捗の自動抽出”，生産システム部門研究発表講演会 2022 講演会論文集
- [3] D. Bolya, et al.: “Yolact: Real-time instance segmentation,” in The IEEE International Conference on Computer Vision (ICCV), October 2019

4. 結論

本研究では，インスタンスセグメンテーションを用いた製品の組立進捗推定手法を提案した．提案手法を用いてデスクトップパソコンに対して組立進捗推定の実験を行った．

実験 1 では全てテストデータに対して正しい進捗の推定をすることができた．実験 2 では進捗を追加し，作業者の検出およびエラー推定を行った．テストデータに対して正解率 89.2%と高い精度で進捗推定ができていることを確認した．

今後の展望として，部品の検出に特化したネットワークへの改良，工場での実データによる実験が考えられる．