

ディープラーニングを用いた手挿入部品検査の検討

池田 溪一郎[†] 鈴木 ひなの[†] 高島 信秀[‡] 倉町 建士[‡] 梶 克彦[†] 内藤 克浩[†] 水野 忠則[†] 中條 直也[†]
愛知工業大学[†] 三菱電機エンジニアリング株式会社[‡]

1 はじめに

近年、工場では人材不足、製造物の多様化が進み、検査の自動化のニーズが高まっている。しかし、既存の画像センサでは検査工程の自動化は全て実現できていない。特に少量生産に対応する手挿入部品の検査については自動化が難しく、目視検査が行われる。

基板を製造する際、部品の手挿工程ではそれが正確な部品配置であるかどうかの検査を行う。目視による手挿入部品検査では見逃しが起こる可能性がある。また、手挿工程での装置による検査では、部品がはんだ付けされていないため、安定しないなどの課題がある。

一方、ディープラーニングは、2012年にILSVRCという大規模な画像認識コンテスト以降、その有効性が認識されている。現在では様々なモデルが提案され、研究が行われている [1]。そして、製造業、医療、防犯など数ある分野の画像処理に適用されるようになってきている。先行研究として、ディープラーニングを使った部品の欠陥検出がある [2]。

本研究では、工場の部品手挿工程において物体検出を可能にするディープラーニングを用いることで検査の自動化と精度の向上が可能であるのか検討する。ここでは、部品の種類の識別に着目する。

2 手挿入部品検査

本研究の手挿入部品の対象を図1に示す。このように配置がぐらついた状態で検査を行う必要がある。



図 1. 識別する電解コンデンサの例

2.1 物体検出のアルゴリズム

本研究では、物体検出のアルゴリズムである Single Shot MultiBox Detector(以下, SSD)[3]を用いる。

SSDは、低解像度でも精度が良いことや高速で物体検出を行うことができる。多オブジェクト検出に有効であるため基板上的様々な部品の識別に期待できる。

2.2 学習用の画像データ作成

ディープラーニングが高いレベルの認識精度を実現するには、数千～数万枚もの画像データが必要である。画像データの作成方法として、カメラによる方法と3DCGによる方法の二つを用いた。例を図2に示す。先行研究の3DCGを使った物体検出では、画像のみで物体検出を行なった際よりも精度が向上することが報告されている [4]。



図 2. データの例

3DCGでは、部品を参考にモデル作成を行なった。この3DCGモデルに対し、水平方向に0～360度へ回転させ、垂直方向に0～90度へ視点を変更を行うアニメーションをつけた。これを10度毎にレンダリングを行なった。カメラでは、水平方向に同様に撮影を行い、垂直方向は0～60度へ6度毎に視点変更を行い撮影した。また、これらの画像データを用いて、画像処理によるデータの拡張を試みた。データ拡張は、元のデータに変換を加えてデータ量を増やすことである。変換では、画像を回転、シフト、フィルタをかけるなどの処理を行う。これによって、数百枚の画像から数千枚の画像を作成した。

3 実験

本研究では、部品の一つである電解コンデンサの検出精度を比較する実験を行なった。学習データには、部品を撮影したカメラ画像と3DCG画像、データ拡張画像を利用した。それぞれの画像の枚数を表1に示す。ディープラーニングには、学習データに正解領域のラベル付けを行い教師データとしたものを用いている。そして、SSDで動画から物体検出を行い、精度を評価した。物体検出を行う動画にはブレッドボード上に学習させた電解

Exmination of hand insertion parts inspection using Deep learning

[†] Keiichirou Ikeda, Hinano Suzuki, Katsuhiko Kaji, Katsuhiko Naito, Tadanori Mizuno, Naoya Chujo: Aichi Institute of Technology

[‡] Nobuhide Takashima, Takeshi Kuramachi: Mitsubishi Electric Engineering

コンデンサを配置して撮影したものを用いた。

基板上の部品の種類と数は多いため、学習データとするカメラ画像は何万枚も撮影が必要で時間がかかってしまう。しかし、3DCG 画像の作成による収集方法は効率的である。基板上の部品はメーカーが CG モデルを配布しているため 3DCG モデルは短時間で作成可能であり、様々な角度の画像取得も容易に行えるからである。今回の実験では、カメラでの撮影には 100 枚あたり 1 時間かかり、3DCG 画像は同枚数で 100 分の 1 の時間でレンダリングが可能であった。

表 1. 実験毎のデータ数

学習データ	電解コンデンサ	元画像	データ拡張	合計
① カメラ画像	3900 μ F	360	3240	3600
② カメラ画像	3900 μ F	360	6480	6840
③ 3DCG	3900 μ F	360	3240	3600
④ 3DCG	3900 μ F	360	6480	6840
⑤ 3DCG	0.33 μ F	360	6480	6840
⑥ 3DCG	100 μ F	360	6480	6840

3.1 学習データの比較実験

3DCG 画像データの有効性を確認するために比較実験を行なった。また、学習データ量の違いによる精度の推移も実験した。学習データとして表 1 の①, ②, ③, ④を使用した。評価方法として正解のうち、再現率と適合率を用いて評価する。物体検出を行う動画には学習させた電解コンデンサのみ配置して、手持ちで角度を変えながら撮影したものを用いた。

結果を図 3 と図 4 に示す。1 種類の電解コンデンサが検出できることを示している。また、データ拡張によって学習データ量を増やしたことで、再現率と適合率が 90 % 以上と高い精度を得られた。また、3DCG 画像データを用いた方が高精度であった。




図 3. 検出結果の例




図 4. 学習データ別の検出精度

3.2 3種類の電解コンデンサ検出実験

基板上の部品の種類は多く、数ミリ程度のものが多いため部品検査の際に部品に焦点を合わせづらいことが想定される。そこで、電解コンデンサの種類を 3 種類に増やして、2 種類の解像度の動画で評価する実験を行った。方法として、表 1 の④, ⑤, ⑥の学習データを使用する。物体検出を行う動画には、学習させた 3 種類の電解コンデンサと学習させていない電解コンデンサ 2 種類を配置して定点で撮影を行った HD(1280*720pixel) の動画と VGA(640*480pixel) の動画を用いている。

HD の動画の検出でも電解コンデンサの種類を増やすと誤検出は増えた。再現率は 92 % と高かったが適合率は 78 % となった。VGA の動画を用いるとさらに誤検出は増えて、再現率が 78 % で適合率が 55 % に低下した。

4 おわりに

本研究では、ディープラーニングを用いて手挿入部品を検出して評価する実験を行なった。実験から部品の学習データをカメラ画像ではなく 3DCG 画像を使用することで短時間で高精度な物体検出が可能であることが分かった。3DCG を使ったディープラーニングの物体検出でも手挿入部品検査において有効であると考えられる。

しかし、学習させた電解コンデンサを 3 種類に増やした物体検出では精度が低下した。

今後、学習データの追加と見直しで精度の改善を行い、電解コンデンサ 10 種類を 3DCG モデル化して物体検出の精度をはかる実験を行う予定である。

参考文献

- [1] Deng, J., et al. “ILSVRC-2012.” <http://www.image-net.org/challenges/LSVRC/2012/> (2019 年 9 月 30 日閲覧)
- [2] Yuki Hanzawa, Yasuyuki Ikeda, Masashi Kurita and Yuki Hasegawa. “AI 技術による外観検査の自動化”. *OMRON TECHNICS*, Vol.51.003JP, 2018.11.
- [3] Liu, Wei, et al. “Ssd: Single shot multibox detector”. European conference on computer vision, Springer, Cham, 2016.
- [4] Tsukasa Kudo. “Training Data Generation Method for Deep Learning Using Cycle-GAN”, International Workshop on Informatics, 2019.