

4J-03

## 立体的な配線における接続先間違い, 端子外れ, 断線の検査の検討

田中颯<sup>†</sup> 蓮尾崇<sup>†</sup> 高島信秀<sup>‡</sup> 倉町建士<sup>‡</sup> 梶克彦<sup>†</sup> 内藤克浩<sup>†</sup> 水野忠則<sup>†</sup> 中條直也<sup>†</sup><sup>†</sup>愛知工業大学 <sup>‡</sup>三菱電機エンジニアリング株式会社

## 1 はじめに

近年, 工場では人手不足が進み, 検査工程の自動化のニーズが高まって平面的なプリント基板の配線検査は自動化がすでに実用化されている。しかし, 立体的な配線の検査は, 現在の検査方式では自動化されていない。

一方, ディープラーニングは, 2012年にILSVRCの画像認識コンテストで注目されて以降 [1], 有効性が認識された。またディープラーニングを使った部品の検査も研究されている [2]。

本研究ではディープラーニングを用いて立体的な配線の検査を行う。ディープラーニングでは膨大な数の学習用の画像データが必要となるため, 学習用の画像データにCGモデルを用いた画像を利用することで学習の効率化を図り, 同時にディープラーニングにおけるCG画像の有効性の検証も行う。また, 立体的な配線の検査精度向上のため, 上部からだけでなく多方向からの撮影の必要性を検討する。

## 2 ディープラーニング

本研究のディープラーニングでは畳み込みネットワークとKerasを用いて学習・検証を行う。

## 2.1 畳み込みネットワークについて

本研究では畳み込みネットワークを用いて学習を行った。畳み込みネットワークとは, 1つ目の畳み込み層でエッジといった小さな局所的パターンを学習し, 2つ目でそれを元により大きなパターンを学習することで視覚概念の抽象化を効率よく行うことが可能である。

## 2.2 Kerasについて

本研究ではネットワークライブラリのKeras[3]を利用する。Kerasとは, Pythonで記述された高水準のディープラーニングのフレームワークであり, 少ない行数のプログラムでニューラルネットワークの記述が可能になる。また, プロトタイプを簡単に素早く作成可能で, 本研究で利用した畳み込みネットワークが利用可能である。

Examination of inspection for misconnection, terminal disconnection, and wire breakage in three-dimensional wiring

<sup>†</sup>Hayate Tanaka, Takashi Hasuo, Katsuhiko Kaji, Katsuhiko Naito, Tadanori Mizuno and Naoya Chujo: Aichi Institute of Technology  
<sup>‡</sup>Nobuhide Takashima and Kenji Kuramachi: Mitsubishi Electric Engineering Co., Ltd.

## 3 学習用画像の作成

学習データとなる実写・CG画像の作成について述べる。

## 3.1 実写画像

撮影ボックスの上部にカメラ, 内部に配線を設置する。そして鮮明に画像を作成するためにライトを縦横方向に設置して照らし, 配線下に光の反射防止材を敷いた。

## 3.2 CG画像

CG画像は, 3DCG作成ソフトのMayaを用いて作成した。Mayaで配線の3Dモデルを作成し, それを画像として出力するレンダリング工程を経て学習用画像を作成する。CG画像作成の効率化のためには, Mayaの基本機能であるアニメーション作成機能を用いた。3Dモデルをアニメーション化し1フレーム毎に画像出力するバッチレンダを用い, 人間が作業する実作業時間が1/24にまで削減できた。

この手法でのCG画像作成では, 1000枚作成する際は1枚につき実作業時間0.6秒で作成でき, 実写画像と比べて2.9時間の削減となった。

以下は, 作成した実写画像とCG画像の一例である。




図 1: 学習用画像の例


## 4 実験

実験で使用した誤配線パターン, および, 多方向撮影の必要性について検討した予備実験について説明する。これらに基づいて行った検証実験について述べる。

## 4.1 配線及び誤配線パターン

赤と黒の配線が平行に正しい場所に接続されているものを正配線とし, それ以外を誤配線とした。誤配線のパターンとして, 本研究では配線の接続先間違い, 端子外れ, 断線を対象とした。実験で用いた誤配線パターンの例を図2

に示す。



(a) 接続先間違い (b) 端子外れ (c) 断線

図 2: 誤配線の例

#### 4.2 多方向撮影の必要性検証

図 2 の端子外れの画像は、上方向からのみではなく横方向からも撮影した画像が検証に必要なだと予想した。

そこで、多方向撮影の必要性を検証するため、図 2 に示す上方向からのみ撮影した単体画像と図 3 に示す 2 方向からの画像を 1 枚にした複合画像を用いて学習させ、識別結果を比較した。この際、学習用画像と識別用画像を入れ替え 5 回交差検証を行った。なお、この検証では CG 画像のみを用いている。




図 3: 複合画像

それぞれの実験で用いた画像の内訳と結果を表 1,2 に示す。

表 1: 各実験の画像枚数

	学習用画像		識別用画像	
	単体画像	複合画像	単体画像	複合画像
実験 1	400	0	100	0
実験 2	0	400	0	100

表 2: 各実験結果の平均

	適合率
実験 1	100%
実験 2	100%

適合率とは判別対象のデータを判別した数のうちそれが正しく判別出来ている割合である。

配線検査という観点から間違った接続を正しいと識別しないことが重要であるため、適合率の値を評価の指標とする。単体画像のみでも識別することができたため、今回の実験条件では多方向からの撮影は不要であった。

#### 4.3 学習と検証

配線の正・誤画像を正しく識別できるか確認するために、実写画像と CG 画像をともに学習させ、その学習データで実写画像を識別させる検証を行った。

また、この学習データを用い実写画像を識別させた。使用した画像の内訳と、識別用画像と学習用画像を入れ替えて 10 回交差検証を行った結果を表 3,4 に示す。こちらの実験においても適合率を評価の指標とした。

表 3: 画像枚数

	学習用画像		識別用画像	
	実写画像	CG 画像	実写画像	CG 画像
正配線画像	1500	4000	100	0
誤配線画像	1500	4000	100	100

表 4: 実験結果

	適合率
10 回の平均	100%

#### 4.4 考察

今回行った 2 本の配線画像での検証では、CG 画像を含めた画像を用いた学習データで実写の画像を識別することができた。しかし、実際の配線検査ではより複雑な配線を用いたり、今回のような白一色の背景ではなかったりと環境に差異がある。より実環境に近い画像での検証が必要である。

### 5 おわりに

本研究では、学習用画像の作成の効率化と、実写画像と CG 画像を交えた学習データでの配線識別を行った。学習用画像の作成は CG 画像を用いたことによって作成時間を 1/24 削減に成功した。また作成した画像での交差検証では非常に高い精度の結果が得られた。さらに、誤配線の端子外れに関しては、上部から撮影した画像のみで十分だという結果が得られた。

今後の課題としては、実環境に近づけた画像での検証がある。

#### 参考文献

- [1] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." Communications of the ACM 60.6 (2017): 84-90.
- [2] 池田溪一郎, et al. "ディープラーニングを用いた手挿入部品検査の検討." 第 82 回全国大会講演論文集 2020.1 (2020): 73-74.
- [3] Gulli, Antonio, and Sujit Pal. Deep learning with Keras. Packt Publishing Ltd, 2017.