

電子部品におけるリードの検出

安田善樹[†] 服部公央亮[†] 鬼頭秀一郎[†] 田口亮[†] 保黒政大[‡] 梅崎太造[†]
 名古屋工業大学[†] 中部大学[‡]

1 はじめに

工業製品の生産において、品質管理を目的とした不良検査は必須である。電子回路基板の生産ではチップマウンタによる高速大量生産に対応するため、画像処理技術を用いた自動検査システムが用いられている^[1]。現在の検査システムは、事前に作成した電子部品の形状データと実装しようとしている電子部品を比較することで良否判定を行う。形状データは部品毎に必要なため、その作成には大きなコストがかかる。形状データの作成においても自動化が進められているが、リードの検出率が低いため、人手によるデータの 입력が避けられない。そこで本稿では、まず AdaBoost により画像中からリード候補の検出を行い、その後、ニューラルネットワークにより真のリードを分類する2段階の手法を提案する。

2 提案手法

2.1 AdaBoost を用いたリード候補の検出

2.1.1 AdaBoost

AdaBoost とは、他の多くの学習アルゴリズムを弱識別器として組み合わせて利用することで、そのパフォーマンスを改善することのできる機械学習アルゴリズムである。本手法では、図1のリード画像のように、コントラストが比較的大きくなる画像に対し効果的であると考え^[2]、弱識別器に Haar-Like 特徴を用いた。



図1 リード画像例

2.1.2 Haar-Like 特徴

Haar-Like 特徴とは、白と黒の矩形領域を組み合わせた特徴で、画像の特徴量は(1)式で計算される。ここで、 f は特徴量、 I_B は黒領域の画素値、 I_W は白領域の画素値、 S は矩形領域の面積である。

$$f = \sum I_B - \sum I_W \quad (1)$$

また、本手法で使用する Haar-Like パターンを図2に示す。

2.1.3 カスケード構造

本手法では、図3のように AdaBoost によって得られた強識別器を多段階構造にするカスケード




図2 使用する Haar-Like パターン




図3 カスケード構造




図4 学習データ例

構造を採用した。これにより、前段の強識別器で明らかにリードでない画像を可能な限り早く棄却することで、高速な検出が期待できる。

2.1.4 学習データ

学習データには、電子部品の画像から切り出したリード画像と背景画像を 18×18 [pixel] に正規化した画像を用いた。本手法で使用した学習データの一部を図4に示す。

2.2 ニューラルネットワークを用いたリードの分類

2.2.1 ニューラルネットワーク

ニューラルネットワークとは、脳機能の特性をコンピュータ上のシミュレーションにより表現することを目指した数学モデルである。ニューラルネットワークにおいて、教師あり学習と教師なし学習という2つの訓練手法が存在する。本稿では、教師信号の入力により問題に最適化されていく教師あり学習を使用する。多層ニューラルネットワークを訓練する際には、誤差逆伝播法を使用する。本稿では、図5のような入力層 18×18 、中間層 512、出力層 1 ユニット、シグモイド係数 3.0、6.0、9.0、12.0 の三階層型ニューラルネットワークを構築した。




図5 三階層型ニューラルネットワーク

Detecting Lead of Electronic Components
 Yoshiki Yasuda[†], Koosuke Hattori[†], Shuichiro Kito[†], Ryo Taguchi[†], Masahiro Hoguro[‡] and Taizo Umezaki[†]
 Nagoya Institute of Technology[†], Chubu University[‡]

2.2.2 学習データ

学習データには、2.1節の AdaBoost を用いて検出されたリード候補のうち、リードとゴミを用いた。本手法で使用した学習データを図 6 に示す。




図 6 学習データ例

3 評価実験と考察

3.1 AdaBoost を用いたリード候補の検出

2.1節の AdaBoost を用いて検出実験を実施した。検出実験に使用する画像は、リードを含む電子部品の画像 225 枚で、定義されているリード本数は 7284 本である。検出率は(2)式のように定義した。ここで、 R は検出率、 n はリードの先端検出数、 N は定義リードの本数である。

$$R = \frac{n}{N} \times 100 \quad (2)$$

図 7 および図 8 に実験結果を示す。図 7 では、全てのリードが正しく検出できていることが確認できる。図 8 より、99.3[%]と従来手法^[1]に比べ検出率が向上し、提案手法が有効であることが確認された。

ただし、図 7 の部品右下部において、ゴミをリードとして誤検出しているため、ニューラルネットワークを用いたリードの分類が必要である。




図 7 リード検出例




図 8 リード検出率

3.2 ニューラルネットワークを用いたリードの分類

2.2 節のニューラルネットワークを用いて学習実験を実施した。50[epoc]毎に得られた神経回路からクロスドデータの認識を行い、(3)式にて学習誤差 e を評価した。 O_{kj} は各画像における出力値、 T_{kj} は同画像における教師信号、 M は入力画像の画像枚数、 N は同一画像の学習回数である。図 9 に実験結果を示す。シグモイド係数 3.0 のとき最も収束しており、学習回数 4000[epoc]付近では全て収束している。

また、同じニューラルネットワークを用いて分類実験を実施した。分類実験に使用する画像

は、3.1 節において検出されたオープンデータであるリード 160 枚、ゴミ 126 枚の全 286 枚である。ニューラルネットワークは、学習回数 4000[epoc]のものを使用する。図 10 に分類結果を示す。図 10 より、リード候補から真のリードを検出できていること、かつゴミの分類ができていることが分かる。シグモイド係数 12.0 のとき最大 93.7[%]の正解率を示し、ニューラルネットワークによる分類が有効であることを確認した。

$$e = \frac{1}{MN} \sum_{k=1}^N \sum_{j=1}^M (O_{kj} - T_{kj})^2 \quad (3)$$




図 9 学習誤差曲線




図 10 分類実験の正解率

4 まとめ

本稿では、AdaBoost を用いた電子部品におけるリード候補の検出手法と、そのリード候補からニューラルネットワークを用いて真のリードを分類する手法を提案した。本手法により、定義されたリードの 99.3[%]を候補として検出することができた。また、検出されたリード候補を 93.7[%]分類できることを示した。しかしながら、ゴミの正解率は 85.7[%]と低い。これは、AdaBoost により検出されたゴミとリードに、違いが生まれにくいためであると考えられる。今後は、より多様な学習を行うことにより、検出率および分類率を向上させたい。

参考文献

- [1] 江寄弘健, "電子部品の階層型自動分類システムの開発", 電学論(C), Vol.26, No.12, pp.1447-1453, (2006).
- [2] P. Viola and M. Jones, "Robust real-time face detection", IJCV, Vol. 57, pp/ 137-154(2004).