

導線の被覆剥ぎ及びピン圧着の良否判定システム

村瀬智光[†] 川井将人[†] 服部公央亮[†] 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

近年、計算機、自動車、航空機などの電子化に伴い、電子機器を接続する導線の高密度化が進んでいる。導線及びその接続工程における不良はシステムに致命的な欠陥をもたらすため、検査が重要となる。しかし、従来の導線検査は目視検査が主流であり、定量的評価が困難であるという問題がある。本研究では良否判定を画像処理技術により自動化することで、導線接続工程の効率化及び導線の高品質化を目指す。

2 実験装置作成

本稿では、一般的に高密度配線に利用される導線(図 1)を用いる。この導線には中央部分にピンホールと呼ばれる穴(図 2)が存在し、ピンホール内部に素線状態で不良判定が可能である。



図 1 導線



図 2 ピンホール

ピンホール周辺は、金属面より照明の影響を受けやすい。照明を一定に保つために、実験装置(図 3 図 4)を作成した。撮影画像を図 5 に示す。




図 3 装置




図 4 略図



図 5 撮影画像

撮影された導線被覆部分は曲がりやいため、導線位置は一定でない。さらに、導線が回転するため、ピンホールの位置も一定ではないという問題点がある。

3 システム処理内容

3.1 最小二乗法を用いた導線画像の回転補正

3.1.1 最小二乗法

最小二乗法とは、単回帰分析に用いられる最も一般的な手法で、計測データなどの整理に利用することができる。

N個の座標データ $(x_i, y_i) (i = 1 \dots n)$ が与えられ

ている。各点より尤度の高い直線を $y_i = \hat{a}x_i + \hat{b}$ とすると \hat{a} と \hat{b} は式(1), (2)で求まる。

$$\hat{a} = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \quad (1)$$

$$\hat{b} = \frac{\sum_{i=1}^n x_i^2 \sum_{i=1}^n y_i - \sum_{i=1}^n x_i y_i \sum_{i=1}^n x_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \quad (2)$$

3.1.2 画像の回転補正

フローチャートを以下に示す。





図 6 処理の画像

3.2 SobelFilter を用いたピンホール画像の切り出し

3.2.1 SobelFilter

SobelFilter とは空間フィルタリングの手法であり、空間 1 次微分を計算し、輪廓を検出するフィルタである。

本稿では、図 4 より導線の下から光を当てている。そのため、下から上への SobelFilter の計算結果を使用する。

3.2.2 切り出し

フローチャートを以下に示す。





図 7 切り出し処理の流れ

A quality judgment system of removing wire jackets and crimping conductors
Tomomitsu Murase[†], Masato Kawai[†], Koosuke Hattori[†], Ryo Taguchi[†], Masahiro Hoguro^{††} and Taizo Umezaki[†]
Nagoya Institute of Technology[†], Chubu University^{††}

3.3 ニューラルネットワークを用いた良否判定

3.3.1 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。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^[1]を使用する。本稿では、入力層 6, 中間層 128, 出力層 1 ユニット, シグモイド係数 3.0, 6.0, 9.0, 12.0 の三層型ニューラルネットワークを構築した。

3.3.2 良否判定

良否判定は(A)良品, (B)不良 1 (素線が半分), (C)不良 2 (素線なし)を判定する。次に例を示す。




図 8 良品・不良品の例

素線部分と穴・金属部分を分類できれば良否判定は可能である。双方の視覚的違いは、縞パターンの有無である。そこで、輝度値の波形を高速フーリエ変換が 2 の倍数でなければならないことと、ピンホール幅が最大で 60 画素であることから 64 画素分の輝度値の波形を取得し、フーリエ変換する。得られたパワースペクトルの一部を切り出し、ニューラルネットワークに入力するための特徴量(6 次元)とする。特徴抽出の流れを図 9 に示す。

学習データは、画像から切り出した輝度値波形データを合計 128 個を使用した。内訳は素線部分 77 個、穴部分 51 個、金属部分 25 個である。

	素線	穴	金属
画像			
輝度値			
周波数			
抽出			

図 9 学習・認識データ抽出の流れ

4 評価実験と考察

3.3 節のニューラルネットワークの用いて学習実験を実施した。100[epoch]毎に得られた神経回路から上記のように得たクロズドデータの認識を行い、学習誤差 e を評価した。図 10 に実験結果を示す。シグモイド係数 6.0 学習回数 4800[epoch]付近でのとき最も収束している。




図 10 評価実験結果

また、同じニューラルネットワークを用いて良否判定を行うための導線認識実験を行った。実験に使用するデータは、学習に使用していない切り出し画像から、64 画素分の輝度値波形を順々に取得していく。それぞれの波形を素線部分か否かを判定し結果を画像に出力する。ニューラルネットワークの重みは、学習回数 4800[epoch]のものを使用する。図 11 に結果画像を示す。赤い部分ほど素線と認識している。




図 11 良否判定結果

図 11 より素線部分に強く反応が出ており、ニューラルネットワークの良否判定が有効であることが確認できた。今後、サンプル数を増やし、認識精度の評価を行う。

5 まとめ

本稿では、導線の良否判定を行った。導線の画像データから輝度値を波形データに変換し、フーリエ変換をおこなって特徴を抽出した。その特徴を使ってニューラルネットワークで良否判定を実装した。今後はサンプル数を増やし、認識精度の評価と精度向上を目指す。

6 謝辞

本研究は、経済産業省の戦略的基盤技術高度化支援事業「高密度配線組立の低コスト器材・装置類の開発」の委託研究(公益財団法人科学技術交流財団, 東洋航空電子株式会社, 株式会社アイキューブテクノロジー, 名古屋工業大学)である。

参考文献

[1]奥田忠義, 道木慎二, 石田宗秋, "ΔΣ変調に基づくパルスニューラルネットワークによる BP 学習", 信学論 (2004).