

プリント板外観検査への機械学習応用

塩入 健 Ken Shioiri, 浜尾昇治 Shoji Hamao

[要 旨]

プリント板への部品搭載工程におけるはんだ付け等の外観検査は、接合部分の信頼性を保証するうえで重要な検査の一つである。検査方法としては目視検査が基本であるが、目視検査は手軽に実施できる一方で、経験豊かな人材を確保することが難しく、一人前になるまでの教育など手間がかかるという問題がある。また少子・高齢化が進んでいる日本では、経験豊富なベテラン検査員が減少し若手も育たないという状況に陥っている。外観検査においては、以前から撮像装置と画像処理を組み合わせた自動化が行われているが、誤検出が多く結局人間が最終確認している場合が多い。近年の機械学習^{1), 2)}などの画像処理技術の進化^{3), 4)}に伴い、検査性能の改善が期待されている。本稿では機械学習技術を活用した外観検査の自動化への取り組みについて紹介する。

1 はじめに

製造過程における製品の目視検査は、人による目視検査と画像処理による自動検査がある。目視による検査は、人間の感覚で合否判定を行うので、ヒューマンエラーが発生しやすく検査員によって不良品の判定基準にばらつきが発生する。また、検査台の照明等の環境によって検査結果に影響を与えたり、精神的・身体的疲れによって作業精度・スピードに差が生じたりすることもある。また昨今では、部品の小型化・集積化が進み、求められる品質も高くなっている。さらに多種多様な顧客ニーズへの対応から多品種少量生産が増え、顧客ニーズの変化の速さから製品のライフサイクルは短くなっている。そのため品質管理への負担は増大している。


そこで注目されているのが、カメラを用いた外観検査の自動化である。カメラを活用して検査工程を自動化すれば、ヒューマンエラーの発生、判定基準のばらつき、人員確保、教育などの手間、人件費などの問題が解決可能である。さらに自動化によってインラインでの高速検査も可能になり、品質を保証しながら生産効率も高めることができる。

検査の自動化には、人が判定基準を決める方法と、機械学習により判定基準を決める方法がある。前者の方法では、部品の種類が多くなると、判断基準が増え、しかも複雑になる。また判断基準の管理や修正も難しくなる。機械学習による方法は、十分なサンプル画像枚数と正しいラベル情報(画像が良品であるか不良品であるか、画像中の不良位置などの答え)があれば高い判定性能が期待できる。画像による外観検査は、機械学習技術の発展などにより近年注目が高まっており、生産現場で実際に問題となっている画像に対して、検査アルゴリズムを開発するケースが増えてきている。

本稿では、2 章で「プリント板製造工程概要」を、3 章で「代表的な不良」を、4 章で「AOI プリント板外観検査における課題」を、5 章で「機械学習によるプリント板外観検査」を、6 章で「機械学習によるプリント板外観検査の評価結果」を説明する。

2 プリント板製造工程概要

一般的な表面実装プリント板の製造工程では、プリント板に塗布した溶剤ペースト^{注1}を溶融するリフロー溶ダリング方式が用いられる。リフロー溶ダリング方式では、図 1 に示すように溶剤ペーストをメタルマスク^{注2}開口部を通してプリント板面に転写する「溶



ダペースト印刷」, 部品落下を防ぐための「接着材塗布」, プリント板面に部品を配置する「部品搭載」, その後溶ダペーストを溶融して部品をプリント板に接合する「リフロー」処理が一連の流れとして自動化されている。表面実装プリント板製造にかかわるこれらの技術を一般に SMT(Surface Mount Technology)と呼んでいる。リフロー炉から排出されたプリント板において, 部品が正しく実装され, かつはんだの付き具合に問題がないかを外観でチェックするのが「外観検査」である。外観検査は, 人間が肉眼または顕微鏡などを使って行う場合と, 光学画像を用いた自動検査機 AOI (Automated Optical Inspection)によって行う場合がある。

AOI による検査は, プリント板を定位置からカメラで撮影し, 画像診断により各部品のはんだ付け状態, さらには部品の有無や, 部品の向き, 部品の種類(印刷文字の認識)などを検査し, 良品か不良品かを判定する。不良品の場合は, どのプリント板のどの部品でどのようなエラーが発生したかのレポートが出力され, 最終的に人間が目視検査によって実際に不良かどうかを判断する。

AOI では定位置からカメラで撮影するため, リードや電極が見えにくい位置にあったり, 見えにくい部品形状である場合には, はんだ付け状態を正しく確認することができない。そのため AOI で検査できない部品は人間の目視検査に頼らざるを得ない。

近年, 搭載部品として 1.0×0.5 mm や 0.6×0.3 mm のチップ部品が多用されるなど, 部品の微細化および高密度化が進み, AOI 判定の正確さや処理速度の向上がより一層求められるようになっている。

注 1: ソルダペースト: 粒径 20~30 μm 程度のはんだ粉末をフラックスと混ぜ込んで適度な粘性を持たせたもの。クリームはんだとも呼ばれている。

注 2: メタルマスク: ソルダペースト印刷時にプリント板に重ねて使用するステンレス板で, プリント板の必要箇所に必要量のソルダペーストを塗布できるように開口部が設けられている。




図 2 正常なフィレット形成の例

3 代表的なはんだ不良

部品が正常に接合された場合, 部品のリードや電極とプリント板のランド^{注 3}にはんだが浸み渡るように広がり, はんだ接合部の外観が凹状に湾曲した状態になる。これをフィレットと呼ぶ。また, はんだが接合部の表面に浸み渡るように広がることを「ぬれ」と呼ぶ。正常に部品が接合されてフィレットが形成された例を図 2 に示す。

印刷されたソルダペーストの量や位置, 搭載された部品の位置, リフロー時の温度管理に問題がある場合, フィレットが形成されず部品が正しく接合されない状態となる。SMT でよく起こる不良の種類とその発生原因については資料⁵⁾に詳しく紹介されている。その中でも代表的な例を以下に示す。

(1) 「ぬれ」不良

部品のリードや電極において所定量のはんだが「ぬれ」ず, フィレットが形成されていない現象を「ぬれ」不良という。原因は, はんだ不足, リードや電極の浮き, 加熱不足などである。

(2) ブリッジ(ショート)

0.5 mm, 0.4 mm といった微細ピッチの SOP, QFP^{注 4}, またはコネクタで, 隣接するリードがはんだでつながってしまう現象である。ソルダペースト印刷の不良, リードの曲がり, 不適切な搭載が原因となっている。

(3) チップ立ち(ツームストン, マンハッタン)

チップ部品の両端電極のはんだ溶融が同時に起こらず, 先に「ぬれ」たはんだの表面張力により片側の電極で部品が立ち上がってしまう現象である。

ランドの寸法や搭載精度の改善, 溶融時間差を小さくするために予備加熱温度を上げるといった対策が取られる。

(4) 未溶融, 未ソルダ

リフロー炉を通したにもかかわらず, ソルダペーストの状態が残ってしまうことを未溶融という。ソルダペーストの劣化やリフロー炉の温度制御が原因となる。

未溶ダは部分的にはんだがない状態で、溶ダペースト印刷条件に起因するものである。

(5) 部品の回転と平行ずれ

部品の回転と平行ずれは、部品の位置がずれて部品のリードや電極が正規のランドからはみ出するか、載っていない状態である。部品搭載時のずれ、あるいは他の部品搭載時の振動や搬送時の振動で部品の位置がずれてしまう場合と、チップ立ちと同様にはんだ溶融時の表面張力による場合とが考えられる。

図 3 に典型的な不良の例を示す。




図 3 SMT で発生する不良の例

注 3: ランド: プリント板面で、部品のリードや電極とはんだ融着させるために銅箔が露出している部分。表面は金などでメッキ処理されている場合もある。

注 4: SOP, QFP: IC 部品パッケージ形状の 1 つ。SOP (Small Outline Package) は L 字型のリードが四角形パッケージの 2 面からつき出ており、QFP (Quad Flat Package) はパッケージの 4 辺から複数のリードがつき出ている。

4 AOI プリント板外観検査における課題

AOI を用いた検査では、複数のパラメータからなる厳しめの判断基準を設定し、不良品を流出させないように運用している。その結果、「見過ぎ」が問題となることが多い。「見過ぎ」とは、目視レベルでは合格品なのに、検査装置が不良と判定する事象を示す。「見過ぎ」が多くなると、自動検査後の目視による確認作業が増加してしまう。

「見過ぎ」を極力抑えるために、部品のはんだ付け状態などを数値化した判断基準値の再調整を繰り返すが、基板の状態や実装部品のバラツキといった実装工程における実装条件が刻々と変化しているため調整しきれず、見過ぎが減らないという課題がある。

5 機械学習によるプリント板外観検査

AOI 検査後の目視確認作業に機械学習を適用することで、「見過ぎ」検査の効率化に取り組んだ。

5.1 教師画像データ取得

機械学習を適用するにあたり、機械学習に使用する画像の収集・アノテーション(ラベル付け)が重要になる。そのため、AOI で撮影した検査画像データを教師画像として取得するシステムを構築した(図 4)。

AOI の検査結果や検査画像データを取得するためには、一般には専用の端末が必要である。今回は、AOI メーカーに端末のインターフェース仕様を開示してもらい、検査結果や教師画像(検査画像)データを直接 PC(Personal Computer)に取り込めるソフトウェアを開発した。このソフトウェアは 1 台の AOI 端末としてふるまう(図 4, 教師用画像取得 PC)。




図 4 画像取得のためのシステム構成

AOI 関連装置は、セキュリティ上の観点および工場外部のネットワークトラブルが工場の生産に影響を及ぼさないように、閉ざされた局所 LAN (AOI 専用 LAN: Local Area Network) で構成した。

AOI 専用 LAN の独立性を保つため、別の独立系 LAN (図 4, c. 独立 LAN) とマルチポート NAS (Network Attached Storage) (図 4, ②) とを介して、社内 LAN 上に構築した機械学習環境 (図 4, ③④) と接続するようにした。

必要な情報は NAS 上のファイルを介して共有するようにし、教師用画像取得 PC は一定間隔で AOI-DB サーバーに蓄積された画像および判定情報を機械学習 PC に送るようにプログラムした。

一般に機械学習では、不良品の画像だけでなく良品の画像も必要である。しかし、AOI-DB サーバーのディスク容量の制約から AOI-DB サーバーには良品と判定された部品の画像データを保存していないという問題があった。そのため、不良と判定された部品の画像であっても、問題箇所となっている電極やリードは部品全体の一部であることに着目し、不良部品画像の中から良品の電極や、リードのフレットを映した部分画像を得て機械学習を行うようにした。

外観検査に機械判定を導入する場合は、機械学習 PC から得られた学習モデルを機械判定 PC に移し、被判定画像の判定結果を教師用画像取得 PC が AOI 端末に入力された目視判定結果として、AOI-DB サーバーに登録する。目視判定の担当者は、AOI が NG 判定した画像でも、機械判定が良品と判定すれば、すでに目視判定が済んでいるとして扱うようにする。

人間による目視検査は、AOI 判定結果が不良で機械判定も不良のものだけについて行うため、機械判定導入により人間の目視判定作業の削減が期待される。

5.2 機械学習識別器

機械学習は、コンピュータに学習させて人間と同じような認識・判断を行わせる方法であり、以下の「学習処理」と「判定処理」の 2 つの手順で行われる^{1), 2), 3)}。

(1) 学習処理

優れた機械学習のアルゴリズムを考案しても、学習させなければ役に立たない。最初に学習データを使って学習が必要である。学習を繰り返し、精度 (学習誤差) が目標精度に達したら、学習済モデルが完成する。

(2) 判定処理

学習済の識別器 (学習済モデル) は、入力される画像データの正常・不良を判定する。例えば、物体の画像をラベル (物体の名前) 付きで学習させた識別器は、学習では使用していない未知の画像に対しても物体の名前を正しく判定することができる。

(3) 識別手順

機械学習識別器として、画像認識の分野で優れた性能を発揮している畳み込みニューラルネットを使用した。畳み込みニューラルネットは何段もの深い層をもつニューラルネットワークで、「畳み込み層」、「プーリング層」などのいくつかの特徴的な機能をもった層を積み上げることで構成されている。今回使用した畳み込みニューラルネットは、高さ×幅が、 3×3 および 3×1 の係数を持つ畳み込み層を 10 層重ねて構築している。

識別の手順を図 5 に示す。まず前処理にて検査対象画像を読み込み、はんだ箇所を切り出す。識別器は切り出したはんだ箇所について、識別結果を 0.0~1.0 の範囲の数値で出力する。この数値は、はんだ箇所の正常品らしさを示し、1.0 が正常品らしさの最大値である。正常品らしさを閾値判定することで、はんだ箇所が正常か不良かを判定する。

本検討では図 6 に示すように複数の識別器を用意し、各識別器の出力を平均化するモデル平均により評価を行った。学習パラメータの初期値を変えて複数の識別器を組み合わせることで、単一の識別器を独立に利用するよりは、ばらつきを抑えるなどの性能の改善が期待できる^{1), 2)}。




図 5 機械学習による識別手順




図6 モデル平均




図7 正常品らしさの分布を示す図

6 機械学習によるプリント板外観検査の評価結果

6.1 検出性能

本稿で提案したアルゴリズムをあらかじめ特定した部品の560枚の検査画像（良品60枚、不良品500枚）に対して適用し、モデル平均手法を用いて性能を評価した。評価に使用した画像は、学習には使用していない画像である。

結果を表1に示す。学習モデルとして8種類用意した。表1に示すように学習モデルごとに検出性能がばらつくため、モデル平均を行い特異な判定をしないようにすることで、ばらつきを抑えた。

図7に、正常品らしさの分布を確認するための累積分布を示す。赤線は不良箇所（493箇所）の正常品らしさの累積分布、青線は正常箇所（65168箇所）の正常品らしさの累積分布を示す。不良箇所の累積分布は1.0を始点として分布しているが、本来0.5未満を開始値として下半分に分布するのが望ましい。また正常箇所の累積分布は0.0を始点として分布しているが、本来0.5以上を開始値として上半分に分布するのが望ましい。不良箇所・正常箇所の累積分布が途中で交差しているため、正常品らしさで閾値判定した場合、誤判定が生じる。

図8にモデル平均と単一モデルの正常品らしさとの比較を示す。モデル平均を行うことで、モデル平均なしに比べて正常箇所の値は増加、不良箇所の値は低下しているため、正常品らしさは改善している。しかし、分布は途中で交差しているため、閾値判定した場合、誤判定が発生する。




図8 モデル平均と単一モデルの正常品らしさ比較

表1 検出性能

学習モデル	不良画像 500 枚					正常画像 60 枚	
	不良箇所数	検出箇所数	未検出箇所数 (見落とし)	検出率	誤検出箇所数	誤検出箇所数 (見過ぎ)	誤検出箇所数 削減率
1	545	495	50	0.91	28	0	0.00
2	545	504	41	0.92	25	0	0.00
3	545	478	67	0.88	11	0	0.00
4	545	497	48	0.91	17	3	0.04
5	545	496	49	0.91	20	0	0.00
6	545	495	50	0.91	10	4	0.06
7	545	489	56	0.90	21	0	0.00
8	545	501	44	0.92	26	3	0.04
モデル平均	545	495	50	0.91	12	0	0.00

6.2 誤判定画像の分析

誤検出の現象を確認するため、実際の画像を確認した。図 9～11 に機械学習による不良検出結果の例を示す。AOI が不良と判断した箇所に対しては、現場の専門家が目視等で判定を行い、機械学習の結果と比較した。図中 AOI が正常と判断した箇所を青枠、AOI が不良と判断し検査員が正常と判断した箇所をオレンジ、AOI が不良と判断し検査員が不良と判断した箇所をピンク色の枠で示す。図 10, 11 に示してある数値は、機械学習が出力する“正常品らしさ”を示す。図 10 中オレンジ色で示した枠は、AOI は不良と判断したが、検査員が正常と判断した箇所である。オレンジ色の枠に対し機械学習の結果は、高い数値を示していることがわかる。また図 11 中ピンク色で示した枠は、AOI が不良と判断し、かつ検査員が不良と判断した箇所である。不良品(ピンクの枠)に対し機械学習の結果は、低い数値を示していることがわかる。機械学習の出力である正常品らしさは、専門家である人間の判定結果に近い値を出力している。

枠の色	AOI の判定	目視判定
	正常	—
	不良	正常
	不良	不良

図 9 分類方法




図 10 正解(見過ぎ検出)の例




図 11 正解(不良箇所検出)の例

図 12 は、機械学習の判定の結果、誤検出(不良箇所だが、機械学習が正常と判断した例)となった画像の例である。不良品(ピンクの枠)の画像に対し、機械学習の結果(正常品らしさ)は高い数値を示している。画像を見る限り色の分布は左右の正常箇所と違いは見受けられず、画像だけでは不良を検出することは困難である。

検査員は他の情報を加味して総合的に判断していると思われる。




図 12 誤検出(見逃し)の例

機械学習手法を適用した場合、調整が必要なパラメータは正常品らしさのみであり、現場での調整の手間の削減も期待できる。しかし、誤判定(見逃し)をゼロにすることはできなかった。正解画像と誤判定画像での畳み込みニューラルネットの各層の出力分布の違いや、学習過程での挙動の分析を行い学習モデルをチューニングすることが必要と思われる。

7 まとめ

本稿では機械学習を用いたプリント板外観検査自動化への取り組みを紹介した。多種多様な部品の中から数種類の部品に絞り込み、機械学習を用いてはんだ箇所の不良検出を試みた。今後は、誤判定画像の分析を進め、学習モデルのチューニングに取り組む予定である。

参考文献

- 1) トレヴァ・J. ヘースティ著, 杉山, 他訳: 統計的学習の基礎, 共立出版(2015)
- 2) C.M.ピショップ著, 元田, 他訳: パターン認識と機械学習(上・下), 丸善出版(2015)
- 3) 岡谷貴之: 画像認識のための深層学習の研究動向, 人工知能, Vol.31, No.2, pp.169-179(2016)
- 4) 岡谷貴之: 深層学習について, 日本ロボット学会誌, Vol.33, No.2, pp.92-96(2015)
- 5) 社団法人 日本溶接協会 マイクロ溶ダリング教育委員会[編]: 標準マイクロ溶ダリング技術, 第3版, 日刊工業新聞社(2012)

執筆者



塩入 健
技術本部
先進技術開発センター



浜尾 昇治
東北アンリツ

公知