

AI を用いた実装基板の検査技術に関する研究

(第 34 報)

中部エレクトロニクス振興会
名古屋市工業研究所

令和 5 年 9 月

目 次

	項
－ 1 はじめに －	1
－ 2 AI について －	
2. 1 AI の概要	3
2. 2 ディープラーニング	4
2. 3 Convolutional Neural Network	8
2. 4 AI の学習と評価	10
2. 5 分類問題と回帰問題	13
2. 6 性能向上のための技術紹介	14
2. 7 2章のまとめ	15
－ 3 検査対象、データセット、AI 評価 －	
3. 1 検査対象と検査項目	16
3. 2 データセット（試料作製）	16
3. 3 データセット（ラベル付け）	20
3. 4 AI の評価方法	25
3. 5 3章のまとめ	30
－ 4 AI の性能確認 －	
4. 1 部品サイズとパッド形状による分類	31
4. 2 AI によるチップ部品の位置ずれ検査	33
4. 3 4章のまとめ	36
－ 5 AI の柔軟性評価① 照明条件 －	
5. 1 照明条件について	37
5. 2 AI 評価（照明条件）	39
5. 3 転移学習と誤判定の考察	44
5. 4 照明条件の小さな変化に関して	46
5. 5 5章のまとめ	47
－ 6 AI の柔軟性評価② 検査対象 －	
6. 1 チップ部品のサイズについて	48
6. 2 AI 評価（チップ部品サイズ）	49
6. 3 誤判定の考察と AI 判定の改善に向けて	54
6. 4 6章のまとめ	57
－ 7 まとめ －	58
参考文献	61

－ 1 はじめに －

近年、AI (Artificial Intelligence) は大きな広がりを見せている。AI は、判定基準が「ブラックボックス」であるため意図しない判定を行う可能性があるにも関わらず、様々な分野で注目を集め、必要不可欠な技術となってきた。このような AI を効果的に活用するためには、AI の長所や短所を正しく把握する必要がある。そこで、中部エレクトロニクス振興会 第4分科会では、AI の性質を調べるため、チップコンデンサの AI による位置ずれ検査を例に取り上げて検討を行った。本報告書では、2018～2022 年度に本分科会で取り組んだ内容を紹介する。

電子分野では、量産品においてプリント基板検査の自動化が進んでいる。プリント基板上の部品点数は多く、部品の実装状態やはんだの不良など検査すべき項目も多岐に渡るが、人による検査には限界があるため、今日の自動検査システムは重要な役割を担っている。しかし、次のような問題も挙げられる。

①過検出

一般に、不良品を流出させないように判定基準は厳しく設定されるため、良品でも一部は不良品として過検出 (誤判定) されることがある¹⁾。不良品として検出された基板は人による目視検査が行われ、目視検査で問題が無い場合は良品として扱う。しかし、高性能・多機能な基板ほど部品点数は多くなり、過検出の数も増えることから目視検査が大きな手間となる。

②検査システム導入のハードル

検査対象にあわせたシステムの構築が必要であり、位置精度など精密なシステムが必要となるため、多品種少量生産では導入のハードルが高い。また、検査システムの専門家による試運転に日数を要したり、稼働後も継続的に、経時変化などによる判定基準の微調整を必要としたりと手間がかかる場合がある。

検査システムに AI を応用できれば、次のような効果が期待できる。

①について

ディープラーニングと呼ばれる AI の技術では、データからの自動的な学習により、多くのパラメータを用いた複雑な判定基準を実現できるため、ルールベース型の従来技術とは、一般に異なる判定基準となる。このため、従来技術との併用でダブルチェックの役割を担い、過検出を低減できる可能性がある。なお、AI で全ての検査を自動化できることが理想であるが、現状では、寸法計測など比較的単純なしきい値で判定基準を制御できる場合は従来技術が向いており、単純なしきい値での線引きが難しい変色などの検査には AI が向いていると考えられる。

②について

AI では、位置精度などが比較的ラフな撮影環境でも検査システムを実現できるため、部品配置が異なる基板の検査に同じ AI を流用できる可能性がある。特殊な調整無しで、様々な撮影環境や検査対象に対応できるシステムが実現できれば、多品種少量生産における導入のハードルを下げることを期待できる。

本分科会における興味の対象は、AI の性能と問題点であり、①については、一般的な検査項目における AI の性能に、②については、撮影環境や検査対象の変化に対する AI の柔軟性に注目した。

なお、本報告書では AI 技術に「ディープラーニング」を取り上げた。また、AI の評価にはソニーグループが提供する「Neural Network Console²⁾」を用いた。「Neural Network Console」では、高度なプログラミング言語を使わずに、マウスなどの操作で AI を実現することができる。

2 章以降の概要は次の通りである。本報告書が AI の性質を理解するための一助になれば幸いである。

2 章 AI について

本報告書に関連する、AI の基本的な用語や技術を紹介する。

3 章 検査対象、データセット、AI 評価

本報告書では、チップコンデンサの位置ずれ検査を対象として、基本的な AI の性能確認と、照明条件やチップ部品サイズの変化に対する AI の柔軟性を検討した。検討に用いたチップ部品画像の作成方法や人による良品・不良品などのラベル付け、検討に用いた AI について述べる。

4 章 AI の性能確認

基本的な AI の性能を確認した。3 章で述べる、人のラベル付け作業が難航し、ラベルの誤りが AI の性能低下につながる可能性が懸念されたため、本章の前半では、人のラベル付け精度に依存しない、部品サイズなどでの分類事例を取り上げ、後半では、本報告書の本題となる位置ずれ検査を取り上げた。

5 章 AI の柔軟性評価① 照明条件

外観検査において照明条件は重要であり、照明条件次第で検査精度が大きく変化する可能性がある。ここでは AI の柔軟性評価として、3 通りの照明条件を取り上げ、照明条件が AI の性能に与える影響を検討した。

6 章 AI の柔軟性評価② 検査対象

AI では、人と同じように検査対象の変化に柔軟に対応できる可能性がある。5 章に続き AI の柔軟性評価として、ここでは部品サイズの変化が AI の性能に与える影響を検討した。

7 章 まとめ

最後に、本報告書のまとめを述べる。

－ 2 AI について －

本章では、本報告書に関連する、AI の基本的な用語や技術を紹介する。

2. 1 AI の概要

AI : Artificial Intelligence (人工知能)

AI の厳密な定義は定まっていないが、本報告書においては、人と同じような知能を人工的に実現する技術として AI を扱う。近年の AI ブームは「第 3 次 AI ブーム」といわれ、ディープラーニングと呼ばれる技術が登場したことで、コンピュータではこれまで困難であった内容の一部が実現できるようになった。

第 1 次 AI ブーム

1960 年代頃で、コンピュータによる「推論」や「探索」が可能となったが、明確なルールが存在するパズルや迷路など簡単なゲームでは有効でも、現実の問題への応用には不十分であった。

第 2 次 AI ブーム

1980 年代で、エキスパートシステムが作られた。これは、コンピュータに「知識」を与え、高度な知識を有する専門家のように受け答えできるシステムであるが、知識や受け答えは全て、あらかじめ人が組み込む必要があり限界があった。なお、エキスパートシステムは今もチャットボットなどに用いられている。

第 3 次 AI ブーム

今日では、高性能なコンピュータや膨大なデータ群である「ビッグデータ」が登場し、また、「機械学習」と呼ばれる、コンピュータが学習する技術も登場した。ディープラーニングは機械学習の技術の 1 つであり、従来の機械学習では、データに潜むパターンやルールのヒント（「特徴量」）を人が示す必要があるのに対し、ディープラーニングでは、人が特徴量を教えなくても自動で学習できる。このような技術が、近年の「第 3 次 AI ブーム」につながり、自動運転や顔認識、音声処理、翻訳精度の向上など、広い分野で AI が必要不可欠となった。

近年の AI は、画像認識の分野などで人の能力を超える事例も報告されている³⁾。このことは、人を雇うよりも AI を使う方が高い性能を得られる可能性を示唆するため、大きな変化点である。

2. 2 ディープラーニング

AI は、書籍^{4,5)}や WEB などに様々な技術情報がある。ここでは本報告書に関連する内容を述べる。

ニューラルネットワークとディープラーニング

様々な AI の中の 1 つの技術である「ディープラーニング」(深層学習)は、比較的簡単な処理を何度も繰り返すことで画像分類などを行い、処理の内容や回数、順序、分岐などで性能が変化する。脳の神経細胞のネットワーク構造を模して、処理の流れをネットワーク状に表現した「ニューラルネットワーク」と呼ばれる数理モデルを発展させたものが、ディープラーニングである。

ネットワークを構成する処理 (人工ニューロン、全結合、活性化関数)

ネットワークを構成する処理の 1 つに、神経細胞をモデルとした「人工ニューロン」がある。図 2-1 は人工ニューロンのモデルである。入力データ ($x_1 \sim x_m$) に、それぞれの重み ($w_{k1} \sim w_{km}$) を掛けて足した v_k (バイアス値 b_k を含める場合あり) に対し、「活性化関数」と呼ばれる非線形処理 (ϕ_k) を行う。活性化関数は複数提案されており、基本となる「Sigmoid」の他、「ReLU」(Rectified Linear Unit) などがある (図 2-2)。実際のネットワークでは、図 2-3 のように複数の人工ニューロンを並列につなげて用いる。図 2-3 において、点線枠で示す処理を「全結合」と呼ぶ。この処理は行列の内積に相当するため、以下では「Affine」と記載する。なお、「Affine」は「FC」(Fully Connected) や「Dense」と呼ばれることもある。

AI の動作イメージ

図 2-3 を用いて、AI の動作を説明する。ここでは例として、【猫】、【自動車】、【リンゴ】のいずれかを想定した 2×3 画素の画像入力に対して、図 2-3 の処理で分類することを考える。図中、入力データの $x_1 \sim x_6$ は、1 画素ごとの値に対応する。また、重み ($w_{11} \sim w_{36}$) はそれぞれ特定の値である。入力データが定まれば、図 2-1 中の計算で出力値 ($y_1 \sim y_3$) を計算できる。ここで、 y_1 は【猫】、 y_2 は【自動車】、 y_3 は【リンゴ】の画像である可能性として考えると、AI は最も大きい出力値に対応する画像として分類 (判定) する。ここで、入力画像は同じでも、重み ($w_{11} \sim w_{36}$) が異なれば出力値は変化するが、重みは AI の学習で調整される。

AI の様々なネットワーク①

1 つの「Affine」で 1 つの層と表現する。図 2-4 のように層が複数ある場合、AI は最終層の出力値で判定を行う。複数の層をつなげることで、より複雑な入出力の関係を実現できる。ディープラーニングは、多層化したニューラルネットワークである。層数 (深さ) 以外にも、処理内容や層のつなぎ方で AI の性能は変化する。画像認識では、「Convolutional Neural Network^{6~9)}」(畳み込みニューラルネットワーク、CNN) と呼ばれる「畳み込み」(以下、「Convolution」と記載) の処理を用いた構造において、時系列データを扱う音声処理などでは、「Recurrent Neural Network¹⁰⁾」(回帰型ニューラルネットワーク、RNN) と呼ばれる循環を持つ構造において優れた性能が報告されている。

