電子部品検査における欠陥検査感度制御のための Deep Convolutional Auto-encoder を用いた学習画像生成の検討*

柳部正樹** 大井健太郎** 田中智裕** 西村晃紀** 前田俊二***

Study on Learning Image Generation Using Deep Convolutional Auto-encoder for Defect Inspection Sensitivity Control in Electronic Component Inspection

Masaki YANABE, Kentarou OOI, Tomohiro TANAKA, Koki NISHIMURA and Shunji MAEDA

In the manufacture of precision electronic components, defects are detected using automatic inspection machines. When high inspection sensitivity is employed, the group of potentially defective candidates identified by the inspection machine can include many acceptable units; this can ultimately lead to an excessive number of incorrect defect detections. This study aims to develop an effective method for classifying images of defect candidates into defect images and good images. Herein, the inspection method of electronic components with various defective images generated from the true defect images is proposed.

Key words: electronic component, image generation, deep convolutional auto-encoder, support vector machine

1. 緒 言

精密な電子部品を製造する際、電子部品における欠陥の有無が自動検査装置により判定されている。しかし、検査の高感度化の要求に伴って、検査装置が欠陥候補として判定したものには良品も多く含まれ、過検出が起ころう¹⁾。そのため、目視等による再検査によって、欠陥候補を欠陥と良品に分ける作業が行われている。製造工程の高効率化を実現するためには、目視等による検査を、図1に示すように自動化することが望まれている²⁾。

高感度な欠陥検査には、Deep Learning等に代表されるMachine Learningの適用が考えられるが、豊富な学習データの確保が必要であり、製造現場では、そのコストと安定な検査基準の提供という解決すべき課題がある。欠陥画像の生成手法に関する報告³⁾⁴⁾もあるが、なお発展途上にある。

本研究では、Deep Learning等による欠陥識別を前提に、欠陥画像を増やせないかを検討している。本報告では、検出した欠陥画像をseedとして、種々の寸法の欠陥画像や、その欠陥を場所の異なる良品に埋め込んで得られた画像をDeep Convolutional Auto-encoder(DCAE)により生成し、それらを学習データとして入力し、欠陥識別を行う。

本研究で想定した欠陥検査に対する懸念は、学習データの不完全性にある。検査装置や熟練検査員で収集した学習データは製造ラインで発生する欠陥の一部を捉えているに過ぎないこと、しかも偏っている恐れを否定できないことにある。そこで、学習データを自ら生成すること、さらにその妥当性を評価すべく検査感度を定量化する手法が求められていると考え、本研究を推進した。

2. 識別対象

本研究では、電子部品等に使われている、絶縁体であるポリイミド上に銅めっきにより形成した回路配線パターンを対象とする。検査装置によって出力された欠陥候補の画像を用いて、良品か欠陥か自動識別を行う。検査装置は市販のものであり、対象配線パターンの画像を、白色LED光源の明視野照明のもと、対物レンズ5倍にてモノクロCCDカメラにより取得し、同じ形状を持つ別の位置の配線パターンの画像と比較することにより、欠陥候補を検出する。欠陥候補画像は、回路配線パターンの一部が200×200画素で出力されたものを用いている。対応する良品画像はあらかじめ対応位置がわかっており、欠陥候補画像と同時に取得される。ここでは、re-visitによって再度画像を取得することなく、検査装置と同じ検出画像を用いて、on the fly(欠陥候補となった画像を例えば解像度を上げて取り直すのではなく、欠陥候補を判定するのに取得した画像そのものを用いた再検査)にて欠陥候補とペアとなる良品画像を用いて識別を行う。欠陥の種類は、凹欠陥、凸欠陥、異物欠陥がある。

Fig.1 Automation of defect identification

* 原稿受付 平成31年1月9日

掲載決定 平成31年4月26日

** 広島工業大学(広島市佐伯区三宅2丁目)

*** 正会員 広島工業大学

3. 欠陥識別の技術課題と提案

3.1 技術課題

Deep Learning 等で欠陥を識別する際、学習データを増やせば、正答率は向上する関係にあり、逆に学習データが不足する場合、望ましい正答率は得られない。そこで、大量の学習データが必要になるが、製造現場で欠陥を収集したり、ラベル付けをしたりすることはコスト増加の要因になるばかりでなく、学習データの質も絡んで安定な検査基準の提供ができないという恐れも生じる。このため、データの拡張(画像の回転、縮小・拡大など)が実施されるが、欠陥の検出偏りの是正はもちろん、欠陥と配線パターンの大小関係を変えることもなされず、有効性が確保されているとは言えない。

これを欠陥認識の観点で表現すると、図 2 に示すようになる。赤点は欠陥画像、青点は良品画像、緑点は欠陥または良品の生成画像を図示したものである。また、破線は識別境界を図示したものである。検査装置等により検出された欠陥は、欠陥寸法がまばらであり、かつ偏りがあることを同図上側は示しており、学習に使用する画像によっては、欠陥が同図上側にある識別境界すぐ右下のように一部分に偏っていたり、逆に同図上側にある識別境界すぐ右上のように全く存在していないため、適切な識別境界が設定されないという問題がある。このように、学習データの不完全性が今まで考慮されていなかった。このため、製造現場で得られた欠陥画像を核に、有効な学習データを同図下側のように追加することによって、適切な識別境界を設定する。本報告では、欠陥と対応する良品を seed として、内挿や外挿により欠陥と良品の違いを縮小したり、拡大した画像を生成する方法を提案する。さらに本報告では、欠陥とこれに対応する良品との差画像と、場所の異なる良品画像を seed として、新規な欠陥の画像を合成する方法を提案する。

3.2 提案手法

欠陥画像生成手法の構成を図 3 に示す。欠陥画像生成では、1 段目の四角で示す学習フェーズで、入力した画像が出力で復元されるように特徴を求める。そして、同図の 2 段目と 3 段目の四角で示す、画像を生成するフェーズでは、ペア画像を seed として Encoder に入力し、それぞれ次元圧縮する。その後、潜在変数を演算(3.2.2 項で説明する)し、Decoder に入力し復元することにより新規な欠陥画像を生成する。具体的には、2 段目に示す良品と欠陥のペア画像を seed として、種々の寸法を有する新規な欠陥画像の生成や、3 段目に示す欠陥と良品の差画像と、欠陥を埋め込みたい良品画像を seed として、新規な欠陥画像を生成する。

3.2.1 項にて欠陥画像生成に用いる DCAE の説明をし、3.2.2 項にて具体的な欠陥画像生成手法について説明する。

3.2.1 Deep Convolutional Auto-encoder (DCAE)

DCAE^{5)~7)}は図 4 に示すように Encoder と Decoder で構成される。Encoder にて入力を低次元特徴に変換し、Decoder にて低次元特徴から入力を復元する。中間層が $2l-1$ 層あるとすると潜在変数の次元数は中央の $z^{(l)}$ 層で最も小さくなり、図 5 に示すように入力画像の情報を圧縮表現した低次元特徴が現れる。後で述べる実験では、1 次元の特徴としてモデル化する。

対象が画像であるので Encoder と Decoder は画像処理に

適した CNN(Convolutional Neural Network)を使用することにする。CNN は、畳込み層、プーリング層、アップサンプリング層、全結合層から構成される。CNN では、多チャネルの画像に対し、複数のフィルタを用いて畳込み演算を行う。チャネル数が K の画像の各画素は K 個の値を持つ、例

Fig.2 Determination of decision boundary using generated images

Fig.3 Generation method of defective image by DCAE

Fig.4 Concept of Deep Convolutional Auto-encoder

Fig.5 Latent variable of Deep Convolutional Auto-encoder

例えば、入力画像に濃淡画像を使用すると入力のチャンネル数は $K=1$ となるが、後の演算によりチャンネル数は変わる。画像の縦横の画素数 $W \times W$ で、チャンネル数が K のとき、画像のサイズを $W \times W \times K$ と表す。中間層の出力は、マップ(map)とも呼ばれる。

第 l 層の畳込み (Convolutional: Conv) 層では、第 $l-1$ 層からの K チャンネルの画像 $z_{ijk}^{(l-1)}$ ($k=0, \dots, K-1$) に、 M 種類のフィルタ W_{pqkm} ($m=0, \dots, M-1$) を適用する。各フィルタのサイズは $H \times H \times K$ である。パディング処理によりマップの大きさは $W \times W \times M$ となる。これらの演算は次式により行われる。

$$z_{ijm}^{(l)} = \sigma \left(\sum_{k=0}^{K-1} \sum_{p=0}^{H-1} \sum_{q=0}^{H-1} W_{pqkm} z_{i+p, j+q, k}^{(l-1)} + b_{ijm} \right) \quad (1)$$

b は、バイアスであり、フィルタごとに各ノード共通 ($b_{ijm} = b_m$) となる。ノードとは、各層の基本的構成要素であり、複数の入力に重みが掛け合わさり、その加算値にバイアスを加え、活性化関数によって変換されて出力されるものである。また、 σ は活性化関数である。

プーリング層は、畳込み層で抽出された特徴マップを縮小するもので、本報で使用する最大プーリング (Max Pooling) は、入力画像 z 上で各チャンネル k ごとに P_{ij} 領域 (画素 (i, j) を中心とする $H \times H$ 領域) から最大となる画素値 u_{ijk} を次式により求める。例えば、着目領域が 2×2 画素の時、その最大値が出力される。これにより、特徴の若干の位置変化にロバストになる。

$$u_{ijk} = \max_{(p,q) \in P_{ij}} z_{pqk} \quad (2)$$

アップサンプリング (Up Sampling) 層はプーリング層と逆の関係にあり、入力画像上で画素 (i, j) をチャンネル k ごとに、 H^2 に拡張するものである。

全結合 (Dense) 層は隣接層間のノードが全結合した層である。第 $l-1$ 層のノードを $i=1, \dots, I$ 、第 l 層のノードを $j=1, \dots, J$ で表すと、第 $l-1$ 層のノードの出力から第 l 層のノードの出力は次式により与えられる。

$$z_j^{(l)} = \sigma \left(\sum_{i=1}^I W_{ji} z_i^{(l-1)} + b_j \right) \quad (3)$$

W は層間の結合の重みで、 b はノードのバイアスとなる。また、 σ は活性化関数である。

3.2.2 欠陥画像生成手法

画像生成には、Auto-encoder、Generative Adversarial Network (GAN)、Deep Convolutional GAN (DC-GAN)、Deep Neural Network (DNN) が報告されている。例えば、文献(8)で DC-GAN に基づく高度な画像生成ができる手法が報告されているが、膨大な学習データセットを用いており、かつ主観的な評価を伴っている。他に文献(9)も同様の報告がなされている。他にも、文献(4)では、学習画像確保のためにサイズ・回転・シェーディング・輝度など多様な欠陥画像を生成することを狙っている。

これらに対し、本提案は、膨大な学習データセットが無い環境下において、実在する欠陥の寸法や場所を変えることによって欠陥検査に重要な識別境界面近傍に画像を生成することを狙っている。これにより、識別に有効な学習データセットを効果的に確保でき検査感度を向上できる。具体的には、高々 2 枚の欠陥候補画像と対応する良品画像で、配線パターンに対して欠陥の寸法を拡大・縮小したり、3 枚の画像、すなわち欠陥候補画像と対応する良品画像の差画像から得られる欠陥を、異なる良品画像に埋め込むものであり、これらは識別境界面近傍に配置される。これらの画像生成は、パラメータによって操作可能である。

本研究では欠陥候補画像と対応する良品画像のペア画像に着目し、生成した画像を欠陥検査にいかに関活用するかを提案するものである。

はじめに、外挿と内挿を用いた欠陥画像生成手法を図 6 に示す¹⁰⁾。Encoder に対して、良品画像と欠陥画像のペアを seed として入力し、良品の潜在変数 l_s と欠陥の潜在変数 l_e を求める。求めた潜在変数から、内挿した潜在変数 V_i と外挿した潜在変数 V_e をそれぞれ次式により求める。

$$V_i = l_s + \alpha(l_e - l_s) = \alpha \cdot l_e + l_s(1 - \alpha) \quad (4)$$

$$V_e = l_s + (1 + \beta)(l_e - l_s) = l_e(1 + \beta) - \beta \cdot l_s \quad (5)$$

この算出された潜在変数を Decoder に入力することにより新規な欠陥画像を生成する。ここで、 α は 2 つの潜在変数をその比率により内挿するパラメータであり、0~1 の値をとる。 β は外挿のパラメータであり、0 が欠陥画像に対応し、0 以上の値をとって外挿する。これらのパラメータにより、欠陥の寸法を変更できる。このように、DCAE では複数画像の潜在変数を対象に、それらを演算処理することで新たな寸法を有する欠陥画像を生成することができる。

次に、合成による欠陥画像生成手法を図 7 に示す¹¹⁾。Encoder に対して、seed として欠陥と対応する良品の差画像と、場所の異なる良品の画像を入力し、差画像の潜在変数 l_a と良品画像の潜在変数 l_b をそれぞれ求める。その際、良品画像の位置を変えることで配線パターン上の任意の位置に欠陥を生成できる。求めた潜在変数から合成した潜在変数 V_s を次式により求める。

$$V_s = l_b \pm l_a \quad (6)$$

この算出された潜在変数を Decoder に入力することにより新規な欠陥画像を生成する。式(6)において加算する場合は、図 7 に示すように欠陥部分の輝度をそのまま良品に埋め込むことができ、式(6)において減算する場合は、欠陥部分の輝度を反転させて良品に埋め込むことができる。

Fig.6 Image generation method with interpolation and extrapolation

Fig.7 Image generation method by synthesis

4.2 欠陥画像生成の潜在変数の次元数決定方法

入力画像と出力画像との復元誤差が小さくなるような潜在変数の次元数を決定する。ここでは、平均平方二乗誤差(RMSE)を指標として使用する。この指標は、平均絶対誤差(MAE)に比べ、大きな誤差に対してより強く反応する。潜在変数の次元数を 50~250 次元まで 50 次元ずつ変え、それぞれ復元誤差を 5 回ずつ算出し、その平均をグラフにプロットする。復元誤差を求める際は、凹欠陥、凸欠陥、異物欠陥の中で代表的な欠陥画像をそれぞれ 1 枚使用した。

図 13 に示すように復元誤差はどの次元数であっても大きな差がないことがわかる。本報では復元誤差が最小となった 100 次元を使用して欠陥画像を生成する。

4.3 欠陥画像生成の評価結果

欠陥画像を対象とした場合と過検出画像を対象とした場合の内挿と外挿によるそれぞれの生成画像の例を図 14 に示す。同図において(a)は凹欠陥、(b)は凸欠陥、(c)は過検出の内挿と外挿による生成画像の例である。seed 画像である良品画像と欠陥画像を、それぞれの上左に示した。seed となる画像をもとに、潜在変数を内挿して生成された内挿画像と外挿して作成された外挿画像を示している。 $\alpha = 0$ で生成される画像は、良品画像から潜在変数で表された次元削減を通して復元された画像である。 $\alpha = 1$ で生成される画像と $\beta = 0$ で生成される画像は、いずれも欠陥画像から復元した画像である。

同図(a)(b)に示すように内挿画像は徐々に欠陥部分が元の欠陥画像の欠陥の大きさに近づくように生成されており、同図(c)に示すように外挿画像は元の過検出画像からさらに正常部の変動を大きくするように生成される。よって、内挿は識別境界を正常部側に、逆に外挿は識別境界を欠陥側に移動させるものとなる。欠陥と対応する良品の差画像と、場所の異なる良品画像を合成し内挿することで、配線パターン上に、様々な大きさの実在する欠陥を合成した画像の例を図 15 に示す。(a)は欠陥を配線間に埋め込んだ画像、(b)は欠陥を配線のエッジにかかるように埋め込んだ画像、(c)は欠陥を配線上に埋め込んだ画像である。seed 画像である良品画像と差画像を上左に示した。合成による生成画像は、良品画像に欠陥を埋め込んだ画像と、良品画像を内挿して得られた画像である。同図において、(a)(b)は式(6)における加算の例、(c)は式(6)における減算の例を示している。

このように、配線パターン上の様々な位置に、様々な大きさの欠陥を生成可能であることが確認できた。同図に示すような画像を用いることにより欠陥種ごとの欠陥検査感度を評価することができる。

Fig.13 Relationship between dimension number and restoration error

4.4 欠陥検査による生成画像の妥当性評価の条件

生成した欠陥画像を学習データとすることにより、欠陥検査基準を変更することが可能かどうか評価する。欠陥検査の実験条件を表 2 に示す。内挿画像と外挿画像、合成画像を使用した場合の妥当性を評価する。欠陥画像生成では欠陥候補画像 90 枚(凹欠陥: 30 枚, 凸欠陥: 30 枚, 異物欠陥: 30 枚)と対応する良品画像 90 枚を使用し、欠陥検査では過検出画像 30 枚と対応する良品画像 30 枚を追加して 240 枚を使用する。DCAE の学習回数は 200 回、バッチサイズは 5 とする。潜在変数の次元数は 4.5 節に示す方法により決定した。SVM は RBF カーネルを使用し、 C と γ の値は 0.01~100 の範囲でグリッドサーチにより決定した。

Fig.14 Generated images with interpolation and extrapolation

Fig.15 Generated images by synthesis

本報では、以下に述べる 3 種類の欠陥検査①, ②, ③を行う。

欠陥検査①では、DCAE で検査画像を 2 次元に次元削減し、SVM により内挿と外挿による生成画像の有無により識別境界がどのように変化するか確認する。使用した画像の例を図 16 に示す。使用した画像は欠陥画像 30 枚、過検出画像 10 枚の計 40 枚と、 $\alpha = 0.8$ として生成した内挿画像 30 枚、 $\beta = 0.2$ として生成した外挿画像 10 枚の計 40 枚である。

欠陥検査②では、本来検出すべき欠陥を、検査装置により検出された欠陥画像を用いて学習し検査した場合と、微細な欠陥画像を追加学習して検査した場合を比較する。すなわち、図 17 に示すように、本来検出すべき欠陥画像を生成し、検査装置により検出された画像で学習し識別境界を設定したモデルで検査した場合と、これらを、別に生成した微細な欠陥画像を追加学習したモデルで検査した場合を比較評価する。内挿による生成画像の例を図 18 に示す。本来検出すべき欠陥は、きめ細かく内挿して得られた複数の画像を専門家にみて頂き、良品と欠陥の境界を求めてもらって、得たものである。境界の欠陥側にある $\alpha = 0.6 \sim 0.9$ の画像 44 枚(凹欠陥:13 枚、凸欠陥:20 枚、異物欠陥:11 枚)を、検出すべき欠陥と考え(赤枠で示す)、元の欠陥画像と入れ替える。追加学習に使用した内挿による生成画像の例を図 19 に示す。後者の検査では、専門家指摘と同等の寸法をもつ、 $\alpha = 0.7$ の内挿欠陥画像 90 枚を学習データに加える。これらは、識別境界が高感度側により適切に設定されるよう、特徴空間に追加でプロットされる。

欠陥検査③では、学習により識別境界を設定したモデルに欠陥の配置位置と欠陥の大きさを変えた生成画像を入力し、その検出率を評価する。使用する画像は図 15 に示す 33 枚の生成画像と、欠陥検査②に使用した本来検出すべき生成した欠陥画像(欠陥画像生成に使用した欠陥を除く)119 枚の計 152 枚である。DCAE により次元削減し SVM にて 5 回検査し、上記生成画像が欠陥と検出される率を求める。この作業をそれぞれの生成画像に対して行いグラフにプロットする。これにより、欠陥の位置や大きさへの依存性を評価できる。

4.5 欠陥検査の潜在変数の次元数決定方法

欠陥検査では Encoder により求めた潜在変数を使用して検査するため復元誤差ではなく正答率により次元数を決定することにした。SVM のパラメータはグリッドサーチにより決定した。潜在変数を 50~250 次元までほぼ 50 次元ずつ変え、図 8 による検査方法により正答率を 5 回ずつ算出し、その平均をグラフにプロットする。図 20 に示すように最も正答率が高くなる 100 次元で検査することにした。

Table2 Experimental conditions of image inspection		
Index		Conditions
Evaluation image	Defective	90 images
	Overdetective	30 images
	Good	120 images
	Generated(inspection.1)	40 images
	Generated(inspection.2)	134 images
	Generated(inspection.3)	77 images
Input image size		24×24pixels
SVM		Kernel:RBF
Number of dimensions of latent variable		50,75,100,125, 150,200,250

Fig.16 Examples of interpolation and extrapolation generated images

Fig.17 Explanation of defect inspection.2

Fig.18 Examples of defect images to be detected originally generated by DCAE

Fig.19 Examples of generated images added to learning data

Fig.20 Relationship between dimension number and accuracy

4.6 欠陥検査の評価結果

図 8 に示す方法により、欠陥検査①, ②, ③を評価した。

図 21 に欠陥検査①の結果を、2 次元の潜在変数にて表示した例を示す。内挿と外挿による生成画像を入れる前の識別境界は円状であり、識別境界の外側に 2 つの過検出が見られる。しかし、内挿と外挿による生成画像を入れることにより識別境界が修正され、緑の点で表される過検出が減っていることがわかる。このように内挿と外挿による生成画像を適切に加えることによって、検査感度が向上することがわかる。

欠陥検査②の結果を図 22 と図 23 に示す。図 22 は本来検出すべき欠陥を、検査装置により検出された画像を用いて学習し検査した場合と、微細な欠陥画像を追加学習して検査した場合の混同行列である。追加学習する際はカンニングとならないよう学習した。5 回の繰返し結果を示している。同図(a)では、本来検出すべき欠陥を、検査装置により検出された画像を用いて学習し検査した場合の結果を示しており、最も悪い結果では欠陥を 8 件も見逃していることが分かる。しかし、生成した微細な欠陥画像を追加学習して検査した場合の同図(b)では、欠陥の見逃しは 1 件だけとなり、欠陥の見逃しが大幅に軽減されている。提案手法の効果が確認できたと考えられる。

見逃した欠陥画像と過検出と再度判定された良品画像を図 23 に示す。赤枠は欠陥の見逃し画像であり、青枠は過検出画像である。過検出は 4 件であったが、微細な欠陥画像を追加学習した結果、5 件になった。これらの過検出は、配線パターンの幅が異なるものや、ぼやけているもの、そして明るさの相違によるものであった。本報では、30 件の過検出を対象としており、これが 5 件に減少しているため、効果が目減りするものではないと考えている。

図 22(a)と図 23(a)は、内挿画像を用いて、厳しい検査を要求した場合の結果である。内挿により欠陥部の寸法を小さくした画像を検査する場合、検出すべき欠陥は特徴空間上で良品画像に近づくように配置される。混同行列と見逃し画像の数が違うのはそれぞれの混同行列で見逃した画像が異なるためである。図 22(b)と図 23(b)は、より微細な欠陥が生成された画像 90 枚を、学習データに追加した場合の結果である。このように、内挿による生成画像を加えることにより、見逃しとなっていた欠陥を少なくすることができ、検査感度が向上したことを確認した。

欠陥検査③の結果を図 24 に示す。同図は、種々の寸法をもつ欠陥を配線パターンの位置を変えて評価したものである。 C と γ の値は事前検査により求めた $C = 1.41$ および $\gamma = 12.6$ を用いて検査した。図 24 は、図 8 による検査方法を 5 回繰り返した結果の平均値を示しており、縦軸が検出率を示している。この結果から、配線上に欠陥を埋めたものが、検出率が低いことがわかる。一方、配線間にある欠陥は小さくても検出できていることがわかる。4.4 節で専門家指摘と同等の寸法をもつ、 $\alpha = 0.7$ の内挿画像を学習データに追加したと述べたが、検出率はこれに見合う形になっていると考える。このように、配線パターンの様々な位置に大きさの異なる欠陥を配置でき、欠陥の位置や寸法ごとの検査感度を評価可能であることが確認できた。

5. 結 言

電子部品の外観検査において、欠陥候補画像の目視等による再検査を自動化することを目的とし、高精度な欠陥識別の可能性を追求すべく、Deep Learning 等による欠陥識別が検討されている。しかし、製造現場では欠陥画像の収集にコストがかかる

(a) Without generated image (b) With generated image

Fig.21 Difference of boundaries due to with/without generated images

Parameters by Grid Search			Accuracy : 90.83%			Evaluation results		
C	1.78					Good	Defect	
γ	1.12					27	3	
			true value	Good	27	3		
				Defect	8	82		

Parameters by Grid Search			Accuracy : 92.50%			Evaluation results		
C	2.82					Good	Defect	
γ	2.00					26	4	
			true value	Good	26	4		
				Defect	5	85		

Parameters by Grid Search			Accuracy : 91.67%			Evaluation results		
C	2.82					Good	Defect	
γ	2.00					26	4	
			true value	Good	26	4		
				Defect	1	89		

(a) Using generated images as inspection targets

Parameters by Grid Search			Accuracy : 95.83%			Evaluation results		
C	2.82					Good	Defect	
γ	2.00					26	4	
			true value	Good	26	4		
				Defect	1	89		

Parameters by Grid Search			Accuracy : 95.00%			Evaluation results		
C	2.82					Good	Defect	
γ	2.00					25	5	
			true value	Good	25	5		
				Defect	1	89		

(b) Using generated images as training data as well as inspection targets

Fig.22 Confusion matrices

(a) Using generated images as inspection targets

(b) Using generated images as training data as well as inspection targets

Fig.23 Examples of erroneously detected images

Fig.24 Transition of discrimination rates with changing positions and size of defects

ため、学習データが不足し、望ましい正答率が得られない。そこで、本研究では、実在する欠陥を seed とした欠陥画像の生成により、Deep Learning 等に用いる学習データの追加手法を検討した。

具体的には、Deep Convolutional Auto-encoder に、欠陥画像と良品画像を入力し、これらを核に、潜在変数の重み付き和により、潜在変数を更新し、これから新たな寸法をもつ欠陥画像を出力する。さらに、種々の寸法をもつ欠陥部と種々の良品画像を、Deep Convolutional Auto-encoder に入力することによって、配線パターン上の任意の位置に欠陥を生成する。

提案手法を評価した結果、元の欠陥から種々の寸法をもつ欠陥が生成できることを確認した。そして、生成した画像を欠陥として学習データに追加したり、正常として学習データに追加することによって、学習データの拡張ができるだけでなく、欠陥判定基準をきめ細かく制御できるようになるという知見が得られた。このように、配線パターンの様々な位置に大きさの異なる欠陥を配置することにより欠陥の大きさだけでなく、配線パターンに対する検査感度を評価することができるようになった。

本質的な点は、検査装置等により検出された欠陥が、製造現場で発生した欠陥の潜在的母集団の一部であり、これに伴って欠陥寸法がまばらとなり、かつ偏ることによる学習データの不完全性が今まで考慮されていなかったという課題に対し、本提案手法により、この課題を解決し得る可能性を見いだせたことにあると考える。

今後の課題は、欠陥の発生要因を考慮して、様々な形状や回転などを含む多様な欠陥を種々の配線パターンに埋め込み、さらに、これをサイズの異なる欠陥画像に展開することである。

参 考 文 献

1) 浦野貴裕, 酒井薫, 前田俊二, 佐藤真一: 対話的教示欠陥選択に基づく

- く効率的な実欠陥・虚報弁別技術, IEICE, 96-D, 1, (2013) 221.
- 2) 西村晃紀, 柳部正樹, 橋本将弥, 荒木智行, 長谷智紘, 森山 健, 前田俊二: ヒストグラムベースの局所特徴量を用いた電子部品の外観検査手法の提案, 精密工学会誌, 84, 7, (2018) 664-670.
- 3) 伊藤秀将, 入本勇字次, 榎本晋一: 画像認識精度を向上させるディープラーニング技術を用いた学習用画像の自動生成, 東芝レビュー, 72.4, (2017).
- 4) 片山隼多, 吉村裕一郎, 青木公也, 興水大和: DNN による外観検査の自動化における学習画像生成の検討, ViEW2017 ビジョン技術の実利用ワークショップ講演論文集 OS1-H1, (2017) 19-22.
- 5) 麻生英樹, 安田宗樹, 前田新一, 岡野原大輔, 岡谷貴之, 久保陽太郎, ボレガラダヌシカ: 深層学習, 近代科学社, (2015) 3 章.
- 6) A.lqahtani, X. Xie, J. Deng, M. W. Jones: A Deep Convolutional Auto-Encoder With Embedded Clustering, In 2018 IEEE International Conference on Image Processing (ICIP), Athens, Greece, (2018) 4058-4062. <https://doi.org/10.1109/ICIP.2018.8451506>.
- 7) 岡谷貴之: 機械学習プロフェッショナルシリーズ, 深層学習, 講談社, (2015).
- 8) 佐川友里香, 萩原将文: 属性を付与した DCGAN による顔画像生成システム, 日本感性工学会, (2017).
- 9) Jun-Yan Zhu, Philipp Krähenbühl, Eli Shechtman, and Alexei A. Efros: Generative Visual Manipulation on the Natural Image Manifold, European Conference on Computer Vision, (ECCV 2016).
- 10) 柳部正樹, 田中智裕, 大井健太郎, 西村晃紀, 森山 健, 長谷智紘, 前田俊二, 電子部品検査精度の向上のためのオートエンコーダを用いた欠陥画像生成手法の検討, 精密工学会 2018 年度秋季大会, (2018) .
- 11) 田中智裕, 大井健太郎, 柳部正樹, 西村晃紀, 森山健, 長谷智紘, 前田俊二, 電子部品検査における画像データ拡張のための画像生成手法の検討, 電気学会, 知覚情報/次世代産業システム 合同研究会, PI-18-050, IIS-18-031, (2018).
- 12) 平井 有三, はじめてのパターン認識, 森北出版, (2012).
- 13) 多田智史, 石井一夫: あたらしい人工知能の教科書, (2016).
- 14) Andreas C.Muller, Sarah Guido, 中田 秀基(訳): Python ではじめる機械学習, オライリージャパン, (2017).