
画像を用いた自動外観検査技術

Automated Visual Inspection Technology Using Image Data

田中 拓哉*
Takuya TANAKA

笠原 亮介*
Ryosuke KASAHARA

要 旨

製造品外観の良否判定を、画像を用いた外観検査により自動化したいというニーズがある。近年の撮像技術や画像認識技術の発展に伴い、画像による自動外観検査の利用が広がりつつある。本稿では、リコーの有する画像による自動外観検査技術のうち、外観検査の性能を競う国内のコンテストで優秀賞を受賞した2つの手法を紹介する。1つ目の手法は、機械学習の一手法である、「半教師あり異常検知」を用いた手法で、良品のサンプル画像のみから良否判定を可能とするものである。一般に、機械学習を利用するためには大量の学習用データが必要となるが、製造部品の不良品は良品に比べて数が少ないため、十分な量を用意することが困難である。そこで、良品のサンプル画像のみで学習可能なアルゴリズムを開発した。2つ目の手法は、外れ度を表すZ-scoreを改良した、良品の形状などがばらついていても精度良く欠陥検出を可能にする手法である。この手法は、1次加工段階の部品や食品など、良品の形状ばらつきが大きい対象でも高い精度で外観検査が可能である。

ABSTRACT

In the manufacturing process, automation of visual inspection is in high demand. Due to recent progress in imaging technologies and computer vision technologies, use of automated visual inspection using image data is increasing. In this paper, we describe our two methods for a visual inspection algorithm contest as an introduction to our automated visual inspection technologies. The first method can learn the decision boundaries of quality determining without image data of the defective parts by using semi-supervised learning. It is difficult to prepare a large number of defective samples because defects occur only rarely. Thus, we developed a new algorithm that can learn without defective parts by semi-supervised anomaly detection. The second method can classify defective samples, even if the shape of the non-defective parts has a large variance. The shapes of some products, such as primary processing stage parts, have a large variance. Thus, we modified the Z-score calculation method to increase robustness. As a result, we achieved a high accuracy in the contest.

* リコーICT研究所 システム研究センター

System Research & Development Center, Ricoh Institute of Information and Communication Technology

本稿は、日本画像学会に帰属の著作権の利用許諾を受け、日本画像学会誌, 221号, Vol. 55, No. 3 (2016)に掲載した論文を基に作成した。

1. はじめに

製造過程における製品の外観検査は、人による目視検査と、画像による自動外観検査がある。目視による検査は、人ごとに判断基準がばらつく、人件費が掛かるなどの問題があるため、画像による自動外観検査を導入してばらつきやコストを低減したいというニーズがある。画像による外観検査では、画像から製品外観の良否を判定したり、製品外観の欠陥を検出したりする必要がある。これらは人が判定基準を決めるルールベースと呼ばれる方法と、機械学習により判定基準を獲得する方法がある。ルールベースでは、欠陥種類が多いなど判断基準が複雑な場合、ルールが複雑になり、ルールの管理や修正が難しいという課題がある。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、画像中の欠陥領域座標などの答え）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、リコーにおいても技術開発を行っている。この一環として、精密工学会が主催する外観検査アルゴリズムコンテスト^{1,2)}へ2014年から参加している。これは、実際に生産現場で課題となっている画像に対して検査アルゴリズムを開発し、良否判定性能と処理時間を競うコンテストであり、毎年約150の団体や個人が参加している。リコーは2年連続で最優秀賞に次ぐ優秀賞を受賞している。本稿では、リコーの外観検査技術の紹介として、2014年、2015年に参加した外観検査アルゴリズムコンテストの取り組みについて述べる。

2. 外観検査アルゴリズムコンテスト2014への取り組み

2-1 コンテスト概要

外観検査アルゴリズムコンテストは例年3月に課題の発表、6月に公開画像提供、9月に検査プログラム提出締め切り、12月に結果公開という流れで進められる。参加者は公開された画像を元に検査プログラムを作成、提出する。評価項目は、公開された画像に非公開の画像を加えた評価用画像セットに対する画像単位の良否判定性能、予測した欠陥領域と正解の欠陥領域の重複度合い、画像単位の処理時間であり、これらを点数化し、順位付けされる。

2014年の課題は、「鋳造部品の表面を連続的に撮影した画像系列からの欠陥検出」と題されており、Fig. 1に示すように、連続的に撮影された鋳造部品の外観検査を行うものである。1台の鋳造部品を連続的に撮影した210枚を1セットとし、合計4セット（840枚）の画像とそれぞれの欠陥の座標情報が公開された。良品と欠陥の例をFig. 2に示す。実線で囲まれた領域が定義された欠陥領域である。欠陥はひび割れ、刻印や成形に不備があるものなど多岐に渡る。また、撮像条件（ピントや明るさ）は統一されていない。




Fig. 1 Example images in Visual Inspection Algorithm Contest 2014¹⁾.

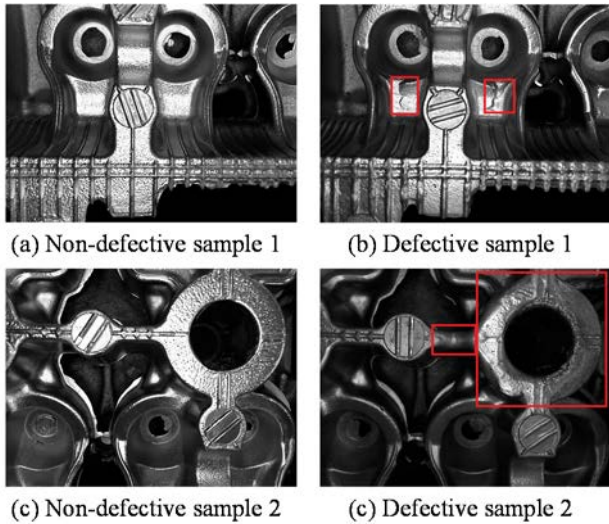


Fig. 2 Example images of non-defective parts and defect parts in Visual Inspection Algorithm Contest 2015¹⁾. The red rectangle is a defined defect area.

2-2 我々のアプローチ

我々は機械学習の一手法である、「半教師あり異常検知」を用いた欠陥検出アルゴリズムを開発した。これは、今回の課題から、以下の2点を問題点と捉えたためである。1つ目の問題は、サンプル画像数が少ないことである。公開された画像を使いやすい形に成形したところ、良品サンプルが70個、欠陥サンプルが14個であった。機械学習の方法として、良く使われている「教師あり学習」による識別では、サンプル数が少ないと十分な性能を得られないことが多い。2つ目の問題は、欠陥のパターンが網羅されていない可能性があることである。公開された画像セットを見ると、欠陥種類や大きさが多岐に渡っており、評価用の画像には、公開画像にない種類や大きさの欠陥があると予測される。

2-2-1 半教師あり異常検知

機械学習では、ある入力に対して、コンピュータが学習を行い、有用な出力を予測する。事前の学習ステップとして、入力データとそれに対応するラベル（正解出力）を学習サンプルとしてシステムに入力して学習を行う。学習ステップの後、判定ステッ

プにおいて、システムにあるデータを入力すると、システムは学習した内容に基づいて正解を予測する。

外観検査において機械学習を用いて良否判定を行う場合、「教師あり学習」を用いる方法が一般的である。この方法は、良品をポジティブクラス、不良品をネガティブクラスとして、データセット（両クラスのサンプル画像とそのラベル）を用いて良否判定の基準を学習する。それに対して、機械学習の一手法である「半教師あり異常検知」を用いる方法がある。この方法では、学習データとして例えば良品のみといった、1つのクラスのサンプル画像のみを用いて学習を行う。この手法では、1つのクラスのサンプル画像を準備すればよいため、今回のように欠陥サンプルが少なく、欠陥種類を網羅していないデータセットでも学習が可能である。

「教師あり学習」と「半教師あり異常検知」の違いをFig. 3に示す。機械学習の学習ステップでは、複数の入力画像に対して特徴量を算出し、特徴量とラベルを元に、特徴空間上で識別面を学習する。

「教師あり学習」では、Fig. 3 (a)に示すように、学習サンプルの良品と不良品、それぞれの特徴量を精度よく識別できるような識別面が学習される。このとき、不良品の学習サンプルが少ないと、未学習画像に対する識別精度が低い不適切な識別面が学習されてしまう。また、学習サンプルにない未知の欠陥の特徴量が、学習サンプルの欠陥の特徴量と大きく異なっていた場合、判定を間違える可能性が高い。これに対して、「半教師あり異常検知」では、Fig. 3 (b)に示すように、良品とそれ以外を分ける識別面が学習される。そのため、学習サンプルにない未知の欠陥の特徴量が、学習サンプルの欠陥の特徴量と大きく異なっていた場合でも、正しく判定することが期待できる。

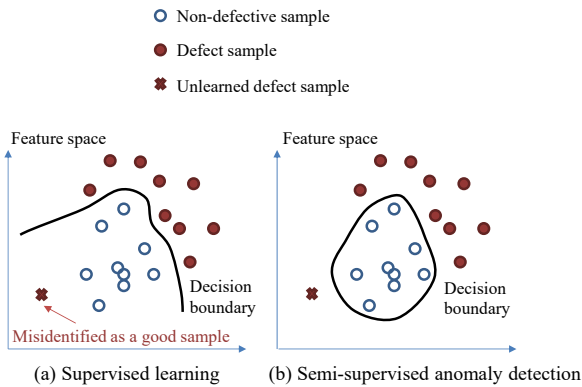


Fig. 3 Difference between supervised learning and semi-supervised anomaly detection in feature space.

2-2-2 欠陥検出アルゴリズム

半教師あり異常検知の手法としてはOne-class SVM³⁾やLOF⁴⁾が有名であり、今回はOne-class SVMを用いた。特徴量としては、SURF特徴⁵⁾のOrientationと特徴点のx座標、y座標の3次元のみとした。画像認識では、数十、数百次元の特徴量が使われることも珍しくないが、今回のように学習に使えるサンプル数が少ない場合に高次元の特徴量を用いると、未学習画像に対する判定性能が落ちる可能性が高いため、特徴量を3次元に絞った。

以下に学習のフェーズと、判定フェーズ（良品・不良品の識別）に分けて処理の概要を記述する。

【学習フェーズ】

- (1) テンプレートマッチングを用いて部位ごとに画像を切り出す。
- (2) 特徴量のDenseサンプリングを行うため、数ピクセルごとにSURF特徴を算出する。
- (3) x座標、y座標、SURF特徴のOrientationの3次元を特徴量として算出する。
- (4) 上記特徴量を複数の良品画像に対して部位ごとに算出する。
- (5) 上記特徴量に対してOne-class SVMを用いて識別面を学習する。

【判定フェーズ】

判定フェーズでは、「傷などがある」のが欠陥となる部位と、「必要な刻印がない」のが欠陥となる部位を分けてそれぞれ判定を行った。

- (a) 「傷などがある」のが欠陥となる場合
 - (a-1) テンプレートマッチングを用いて部位ごとに画像を切り出す。
 - (a-2) SURF特徴点を抽出する。（ただし、SURF特徴点のScaleが学習時と近い値以外の特徴点は除外する。）
 - (a-3) 特徴点でのSURF特徴のOrientationを算出し、特徴量をx座標、y座標、SURF特徴のOrientationの3次元として、特徴点での特徴量を算出する。
 - (a-4) 各特徴点に対して、学習フェーズで学習を行ったOne-class SVMで異常判定し、高い空間密度で異常が検出された場合に欠陥と判定する。
- (b) 「必要な刻印がない」のが欠陥となる場合
 - (b-1) テンプレートマッチングを用いて部位ごとに画像を切り出す。
 - (b-2) SURF特徴点のScaleは学習時と同じ値とし、Denseサンプリングを行うため、数ピクセルごとにSURF特徴のOrientationを算出し、特徴量をx座標、y座標、SURF特徴のOrientationの3次元として、特徴量を算出する。
 - (b-3) 求めた特徴量に対して、学習フェーズで学習を行ったOne-class SVMで異常を検出し、正常と判定された特徴点の数を閾値で判断し、閾値以下であればその部位を欠陥として判定する。

2-3 結果

公開画像に対する判定性能を Table 1 に示す。Defect detection rate (欠陥検出率) は、提供されているサンプル画像合計840枚の中に存在する欠陥部位の検出率である。誤検出率は、サンプル画像合計840枚の中で誤って正常部位を欠陥部位と誤検出した割合を示している。良品の画像のみ学習したにもかかわらず、高い精度で欠陥検出ができていることが分かる。また、False detection rate (誤検出率) は840枚中1枚であり、誤検出率を低く抑えた上で8割近い欠陥を検出できていることが分かる。

Table 1 Accuracy and processing time.

Defect detection rate	79% (11 / 14 defect)
False detection rate	0.12% (1 / 840 image)
Processing time	164 (ms / image)

※CPU: Core i7 870, Memory: 20GB, OS: Windows7 64bit

Fig. 4 に公開画像に対する検出結果の例を示す。Fig. 4 (a) に欠陥検出成功例を、Fig. 4 (b) に誤検出例を示す。共に実線の矩形が正解の欠陥領域であり、点線の矩形が本アルゴリズムの検出結果である。Fig. 4 (a) では、検出範囲は大きいものの、正常に欠陥箇所が検出できていることがわかる。また、Fig. 4 (b) では良品を欠陥と誤判定している。Fig. 2 (c)、Fig. 2 (d) を見ると、誤判定した領域は、刻印があるものが良品と定義されている。Fig. 4 (b) で誤判定した領域は刻印がないため、本アルゴリズムでは欠陥領域と識別されたと考えられる。

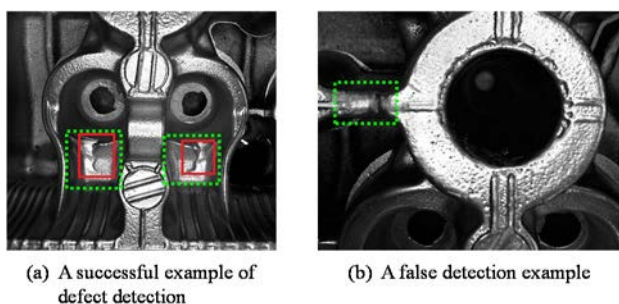


Fig. 4 Examples of defect detection result. The red rectangle of solid line is a defined defect area. The green rectangle of dot line is a detected defect area.

処理時間に関しては、マルチスレッド化など高速化のための手段は特に適応していない状態で、サンプル画像840枚を処理したところ1枚あたり164 msであった。

今回は146件のエントリーがあり、評価用画像セットに対する本アルゴリズムの結果は優秀賞であった¹⁾。

3. 外観検査アルゴリズムコンテスト2015への取り組み

3-1 コンテスト概要

外観検査アルゴリズムコンテスト2015²⁾の課題は、「铸造部品の良品サンプル画像からの欠陥検出」と題されており、Fig. 5に示すような铸造部品画像の欠陥検出を行う。良品と不良品の画像合計11枚と欠陥の座標情報が公開された。欠陥の例をFig. 6に示す。実線で囲まれた領域が定義された欠陥領域である。欠陥はバリや穴が開いている、もしくはあるべき穴が塞がっているなど多岐に渡る。また、撮像条件（明るさや撮影位置）は固定されておらず、正解の欠陥以外にも汚れが存在し、加えて形状がばらついており、難易度の高い課題である。特に、Fig. 7に示すように、良品の中でも縁の厚みが大きく異なるなど、形状ばらつきがあり、このばらつきを欠陥と誤検出せずに、高い精度で欠陥検出可能なアルゴリズムを構築することが求められる。競技の評価方法は2014年時と同様である。




Fig. 5 Example images in Visual Inspection Algorithm Contest 2015²⁾.




Fig. 6 Defect examples in Visual Inspection Algorithm Contest 2015²⁾. Red rectangle is a defined defect area.




Fig. 7 Variations in non-defective parts.

3-2 欠陥検出アルゴリズム

提供される公開画像は全11枚であり、2-2章で提案した半教師あり異常検知による手法を用いるには良品画像枚数が足りない。そこで、良品学習⁶⁾を元にした手法を用いた。

良品学習とは、検査画像の画素ごとに式(1)で求められるZ-score⁷⁾と呼ばれる値を用いて良否判定や欠陥検出を行うものである。ここで、 i, j は画素位置であり、 v は輝度値、 m は学習用の良品画像から求めた輝度値の平均値、 std は輝度値の標準偏差を表す。

$$Z\text{-score}(i, j) = \frac{v(i, j) - m(i, j)}{std(i, j)} \quad (1)$$

Z-scoreは平均値からの差を標準偏差で割ったものなので、Z-scoreの絶対値が大きいくほど良品から外れていることを意味する。そのため、画素ごとのZ-scoreの絶対値の総和から良否判定を行う、または、閾値以上のZ-scoreを持つ画素が密集した領域を欠陥領域と判定することにより外観検査や欠陥検出が可能となる。

提供画像をみると、Fig. 7に示すように、良品部品の縁の厚みや穴の大きさがばらついていることが分かる。そのため、良品学習を単純に適用すると誤検出が増えてしまう可能性がある。そこで、Z-scoreを求める対象画素の周辺画素の平均と標準偏差も用いて複数のZ-scoreを求め、その中の最小値を対象画素の欠陥度合いを示す量（「欠陥量」と表記）とした。これを式(2)に示す。

$$\text{欠陥量}(i, j) = \min_{k, l} \left\{ \frac{|v(i, j) - m(k, l)|}{std(k, l)} \right\} \quad (2)$$

ここで、 $|k - i| \leq P, |l - j| \leq P$ であり、 P は0以上の整数である。これにより、Fig. 7のように縁の厚みが変わっても、 P で定義される周辺領域内に収まる変化であれば誤検出の抑制が期待できる。

以下に、開発した欠陥検出アルゴリズムの概要を記述する。

【学習フェーズ】

良品画像を用いて、パーツごとの各画素について、輝度値の平均と標準偏差を求めておく。

【判定フェーズ】

- (1) テンプレートマッチングを用いてパーツごとに画像を切り出す。
- (2) 各パーツについて、画素ごとに式(2)により欠陥量を計算する。
- (3) 欠陥量について閾値で二値化し、閾値以上の画素を欠陥画素とする。
- (4) 欠陥画素について、ラベリングを行い、各領域の面積を求める。面積が一定以上の領域の外接矩形を欠陥領域として座標を求める。

3-3 結果

今回は提供された画像枚数が少なかったため、画像を加工し、良品画像20枚、不良品画像26枚、全46枚に増加させた。これらを用いて画素ごとの平均、標準偏差を求めた。その後、この46枚について、回転、輝度変化、平滑化フィルタを施して合計782枚

に増加させ、これらを評価用に用いた。この判定性能評価結果をTable 2に示す。

Table 2の良否判定正解率は、入力画像が良品か否かをどれだけ正解できたか示しており、評価用782枚のうち755枚（96.55%）を正しく良否判定できたという結果になった。未検出率は、不良品の入力画像を良品と判定してしまった割合を示しており、不良品画像442枚のうち、27枚（6.11%）を不良と判定できなかった。良品画像は全て良品と判定できたので、誤検出率は0%であった。処理時間については、1枚あたり143.7 msであった。以上より、高い判定性能を持ち、処理時間も1秒以下となるアルゴリズムを構築できた。

Table 2 Accuracy and processing time.

Accuracy	96.55% (755 / 782 image)
Miss detection rate	6.11% (27 / 442 image)
Processing time	143.7 (ms / image)

※CPU: xeon x5690, Memory: 24GB, OS: Windows7 64bit

本アルゴリズムでの欠陥検出結果をFig. 8に示す。実線が正解の欠陥領域で、点線が本アルゴリズムの出力結果である。Fig. 8 (a)は欠陥検出成功例であり、Fig. 8 (b)は未検出例である。




Fig. 8 Examples of defect detection result. Red rectangle of solid line is a defined defect area and green rectangle of dot line is a detected defect area.

今回は142件のエントリーがあり、評価用画像セットに対する本アルゴリズムの結果は優秀賞であった²⁾。

4. 応用について

2章で紹介した手法は、「半教師あり異常検知」を利用したものであり、異常な状態のデータは得られにくいですが、正常な状態のデータは得られやすい事例であれば、外観検査以外にも適応が可能である。例えば、不正アクセス検知、セキュリティカメラ映像中の異常検知、高齢者向け見守り検知、クレジットカードなどの不正利用検知、ヘルスケア向けの身体データからの異常検知などが応用として考えられる。

3章で紹介した手法は、良品がばらついていても高い精度で良否判定が可能な手法である。これは、今回紹介した外観検査アルゴリズムコンテストのような鑄造部品以外でも、良品形状のばらつきが大きい食品などの検査への応用が考えられる。

5. まとめ

本稿では、リコーの外観検査技術の紹介として、外観検査アルゴリズムコンテストの取り組みを紹介した。2章では、学習時に不良画像を必要としない半教師あり異常検知を用いた手法を紹介した。外観検査アルゴリズムを構築する段階で学習用の不良画像を準備しなくてよいため、これまで不良画像を大量に準備できなかった製品でも外観検査の導入が可能になると考えられる。3章では、良品の形状がばらついていても精度良く良否判定が可能な良品学習による手法を紹介した。外観検査アルゴリズムコンテスト2015の課題のような鑄造部品や食品など良品ばらつきが大きい対象でも高い精度での外観検査が可能になると考えられる。

今後は本稿で紹介した技術に加え、これまで培った画像処理、機械学習技術を活かし、外観検査技術開発を行う。また、製品の的外観検査にとどまらず、4章で述べたような応用先へ展開していく。

謝辞

本稿で掲載した画像の一部は、外観検査アルゴリズムコンテストの課題画像です。具体的には、Fig. 1, Fig. 2, Fig. 4は外観検査アルゴリズムコンテスト2014の課題画像、Fig. 5～8は外観検査アルゴリズムコンテスト2015の課題画像です。画像を提供くださった、公益社団法人精密工学会 画像応用技術専門委員会に感謝いたします。

参考文献

- 1) 精密工学会: 外観検査アルゴリズムコンテスト2014, 精密工学会, <http://alcon.itlab.org/14/> (参照2016-03-15).
- 2) 精密工学会: 外観検査アルゴリズムコンテスト2015, 精密工学会, <http://alcon.itlab.org/15/> (参照2016-03-15).
- 3) B. Schölkopf et al.: Estimating the support of a high-dimensional distribution, *Neural Computation*, Vol. 13, Issue 7, pp. 1443-1471 (2001).
- 4) M. M. Breunig et al.: LOF: identifying density-based local outliers, *ACM SIGMOD Int. Conf. on Management of Data*, pp. 93-104 (2000).
- 5) H. Bay, T. Tuytelaars, L. Van Gool: Surf: Speeded up robust features, *9th European Conference on Computer Vision*, Springer Berlin Heidelberg, pp. 404-417 (2006).
- 6) 有限会社オービット: 画像処理方法およびその装置, 特開2005-265661 (2005).
- 7) D. Padfield, G. Brooksby, R. Kaucic: Automatic Deformation Detection for Aircraft Engine Disk Inspection, *Journal of Multimedia*, Vol. 2, No. 4, pp. 34-44 (2007).