工業製品における異常検出に関する研究

藤本 健司*　　早稲田 一嘉**

A Study on Anomaly Detection in Industrial Parts

Kenji FUJIMOTO*　Kazuyoshi WASEDA**

ABSTRACT

Airplanes and other industrial parts are still visually inspected for appearance. The problem with visual inspection is that it is costly and time-consuming to train technicians. In this research, we propose a new method of photographing parts and an inspection method using deep learning as an alternative to visual inspection.

Keywords : deep learning,　appearance inspection, automatic photographing method

1. はじめに

航空機の部品は, 自動車が 1 台当たり約 2 万～3 万個の部品で構成されているのに対し，1 機あたり約 600 万個の部品で構成されている．また，安全性を最優先にするため，すべての部品において認証取得が必要となるなど非常に厳しい品質管理が実施されている．その中でも特に，部品の外観検査については，自動化を行わず，未だに目視による全数検査を行っているケースが多い．目視を行う外観検査では，検査員が検査する部品を手でいろいろな角度に傾け，その部品に照明を当てることで傷の検出を行っている．そのため，1 日に作業できる数は限られており，検査員の技量によって，検査部品数や検査結果にばらつきが出るという問題点を抱えている．また，生産量を増やすためには検査員を増員する必要があるが，そのための検査員の育成には，時間とコストが膨大にかかってしまうという問題点がある．

このような目視による外観検査を自動化することは非常に有益であるが, その安全性が保証できないため, 現在は，導入されていないケースが多い．しかし，全ての部品から一部の不良部品を検査のラインから省くだけでも検査員に対する負担は大きく減らせると考えられる．

そこで，本研究では，目視に代わる新たな自動撮影手法の提案とその撮影された画像に対して物体検出技術を用いた異常検知モデルの構築，および，その性能についての検証を行うことを目的とする．なお，本研究では, 工業製品上の傷を異常部位と位置付けている．

*　電子工学科 教授
**　機械工学科 教授

2. 提案する自動撮影手法

本研究では，2 種類の新しい自動撮影手法を提案する．また，今回の実験装置に使用する部品は既製品を使用し，容易に構築できるようにしている．

2.1 3D プロジェクションマッピング照明を用いた自動撮影

目視で部品の傷を検出するには，照明に対して部品の角度を変更しながら，傷が浮かび上がるのかどうかを確認している. 本手法では, 部品を動かすのではなく, 部品を固定して，照明を移動させることで同等の効果が得られるのではないかと考えた．図 1 に実験装置の概要を示す．

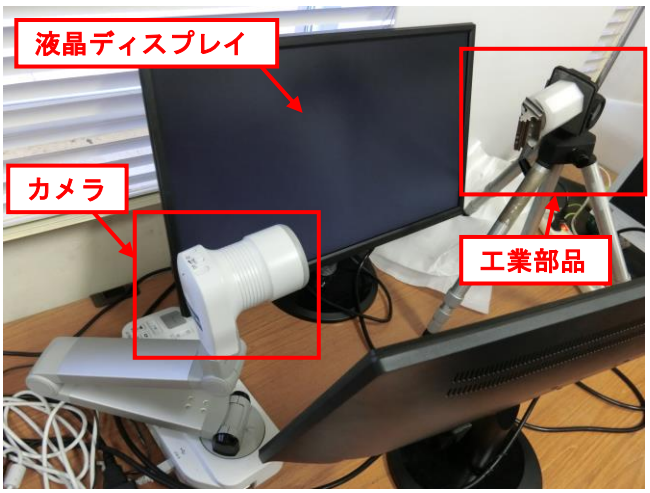

図 1 プロジェクションマッピング照明実験装置

今回の実験装置には，実際の現場で使用されているカメラ(書画カメラ)と照明には液晶ディスプレイを用いた．次に，照明を移動させる方法としては，液晶ディスプレイ上で任意の形の図形（四角形や丸など）を描画させ，その位置を変えて連続的に描画することで実現している(図 2 参照)．この手法を本研究では，3D プロジェクションマッピング照明と名付けた．この 3D プロジェクションマッピング照明を用いることで，照明をあらゆる位置から部品に当てることが可能となっている．また，照明の光の形や色についても容易に変更でき，照明の移動方法も容易にプログラミングなどで実装できるという利点がある．

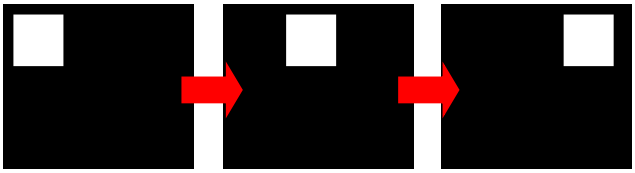

図 2 液晶ディスプレイを用いた照明の移動方法

2.2 プロジェクタとマイコンボードを用いた自動撮影

2.1 節で提案した手法は，部品を固定し，照明を移動させたが，今回提案する手法は，実際の目視の検査の時と同様に，照明を固定し，部品を傾けつつ，自動撮影を行う方法である．図 3 に実験装置の概要を示す．

図 3 マイコンボードを用いた自動撮影装置

本実験装置では，工業備品をサーボモータに固定し，サーボモータは Arduino を搭載したマイコンボードで制御を行っている．カメラについては，2.1 節で使用したものと同じものを使用し，照明には，液晶ディスプレイでは部品全体に光を当てるには照度が足りないため，広い範囲に満遍なく光を当てることのできる DLP 方式のプロジェクタを使用した．

3. 使用する物体検出技術

現在，画像認識技術として，深層学習の手法の 1 つである Convolutional Neural Network[1]（以下，CNN）が広く使われている．しかし，この手法を用いて工業部品の傷の検出を正しく行うためには，大量の学習用画像や画像の撮影条件を常に一定に保つ必要がある．そのため，今回は，CNN ではなく，この CNN を組み込んだ YOLO[2]と呼ばれる深層学習モデルによる物体検出技術を用いる．この手法にはいくつものバージョンが存在するが，本研究では，その中でも最新の YOLOv5 と呼ばれる手法を利用して，傷の検出を行うことができるモデルを開発する．なお，YOLO を使用して傷検出モデルを作成するためには，事前に図 4 のように撮影した画像に対して傷の場所を矩形で囲み，その座標と，傷の種類のデータをテキストデータとして登録するアノテーションという作業を行い，通常の深層学習モデルと同様に学習を行う必要がある．

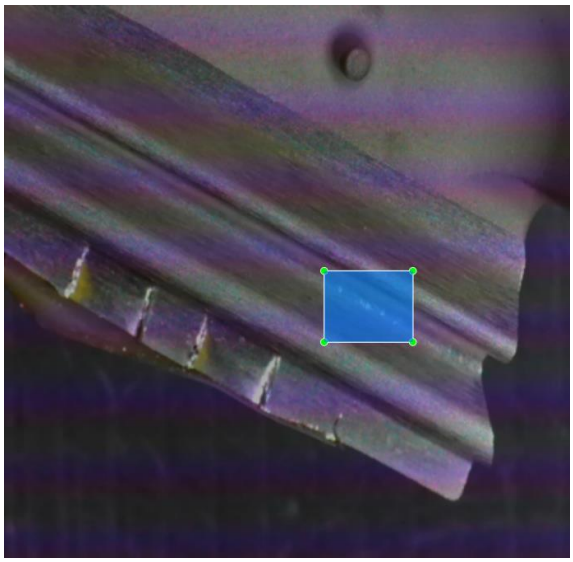

図 4 アノテーション（LabelImg ツール使用）

アノテーションによって作成された YOLO 用のラベルデータの例を図 5 に示す．YOLO は，画像データとその画像に対応したラベリングデータを使用して学習を行う．

```
0 0.722356 0.599760 0.093750 0.045673
```

図 5 ラベルデータの例(アノテーション)

図 5 において，最初の数値データは，分類に使用したクラスに対応したラベル番号が割り振られており，続く 2 つの数値は，囲んだ矩形の中心の x 座標と，y 座標，そして，最後の 2 つが，囲んだ矩形の幅と高さを表している．また，YOLO 形式では，座標の値ではなく，画像の幅と高さを用いて正規化されているため，画像サイズの縦横比を固定して拡大縮小しても検出結

果には影響を及ぼさない.

4. 実験方法

4.1 工業部品の撮影　2.1 節で提案した自動撮影手法（以下，手法 A）と 2.2 節で提案した自動撮影手法（以下，手法 B）を用いて，実際に傷のついていない工業製品（良品）と傷のついている工業部品（不良品）の撮影を行った．ただし，不良品は良品に比べて発生する数が非常に少ないため，撮影に使用できた部品も少なくなってしまった．また，不良品を提供してもらった時期が違うため，それぞれの自動撮影手法で撮影した部品は異なる種類となっている．

4.2 物体検出モデルの作成　手法 A と手法 B によって撮影した画像を用いて，傷の場所や種類についてアノテーションを行い，YOLOv5 を用いて物体検出モデルを作成した．

表 1 に, モデルの作成のために使用した画像総数と, 学習と検証用の画像枚数を示す.

表 1　撮影手法毎の画像総数，学習・検証用画像枚数

自動撮影手法	画像総数 枚数	学習画像 枚数	検証画像 枚数
手法 A	119 枚	97 枚	22 枚
手法 B	251 枚	193 枚	58 枚

また，今回学習画像枚数が少ないため，学習をスムーズに行うために学習済みのネットワークを用いて，ファインチューニングを行った．使用したモデルの規模は，入力サイズが 640×640 ピクセル，総パラメータ数は約 4650 万となっており, YOLOv5 のモデルとしては中～大規模のモデルとなっている.

5. 実験結果

5.1 手法 A を用いた自動撮影結果　手法 A を用いて撮影した画像の一例を図 6 に示す.

図 6 照明の移動による傷の撮影結果

図 6 より，左側の画像では傷が見難い状態であるのに対し，右側の画像では，傷が浮かび上がっていることが確認できる．このことから，部品を固定し，照明を移動させる手法 A の傷の撮影に対する有効性が確認できた.

一方で，照明を動かしながら撮影しているので，図 7 の上段の 2 つの画像のように照明が当たっている部分と下段の 2 つの画像のように照明が部品に当たっていないようなケースでは陰影の差が大きくなっていることが確認できた.

図 7 手法 A を用いた撮影画像例

5.2 手法 B を用いた自動撮影結果　手法 B を用いて撮影した画像の一例を図 8 に示す.

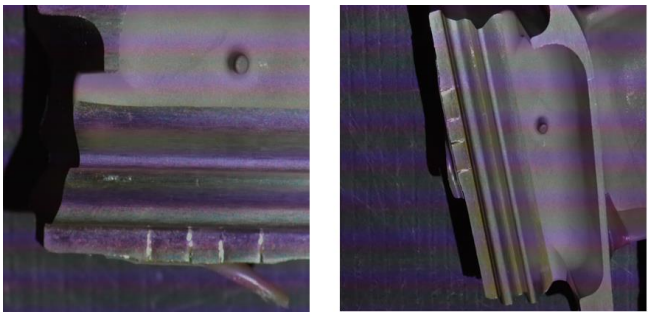

図 8 手法 B を用いた撮影結果の一例

手法 B では, 部品全体に偏りなく照明を当てながら, 部品の角度をサーボモータにより自動的に変化させているが，この手法においても傷を確認することができた．また，手法 A に比べて，照度が強く，部品に対して平行に当たる光源（DLP 式プロジェクタ）を使用しているため，部品の山と谷になった溝の部分まで鮮明に撮影が可能となっている．その際に，傷の部分については，撮影した画像内に白く浮き上がることが確認できた.

しかし，図 9 に示すように，照度が高いため，手法 A ではほとんど見られなかった白飛びが部品のエッジ

部分や，傷の周辺に見られた．特に，傷の周辺で白飛びした場合には，傷を確認できなくなることが確認できた．

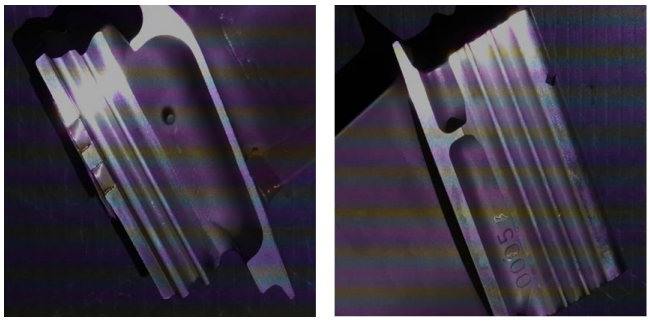

図 9 手法 B を用いた撮影結果の一例 （白飛び）

5.3 YOLOv5 を用いた傷検出結果（手法 A） 手法 A で撮影した画像 119 枚のうち，学習用画像として 97 枚，残りの 22 枚を学習後のモデルの検証用画像として用いた．学習終了後の傷検出モデルを用いて，傷の検出を行った結果の一例を図 10 に示す．

図 10 検出結果の一例 (手法 A)

図 10 より，傷の場所に矩形（ボックス）が表示され，傷が検出できていることが分かる．なお，矩形の上部に Scratched と記載されているのが検出用に使用したクラスのラベル名で，その横の数値は，矩形で囲んだ部分が正しいラベルのものであることを確率で表しており，0.00～1.00 の範囲の数値を取る．

今回使用した検証用画像 22 枚のうち，検出できなかったのは，3 枚であり，検証画像に対する検出精度は，86.3%となった．本来であれば，検証用以外にもテスト用画像を準備する必要があるが，画像の総数が少なかったため，手法 A のケースについては，テスト用画像は準備していない．

次に，検出できなかった画像の一例を図 11 に示す．

図 11 傷の検出できなかった画像例

図 11 は照度が低く，目視では傷が浮かび上がっていないように見える．他の検出できないケースについても同様の結果であった．

5.4 YOLOv5 を用いた傷検出結果（手法 B） 手法 B で撮影した画像 251 枚のうち，学習用画像として 193 枚，残りの 58 枚を学習後のモデルの検証用画像として用いた．また，テスト用画像として別途 22 枚を用いて，検出結果を確認した．

学習終了後の傷検出モデルを用いて，傷の検出を行った結果の一例を図 12 に示す．

図 12 検出結果の例 (手法 B)

今回使用した検証用画像 58 枚のうち，検出できなかったのは，16 枚であり，検証画像に対する検出精度は，72.4%となった．また，テスト用画像 22 枚に対して検出できなかった枚数は 6 枚となり，テスト画像に対する検出精度は 72.7%となり，検証結果と差はないことが分かった．

次に検出できなかった画像の例を図 13 に示す．

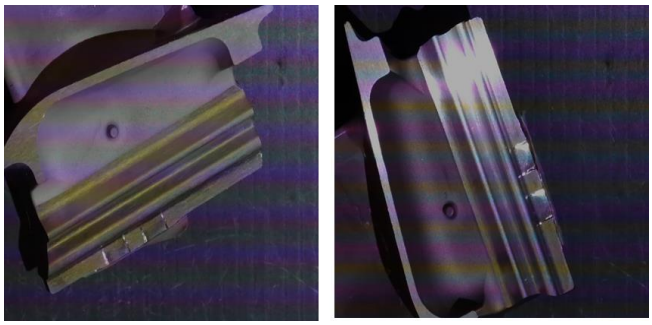

図 13 検出できなかった画像例（手法 B）

図 13 の左側の画像は，目視で確認しても傷が確認できないような画像であり，右側の画像については，手法 B の問題点である白飛びが発生している．今回，傷の検出ができなかった他の画像についても同様の傾向が見られた．

6. まとめ

今回提案した 2 種類の自動撮影手法は，どちらの手法においても工業部品の傷を撮影できることが確認できた．

手法 A については，撮影した画像の照度が全体的に低いという特徴はあるが，傷の検出については照明を移動させることで検査員が部品を照明に対して手で動かし，傷を確認するケースと同等の成果が得られた．

手法 B については，手法 A に比べて撮影した画像の照度が高いといった特徴と，部品全体に照明を当てることができるため，広範囲にわたって一度に傷を検出することができるといった特徴があることが分かった．

また，今回 YOLOv5 を用いて作成した傷検出モデルについては，手法 A については 86.3%，手法 B については，検証用，テスト用画像，共に約 72%といった検出精度結果を得ることができた．

最期に，今回提案したシステムを実際の現場の目視による外観検査と置き換えるには，もう少し高い精度が必要であると考えられる．しかし，現時点のモデルにおいても，検査の上流工程などで使用することで，70～80%程度の不良品をあらかじめ除くことができるため，下流工程の検査員の負担軽減は行えると考えられる．

謝辞

本研究の一部は上村アドバンスド・テクノロジー株式会社による奨学寄附金の支援を受けて進められました．ここに謝意を表します．

参考文献

(1) Masakazu Matsugu, Katsuhiko Mori, *et al.*: “Subject independent facial expression recognition with robust face detection using a convolutional neural network”, Neural Networks, Vol.16, No.5, pp.555–559, 2013

(2) Joseph Redmon, Santosh Divvala, *et al.*: “You Only Look Once: Unified, Real-Time Object Detection”, Conference2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Vol.1, pp.779-788, 2016