

AI による工業用ガラス部品の外観検査法の開発

増田 正人^{1*} 三澤 基宏² 川口 剛³ 中林 靖¹ 田村 善昭¹

Development of Visual Inspection Method for Industrial Glass Components using Artificial Intelligence

Masato MASUDA^{1*} Motohiro MISAWA² Go KAWAGUCHI³

Yasushi NAKABAYASHI¹ Yoshiaki TAMURA¹

1. はじめに

カメラなどのレンズでは、被写体の像を捉える凸レンズや凹レンズを組み合わせ CMOS センサなどで投影物の画像をキャプチャする。しかしながら、センサに取り込まれる光は日中では多くの赤外線が含まれ、その影響で撮影画像の色調に乱れが生じてしまう。そのため、赤外線を遮断するフィルタ(IR カットフィルタ)をレンズとセンサの間に設け、肉眼でとらえた色調と同等の画像を保存する¹⁾。カメラレンズより小さな部品であり、この IR カットフィルタに小さな傷や汚れなどの欠損があるとカメラで保存する画像に大きな不具合を生じさせる。IR カットフィルタの製造過程で、一定の割合で欠損部品は生産されてしまう。従来、欠損部品は目視により不良品の除去を行っている。そこで我々は人工知能技術(AI)をもとに良品不良品の判別システムの開発を行う。

一般的に食品の製造ラインでは AI による外観検査をよく目にする。製品のパック詰め時の過不足や、製品の欠損などを判別し製造ラインから除外するシステムである。これらはある程度の形や大きさと物体が写る領域などがわかっており、マスク画像を作りやすいから可能となる部分が多い。対して、IR カットフィルタなどの精密部品は微細な傷や汚れが製品の品質に直結するため、物体を認識するのではなく、点や線を検出し、それが不良なのかを判別するシステムが必要なり、一般的な外観検査と比べると非常に難しい問題となる。

本研究では欠損ありを Positive、欠損なしを Negative

とした場合、求められる水準として、疑陽性がなく正解率が高くなるような判別器が求められる。AI の予測結果が欠損なし Negative で、実際の正解は欠損あり Positive の偽陰性(FP)の場合では不良品流出となってしまいうため認められない。そのため、疑わしい部品は欠損ありとして検知しなくてはならない。さらに AI が予測した不良品のうち IR カットフィルタのどの部分に不良箇所があるのかというのも品質管理の点から求められる。本稿では、IR カットフィルタの画像から良品と不良品を判別するための AI 技術を確立し、その精度を検討する。

2. 画像認識技術による不良品判別法

本研究では製造された IR カットフィルタの画像を畳み込みニューラルネットワーク(CNN)²⁾を用いて不良品判別を行う。CNN の入力には図 1 のような IR カットフィルタ一枚を捉えたカラー画像を与える。出力には不良の種類を傷、汚れ、水汚れの 3 種である。IR カットフィルタの画像は 2592×1944 ピクセルであり、フィルタを支える留め具が移りこみ、対象とするフィルタ以外の関係のない領域も映っているため、CNN の学習用画像としてフィルタが中央に配置されるように 1920×1920 の画像サイズにトリミングを行った(図 2(a))。さらに 1920×1920 の入力画像は CNN で扱うには大きいので、64×64 の小領域に分割した。CNN ではこの小領域に不良の 3 種が含まれるか否かを推定させる。学習の出力データはタナカ技研で収集した不良品のマーカー画像(図 2(b))をもとに作成する。マーカー画像も入

¹ 東洋大学 総合情報学部 総合情報学科
Toyo University

² 株式会社タナカ技研
Tanaka Engineering Inc.

³ 株式会社リアルカ
Realca Co., Ltd.

*Corresponding Author: masuda061@toyo.jp

力画像と同様に 64×64 の小領域に分割し、その小領域画像内にどの種類の不良が含まれるのかを出力の値とする。出力の値は不良の種類で 1~3 とラベル付けし、ラベル 0 が不良箇所なしとした。すなわち 0~3 の 4 ラベルを出力するカテゴリ分類問題である。ここで、構成した CNN の構造を図 3 に示す。入力画像に含まれる微小の傷や汚れを検知するため、畳み込み層を 3 層として、畳み込みによる画像の抽象度を上げ過ぎないように設計している。






図 1. IR カットフィルタの画像



(a) IR カットフィルタ画像 (b) ラベル画像
(0: 白、1: 赤、2: 緑、3: 青)
図 2. トリミング画像 (1920×1920 ピクセル)




図 3. CNN の構成

3. 画像認識による不良品判別結果

3.1 学習データセット

学習には良品画像と不良品画像を含めた 335 枚の IR カットフィルタを使用する。画像は 1920×1920 であり、小領域に分割して使用する。この時、小領域サイズは 64×64 とし、画像をオーバーラップさせるためストライドは 32×32 として学習データを作成した。 64×64 の小領域に含まれる不良品の画像は 2,784 枚であり、それと同数の良品画像をランダムにピックアップし、使用する小領域画像は 5,568 枚となる。これらの画像か

ら検証データとして 1,112 枚を分別する。学習データは、画像に 90 度ずつの回転を加え学習に使用する画像の枚数は 17,824 枚とした。

3.2 学習結果

上述のデータセットを用いて、CNN で学習を行う。学習時の損失関数は categorical cross entropy、最適化関数は adadelta 関数を使用した。また、学習は 10 エポックとした。学習はおおむね良好であったが、検証データに対する acc はそれほど高くなく、検証データのうちの 6 割強程度しか正解を導き出せていない(図 4)。学習データにおいても 8 割弱程度しか正解を導出できていない。テスト用として、未学習の IR カットフィルタを入力に与え、 1920×1920 の画像内に不良箇所があるか否かを検証した。未学習画像も学習用画像と同様に、 1920×1920 ピクセルの 1 枚を 64×64 の小領域に分割、ストライドを 64×64 とし、元画像 1 枚に対して 900 枚の入力画像を生成させる。900 枚の画像のうちに良品ラベル以外が検出されれば不良品画像として、不良品ラベルが無ければ良品画像として出力するように 1920×1920 の画像 153 枚を用いて検証を行った。結果は不良品と良品の画像ともに、すべての画像が不良品の判定となった。この理由として、IR カットフィルタを支える留め具の光の反射や IR カットフィルタの淵の部分に傷だと認識されてしまうことが分かった。一方で、IR カットフィルタ内部の画像に対しては概ね良好に回答できている。このことから淵と留め具の部分を考慮した判別が必要であると考えられる。




図 4. 学習過程における loss 値と accuracy 値
(横軸は epoch 数、縦軸は loss と accuracy の値)

4. Discriminator の実装

前述の通り CNN により IR カットフィルタ内部の不良品判別はある程度できており、淵や留め具の誤検知を考慮する必要がある。そこで我々は前述の学習済み CNN モデルの出力 900 枚を 30×30 の配列に格納し、そ

の配列データから不良品か否かを判別する Discriminator を作成した。Discriminator は 30×30 の配列データを受け取り、CNN 同様に畳み込み層を用いて良品画像か不良品画像かの 2 値を判別させるネットワークである(図 5)。判別は良品か不良品の 2 値となるため、入力する配列データの数値は小領域に不良品ラベルが含まれている箇所には 1 を、含まれていない箇所には 0 を与える。30×30 の配列データは元画像の位置情報を反映した数値データであるため、空間的処理が得意な CNN でネットワークが構築できると考えた。これにより、IR カットフィルタの淵や留め具を考慮した不良品判別が可能と考えられる。




図 5. Discriminator の概念図

5. Discriminator の学習と検証

3.2 章と同様に、1920×1920 のテスト画像を 64×64 の小領域に分割し、900 枚の画像を作成する。その 900 枚の小領域画像から学習済み CNN 用いて 30×30 の配列データを作成する。学習時は 30×30 の配列データは学習画像から作成され、元画像が良品・不良品のどちらかであったのかの 2 値を出力データと与え、学習を行う。検証時では、テスト画像を同様の手順で入力データ、出力データを作成し、正答率を求める。Discriminator の正答率は 100% であった。また混同行列を用いた正答率を表 1 に示す。表 1 より FP(AI が良品と判断したが実際は不良品である、表左下の数字)の数も 0 に抑えられ、十分な結果を得られた。さらに、不良品と判断された画像のどこの領域に不良が見受けられたのかは、一つ目の CNN の結果を見ることで把握でき、不良個所のは々非々が検証できる(図 6)。

また、本稿では示せないが、他の工業部品においても同様の方法をとることで、十分な精度の外観検査が行えることが分かった。


6. まとめ

本研究では IR カットフィルタの欠損を画像認識により検知する AI モデルを作成した。本システムは 2 つの CNN を組み合わせることにより、IR カットフィルタ内の欠損を検知し不良品判別を行えることを示した。

IR カットフィルタをはじめ精密機器に使用される工業用部品ではミリメートル、マイクロメートルオーダーの検知器が必要であり、画像としては数ピクセルの異常を検知しなければならない。本研究での画像認識技術は、一般的な物体認識技術とは異なり、抽象度を上げすぎないことで微細な傷や汚れを検知するシステムである。本研究の成果は同様の工業用部品や微細な損傷の検知が必要な事象にも応用が期待できる。

表 1. Discriminator の予測結果の混同行列

IR カットフィルタ (内部)		Predicted	
		良品	不良品
Actual	良品	73	0
	不良品	0	80

図 6. AI 予測による不良ラベル検出画像
(赤枠:不良品ラベルを含んでいる領域と認識)

謝辞

本研究は 2019 年度に埼玉県 AI を活用した機器等開発・実証補助事業として、「光学ガラス部品及び金属加工部品に関する外観検査サービス提供基盤の開発」の事業テーマで実施され、2020 年度以降は株式会社タカ技研との共同研究にて実施した研究である。

参考文献

- 1) IR カットフィルターとは何か、なぜ組み込みビジョンアプリケーションに必要なのか? <https://www.e-consystems.com/blog/camera/ja/technologies/what-is-an-ir-cut-filter-why-do-embedded-vision-applications-need-it/>
- 2) Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks” [chrome-extension://efaidnbmnnnibpcaglgclefindmkaj/https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf)