

# ディープラーニングを利用したガラス製品の自動検査システム

## Auto-inspection system using deep-learning for glass materials

高澤 悠介\*  
Yusuke TAKAZAWA

堀江 一央\*  
Kazuhisa HORIE

\* 日本電気硝子(株) 電子部品事業部  
\* Nippon Electric Glass Co., Ltd. Electronic Products Division

As deep learning technology has been improved in recent years, it has started to be applied to image inspection process of high needs for making a high advanced automation in a factory. However, most of them are not completed by only the deep learning technology where they are installed for support of worker, in which the system inspect roughly first and then worker re-inspect in more details (resulting in benefit of saving worker compared full-worker system).

Therefore, we did not use the deep learning technology to the inspection itself, but tried to use for classification of defects by rule-based system from conventional image data. We can improve inspection level successfully which can achieve full-automatic inspection system that does not rely on inspection by worker.

## 1. 前書き

### 1.1 ディープラーニングの課題

近年、大量のデータから自動で特徴を抽出できる深層学習(ディープラーニング、以下 DL と表記)技術への期待が高まっている。現在は、第三次AIの時代と言われ、2012 年に DL 手法が脚光を浴び、AI が急速に進化した時代となっている。だが、その活用が決して簡単なものではないのも事実である。1)

財務省発表による企業の先端技術(IoT、AI、ロボット、クラウド、ビッグデータ)活用状況をみると、対象 1273 社中、AI をすでに活用しているのは 10%程度にすぎない。だが、「検討中」、「活用したくてもできない」という割合は最も高い。業種別にみても製造業は同じ傾向にある。2)

一方、我々は様々な材質、形状のガラス製品を製造・販売しており、その殆どの検査にルールベースの画像処理技術を用いている。しかしながら、判定・分類するためのルールを定義することが難しい製品は、ルールベース単独の検査ではなく、ルールベース手法にて厳しい閾値で検査を行った後、その良品または不良品を再度人の目視検査を通じて最終的な良品／不良品判定を行っている。近年、その目視検査を担っている熟練労働者は減少し、且つその技能の伝承は必ずしも進んでいない。加えて、人による目視検査は体調や環境などによるばらつきが避けられないなどの問題点もある。AI による自動検査の確立が待望される所以である。

AI はブラックボックスで信用できないという考え方が多い。しかし、熟練した検査員が官能検査を行う判断基準は第三者からするとブラックボックスである。これをわかりやすく数値化したのが従来の画像処理によるルールベースシステム(閾値による判定)であるが、それでは閾値を厳しくせざるを得ず、不良品に良品が混じってしまう。検査機において、適切な閾値を求めることが第一目標となる。

### 1.2 研究目的

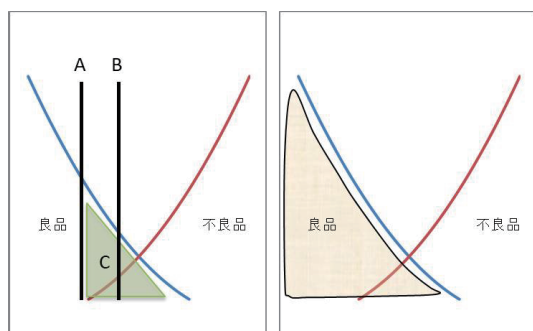
全てのガラス製品において、人による検査を排除し、自動検査機のみで検査する工程を築くことが最終目的である。その手段として、DL 技術と現状のルールベース手法を融合させることで、人による目視検査を無くし、「完全なる自動検査」を達成することを試みた。

図1は、例えば外観検査のような場合での良品と不良品、どちらも混在するそれぞれのエリアを模式的に描いたものである。X 図で示すルールベース手法による良否判定の場合、不良品を含まない位置で閾値 A を設定すると良品量は非常に少なくなり、不良品のなかに良品が多く混じる結果となる。逆に少しでも混在エリアを入れた閾値 B の場合、不良品が流出してしまう。この混在エリアをなるべく小さくし、閾値を境界ギリギリに設定することが最適ではあるものの、先のとおり目視による最終検査にはばらつきがある。

しかし Y 図に示す AI による判定ならば良品判定のみのエリアを曲線で取得できる可能性がある。AI による判定は人が判断した画像を学習し人の目に近づけることを第一とするため、一定の閾値を必要としない。これは画像を学習することで良品領域をカバーすることと同じである。それは一定の直線で仕切られるものではない。つまり DL 技術を用いることで判定の閾値ではなく、良品であるエリアを他と分類することが期待できる。

X 図に示す閾値 A で一旦判定を行った後、不良品判定された混在エリア C から、DL 技術を利用して求めた Y 図のエリアに含まれる製品があるかどうか再判定する。これは先に示した人特有のばらつきを排除した形で、限りなく人の目に近い検査となりえる。

我々の製品の中で、特に自動検査機での良品率が目視検査と比べて低い「ある管ガラス製品」を選択し、DL 技術を自動検査システム内に取り込むトライアルを行った。ここで「良品率」とは、実際の製品の良品率ではなく、自動検査機で良品と判定された割合をいう。つまり、自動検査機での良品率と実際の製品の良品率との差が大きいほど、自動検査機にて不良判定された製品の中により多くの良品が含まれているということである。



X. ルールベース手法による良否判定 Y. DL 技術を用いた良否判定

図 1. 良品、不良品およびそれらが混在するエリア

DL 技術を良品／不良品検査そのものに用いるのではなく、従来の画像処理によるルールベース手法にて検出した欠陥を正確に分類させることに用いた。結果、従来のルールベース手法による検査レベルを向上させることができ、より人の目に近い検査システムとして構築し、自動検査機にそのシステムを導入させることができた。以下に詳細を報告する。

## 2. システムの概要

今回提案したシステムについて説明する。DL 技術を不良の原因となる欠陥の分類に利用した。現状のルールベースの自動検査では欠陥の分類が正確にできない。そのため、最も流出させてはならない欠陥の閾値にすべて統一して運用している。そのため、比較的閾値が甘い欠陥では過剰に不良として判定してしまい、自動検査機での「良品率」を著しく低下させていた。今回考案したシステムのフローを図 2 に示す。

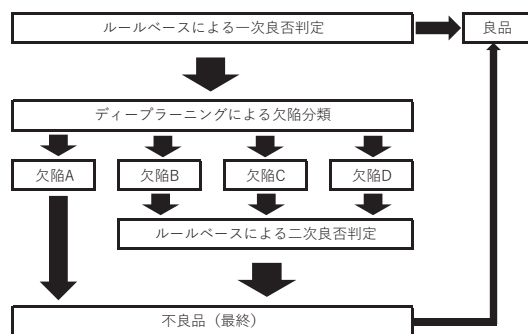


図 2. 考案した検査システムフロー

今回トライした管ガラス製品の欠陥数は A～D の 4 つである。まず、既設のルールベースによる一次良否判定を行う。ここでは欠陥サイズとしての閾値が最も小さい、欠陥項目 A の閾値で欠陥 B～D も判定しているため、欠陥 B～D の中には通常は良品でも不良品と判定されるものが混在している。そのため一次良否判定にて良品と判定されたものは確実に良品となる仕組みである。

次に、一次良否判定にて不良品と判定されたものの欠陥画像を抽出し、その画像を用いて DL 技術により学習させる。詳細な抽出、学習手法については後の章で述べる。学習させたモデルを検査ソフトに導入し、一次良否判定にて不良品と判定された欠陥画像を A～D にそれぞれ分類する。分類された欠陥画像について、ルールベースによる二次良否判定にてそれぞれに適した閾値で良否判定を行う。ただし、欠陥 A のみ、一次

良否判定にて最適な閾値で判定されているため、DL 技術にて欠陥 A と分類されたものについては、二次良否判定の必要がなく、全て不良判定とする。

このように、一次良否判定→DL 技術を用いた欠陥分類→二次良否判定を経て、最終的に良品／不良品を行うシステムを構築した。

## 3. 画像抽出手法

一次良否判定に用いる画像サイズは、 $1800 \times 1024$  (pix)。従来のルールベースによる画像処理を行った結果、検出された欠陥領域を中心に  $500 \times 500$  (pix) の面積で画像を切り取る。この画像を DL 技術による学習画像データとして使用する。

学習画像データは微細な特徴をとらえるため TIFF 形式による無圧縮画像を用いる。また、欠陥領域を中心に据える都合上、切り取り範囲が元画像内に収まらない場合、輝度 0 の黒い背景を補完し面積をそろえる。

$500 \times 500$  (pix) の面積にする理由は各欠陥が十分に収まるサイズだからである。欠陥によっては線状の長さや途切れ具合、欠陥端部や周囲の状況が特徴の一部となっている。

## 4. 学習手法

上記により抽出された画像を用いて DL 技術を用いて学習させる。抽出した画像は予め最も熟練された検査者にて上記 4 種類の欠陥分類を行う。

DL の開発エンジンは、市販されている一般的なものを使用した。学習用画像については、できるだけ同数の画像を準備し、学習させることとしたが、出現頻度が異なるため、画像を一定の条件で水増しさせる処理を行い、各欠陥画像について、最終的にそれぞれ約 1000 枚の画像を用いて学習させた。

図 3 に欠陥 A～D について、典型的な画像を示す。

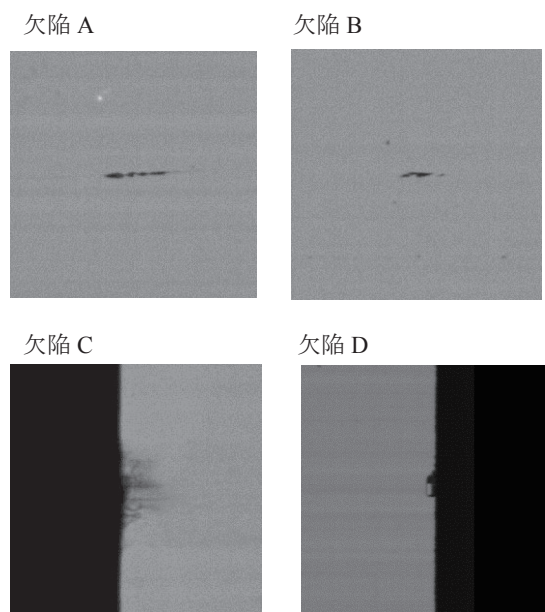


図 3. 欠陥画像 (A～D)

画像の水増し条件は、欠陥毎に異なる。欠陥 C と欠陥 D はそれぞれ発生する場所が決まっている。C は製品の左端、D は右端、このためこれらについては上下の反転画像を作成するのみで左右の画像は作成しない。一方、欠陥 A と B は発生する場所に際限がなく上下左右の鏡像以外に 180 度回転させた画

像を作成した。また製品によって若干の色味が異なる場合があり輝度が一定でないことから、それぞれの画像に対して 20% の範囲で輝度変化をランダムに変更した画像を作成し学習画像とした。

## 5. 学習結果

図 4 に欠陥分類の正解率の推移を示す。

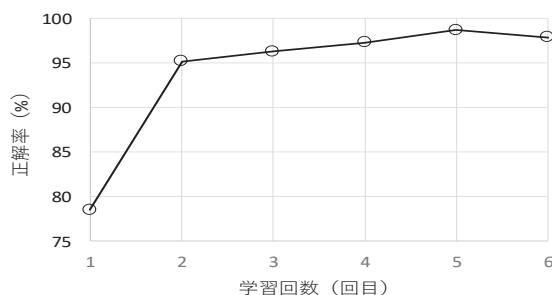


図 4. 欠陥分類の正解率(%)

図 4 より、学習回数が 4 回目を超えると、正確率が 97% 以上と非常に高い正解率を維持することが確認できた。本学習モデルを自動検査機に導入して、実検査にて効果を確認した。

なお正解率は高水準ではあるものの、誤分類をケアするために以下に示す 3 つのルールベースによる処理を行った。

- ・欠陥数の限度:  
1 ワーク中に一定数以上の欠陥が見つかり、分類判定前に不良品として判定する。
- ・欠陥の個別判定:  
致命的な欠陥 A は分類され次第、他の欠陥を考慮せず不良品とする。ワーク内に複数欠陥があった場合、たとえ一つが誤った分類を行っても致命的な欠陥判定 A が一つでもあれば不良品判定とする。
- ・信頼度の閾値:  
Softmax 関数の結果の値(信頼度)が一定値以上でないとその判定を使わない。

## 6. 自動検査システムの効果

図 5 に実自動検査機に本システムを導入し、検査テストを行った結果を示す。

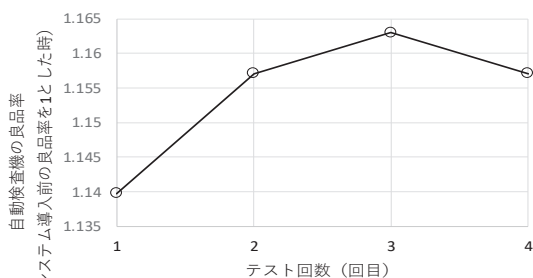


図 5. 自動検査機の良品率

図 5 より、テスト回数が 2 回目より、導入する前と比較して自動検査機の良品率が約 15% 以上向上することが確認できた。こ

のように本システム導入により、自動検査機自体の性能を飛躍的に向上させることが期待できる。

## 7. まとめ

我々の製品の中で、特に自動検査機での良品率が低い「ある管ガラス製品」を選択し、DL 技術を自動検査システム内に取り込むトライアルを行った。DL 技術を良品／不良品検査そのものに用いるのではなく、従来の画像処理によるルールベース手法にて検出した欠陥を正確に分類させることに用いた。結果、従来の手法による検査レベルを向上させることができ、より人の目に近い検査システムとして構築し、自動検査機にそのシステムを導入させることができた。

今後、様々なガラス製品に適用しうる汎用システムとなり、人による目視検査撤廃に向けて有効な手段となることが期待できる。

## 8. 最後に

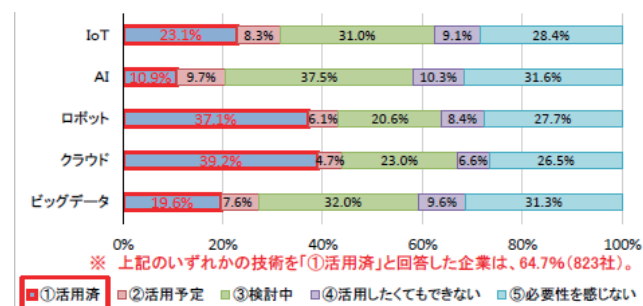
本システムを開発する中で発見された興味深い事例を紹介したい。ある程度学習が進んだモデルに誤ったラベルのサンプルを判定させると、信頼度が高い状態で正確な判定を行ってくれる。これは仮に誤ったラベルによる教示を行っても AI はその誤りを指摘してくれることにほかならない。

この判定を用いて、先の図1の混在エリア C にあるワークの特徴をより明確に定義し撲滅できる可能性がある。良否があいまいな製品の是非を議論する余地ができるのだ。

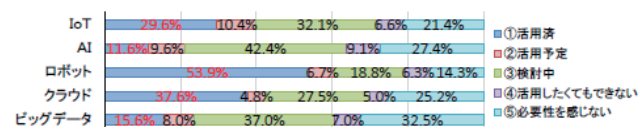
AI を導入することで、いきなり完全な自動検査機はできなくとも教示画像を整理する中で、検査すべき対象がより明確になることは、現場を巻き込み、より良い検査機を作るうえで重要な要素であると思う。

## 参考文献

- 1) 高野 敦: NIKKEI ELECTRONICS 2018.05
- 2) 財務省 財務局調査による「先端技術 (IoT、AI 等) の活用状況」について (平成 30 年 11 月)



先端技術の活用状況について (回答社数: 1273 社)



上記のうち製造業の場合

以上