

## フーリエ変換と CNN による医薬品包装の外観不良検出

## Defect detection for pharmaceutical packaging using Fourier transform and convolutional neural network

福島 誠人<sup>†</sup>  
Masato Fukushima

波部 斉<sup>†</sup>  
Hitoshi Habe

## 1. はじめに

医薬品は機械で自動的に高速かつ大量に製造されている。大量生産された中には不良品が含まれるので、それを誤って出荷しないように、取り除く必要がある。不良品を見付けるためには、目視による確認、カメラなどによる自動外観検査が行われているが、より精度の高い検査機が求められている。自動で不良品を発見するためには、外観を撮影した画像を用いることが有用といえる。画像中の不良箇所の見え方は多岐にわたるため、画像処理でその有無を判断するための条件を書き下すことは困難である。そこで、不良品・良品画像のサンプルから機械学習によって識別規則を得ることが望ましいと言える。

本稿では、図 1 に示すような医薬品のシール部分を切り取ってフーリエ変換を行い、そこから得られたパワースペクトルを CNN に適用し識別する手法を提案する。CNN (畳み込みニューラルネットワーク) は、近年物体認識技術において古典的な手法よりも優れている事が証明されており、外観不良検出においても有用である事が期待できる [1]。福島らは、CNN のネットワーク構造・前処理の有無を比較し、前処理を行なった画像に CNN を適用させる手法が有効であることが示した [2]。しかし、前処理の実験が不十分であり、CNN の有効性が示されているが、他の識別器との比較実験が行われていない。本稿では、いくつかのパターンの前処理を比較し、さらに古典的な識別器である SVM と比較し、提案手法が有効であることを示す。

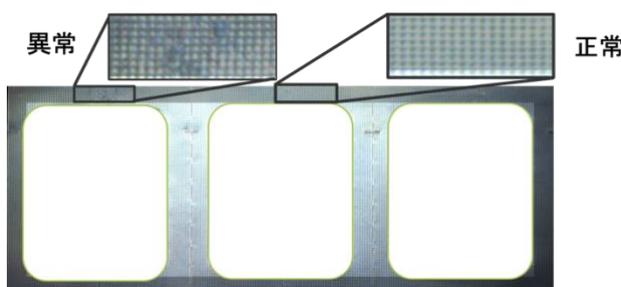


図 1 正常・異常箇所の例

## 2. 関連研究

外観検査において、CNN, Autoencoder を用いて不良品を検出する手法が提案されている。本研究と関連するものとして、Racki らは、人工的に生成されたテクスチャ加工されたデータを対象とし、異常・正常をセグメンテーションし、それを CNN で識別を行っている [3]。その結果、識別率が高く、ロバスト性があると証明されている。しかし、対象としているのは、識別しやすいように加工されたデータセットを用いており、実世界を想定した場合、照明の影響、ノイズが入っているなどが考えられるので、

セグメンテーション結果を利用し検出すると識別率は著しく下がる事が考えられる。

また、Yundong らは、周期的なパターンを持った布とジャガードパターンを持つ布を対象とし、Fisher Criterion を基にした Stack Denoising Autoencoder (SDA) を用いて画像を再構成し、生成した画像と元画像の差を計算し異常・正常かどうかの識別を行い、閾値処理し異常箇所の特定を行っている [4]。その結果、識別率が高く、識別スピードが早く実環境での使用する為の条件を十分に満たしている事が証明されている。しかし、この論文の対象のデータより本稿で使用しているデータは、照明の影響を受けやすいので、SDA で再構成された画像に影響を受ける事が考えられ、再構成画像と元画像の誤差を用いる手法では識別率が低下する事が考えられる。

以上より本稿では、医薬品の正常・異常を見極める手法として CNN を用いる。

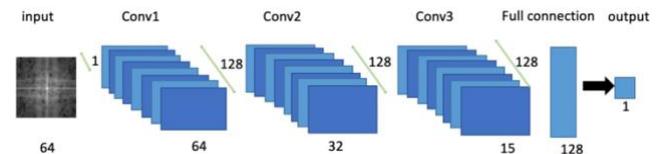


図 2 CNN のネットワーク構造

## 3. 提案手法

この章では、提案手法について説明する。以下にその詳細を述べる。

## 3.1. CNN

畳み込みニューラルネットワーク (CNN) とは、畳み込み層を導入したニューラルネットワークのことである。CNN を含めたネットワーク全体の学習では、特徴抽出を含めたパラメータを最適化するため、高い汎化性能を得ることができる。

一般に、学習データが少ない場合に、層の深い複雑なネットワークを用いると、過学習によって精度が低くなるリスクが高くなるので、可能な限り単純なネットワークとすることが望ましい。今回の医薬品包装の検査でも、準備できるデータには限りがあるため、CNN の構造は可能な限り単純なものとし、図 2 のようなネットワーク構造を用いた。図 2 では、画像のサイズやフィルターの枚数やネットワーク構造を示している。input は入力画像を表しており、サイズは幅・高さ 64 のフーリエ変換画像をパワースペクトルで表した画像を用いている。Conv1, Conv2, Conv3 は畳み込み層を表している。この層では、ReLU・MAX プーリング層を適用し、入力画像から特徴量を抽出している。Full connection は、全結合層を表している。この層では、畳み込み層で抽出された特徴を用いて識別処理を行い、ソフト

マックスクロスエントロピーを用いて、誤差が最小になるように学習を行っている。

### 3.2. フーリエ変換

図1を見ると、正常箇所には格子が規則的に並んでいる事が分かり、規則的なパターンを持つテクスチャに有効なフーリエ変換を用いる事を提案する。

フーリエ変換は、主にテクスチャ解析に利用されており、物質・材質の違いを濃淡パターンを用いて表現する事が可能である。図3では、異常・正常画像に対して、フーリエ変換を行い、それをパワースペクトルで表現した画像を示しており、異常画像は格子が潰れているので、正常と比較するとパワースペクトル画像の中心付近では、格子がぼやけていることが分かる。

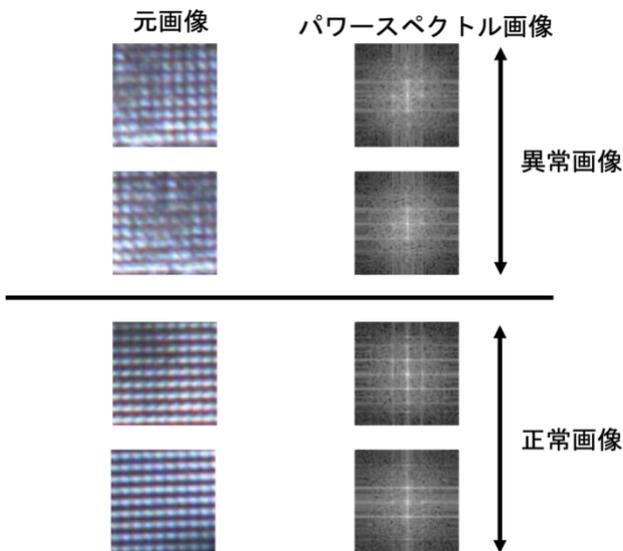


図3 異常・正常画像をフーリエ変換し、パワースペクトルで表した画像

## 4. 実験

提案手法の有効性を確認するための実験を行った。以下にその詳細を述べる。

### 4.1. 実験に用いる画像

実験では、医薬品のサンプルを用意し、それをカメラで撮影し、提案手法の学習・テストに用いる画像を28枚得た。図3にその例を示す。図4では不良検査の対象となるシール部分以外をマスクしている。先に述べたとおり、提案手法は幅・高さ64の部分画像を単位としてフーリエ変換し、パワースペクトルで表現した画像をCNNに入力して不良の有無を識別する。切り出してフーリエ変換した例を図3に示す。28枚の画像についてこの処理を行って、異常時のサンプルを622枚、正常時のサンプルを11379枚得た。

### 4.2 実験内容

1章で述べたように、福島ら[2]は、前処理を行った画像をCNNに適用することが有効である事が示されているが、前処理の実験が少なく、CNN以外の識別器を用いて比較実験が行われていないので、本稿では、以下のような実験を行う。

- ・前処理の違い：前処理としてフーリエ変換を行う他にソーベルフィルタを用いる場合との比較を行う。

- ・識別器の比較：先に述べたように、古典的な手法のSVMと比較を行う



図4 RGB画像

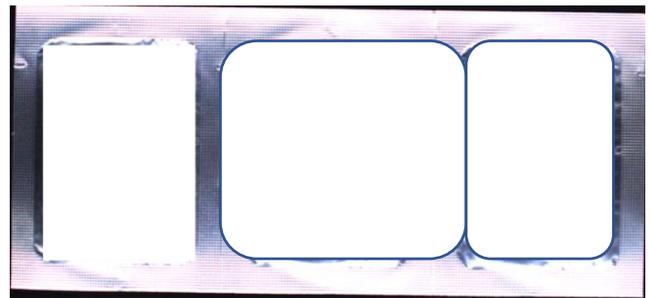


図5 照明の影響を強く受けた画像

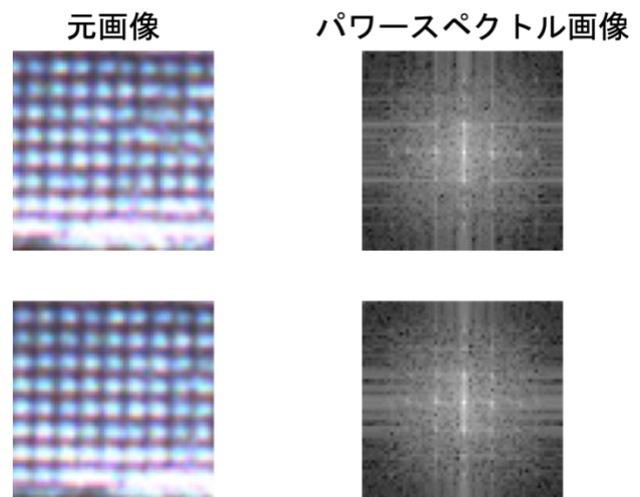


図6 異常箇所を正確に識別できた例

### 3.3 実験結果

以下に述べるすべての実験に共通して、3.1節で述べたようにサンプル画像から抽出した64×64の部分画像にフーリエ変換を行った画像を処理対象とし、CNNの学習にその80%を、テストに20%を用いた。図5のような画像では、照明の影響を強く受けていることが分かる。その影響は正常箇所も多く、不良検出の妨げになることが考えられるので、学習に使用する正常と異常データ数の割合を異常の割合を多くし、テストでは、実環境での検査を想定し、切り取られた画像全てを使用している。また、表では正常・異常データの検出における再現率を示している。

#### (1) 前処理の違いの影響

図6は、前処理でフーリエ変換を用いた場合は異常と正確に識別できたが、ソーベルフィルタを用いた場合は、正常と誤識別してしまった画像を示しており、表1は、不良の有無の識別精度を示している。実験に使用した画像は、図5のような照明の影響を強く受けた画像が多く、ソーベルフィルタはその影響を抑えながら輪郭を抽出する手法

であるが、照明の影響が大きく輪郭抽出をうまく行えなかった為、精度が低下したと考えられる。しかし、フーリエ変換では、図 6 のパワースペクトル画像を見ると、格子がぼやけているので、照明の影響を受けても正確に識別できたと考えられる。

表 1 前処理の違いの影響

| 前処理       | 異常    | 正常    |
|-----------|-------|-------|
| フーリエ変換    | 83.54 | 87.32 |
| ソーベルフィルター | 67.72 | 79.60 |

## (2) 識別器の違いの影響

図 7 は、SVM では異常と誤識別したが、CNN では正常と正確に識別された画像を示しており、表 2 は不良の有無の識別精度を示している。図 5 のように照明の影響を強く受け、図 6、図 7 のように照明の影響でパワースペクトル画像の格子の表れ方が異なるので、SVM は識別が困難だと考えられる。一方、CNN では照明の影響を受けても高い識別精度である事が分かる。

表 2 識別器の違いの影響

| 前処理 | 異常    | 正常    |
|-----|-------|-------|
| CNN | 83.54 | 87.32 |
| SVM | 83.00 | 33.00 |

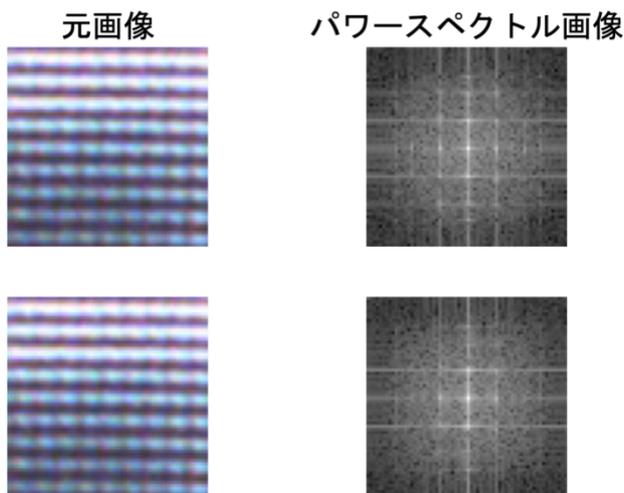


図 7 正常箇所を正確に識別した画像

## 4. おわりに

本稿では、フーリエ変換と CNN を組み合わせた手法を提案し、その有効性を確認した。今後は、データを増やして、提案手法の有効性を確認することや、実システムへの適用などが挙げられる

## 参考文献

- [1] LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P., "Gradient-Based Learning Applied to Document Recognition," IEEE, Vol. 86, No. 11, pp. 2278-2324, 1998.
- [2] 福島 誠人, 波部 斉, 井森 健一, 菊地 正樹, "機械学習による医薬品包装の外観不良検出", 情報処理学会, 2018.
- [3] Domen Racki, Dejan Tomazevi, Danijel Skocaj, "A

compact convolutional neural network for textured surface anomaly detection", IEEE, 2018.

[4] Yundong Li, Weigang Zhao, Jiahao Pan, "Deformable Patterned Fabric Defect Detection With Fisher Criterion-Based Deep Learning", IEEE, VOL. 14, NO. 2, 2107.