

機械学習による医薬品包装の外観不良の検出

Defect detection for pharmaceutical packaging using machine learning

福島 誠人[†]
Masato Fukushima

波部 斉[†]
Hitoshi Habe

菊地 正樹[‡]
Masaki Kikuchi

井森 健一[‡]
Kenichi Imori

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どうしても出てきてしまうが、それを誤って出荷しないように、不良品を取り除く必要がある。不良品を見付けるためには、目視による確認や、カメラなどによる自動外観検査が行われているが、いずれも現状では 100%の精度は得られないので、より精度の高い検査が求められている。

本稿では、図 1 に示すような医薬品のシール部分の噛み込みを機械学習によって自動検出する。そこでは、カメラで撮影した画像に噛み込みが存在するかどうかを、畳み込みニューラルネットワーク (CNN) を用いて識別する。CNN を用いると、様々な画像認識において高い精度が得られることが知られており、外観不良の検出においても有用であると期待される。CNN を用いた識別の際には、ネットワークの構成が結果に大きく影響するため、本稿ではいくつかのパターンで有効性を検証した結果を示す。




図 1 医薬品のシール部分に発生する噛み込みの例

2. 提案手法

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 32 の RGB 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、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う。今回は異常か正常かのどちらかである。このような処理によって最終的に出力層 output から識別結果を出力する。畳み込みニューラルネットワークの構造の最適化で行われる計算は、基本的には掛け算の繰り返しなので、入力データ (画像の輝度) が大きすぎたり小さすぎたりすると値が小さくなったりしてうまく最適化できない。次節以降で述べるように、今回用いる画像の照明度は照明条件によって変化するので、入力画像を平均 0 に正規化する Mean Subtraction layer を用いた。そして、CNN は過学習が起こりやすいので、それを抑制するために Drop layer を用いた。




図 2 CNN のネットワーク構造

3. 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。

3.1 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て提案手法の学習・テストに用いる画像を 20 枚得た。図 3 にその例を示す。図 3 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 32 の部分画像を単位として CNN に入力して不良の有無を識別する。図 3 のような画像からシール部分を切り出し、それに噛み込みが含まれていれば異常、そうでなければ正常のデータとして扱う。20 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 2160 枚、正常時のサンプルを 44119 枚得た。その例を図 4 に示す。



図 3 RGB 画像

[†]近畿大学, Kindai University

[‡]株式会社アイエムイー




図4 正常箇所と異常箇所の例

3.2 実験での比較対象

CNN を含むニューラルネットワークの構造を変化させると精度が大きく変化する可能性がある。また、今回用意したサンプル画像は、照明条件が大きくことなるものが含まれているので、照明条件の変化が精度に影響を与える可能性がある。これらの影響を明らかにするため、本稿では以下のような点を変化させて実験を行い、その結果を示す。

- ・ ネットワークの深さ：図1に示すようにCNNは3層構造としているが、他に2層・5層での結果と比較する
- ・ 照明条件：サンプル画像は照明が明・暗の2通りで撮影したため、明・暗それぞれのみを用いた場合と、すべての画像をまとめて用いた場合と比較する
- ・ 前処理の有無：2節で述べたように MeanSubtraction (以下、MS) を前処理として行うが、その妥当性をみるために、MSを行わない場合との比較を行う

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32×32の部分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。いずれのデータも正常データと異常データの割合を1:1にしている。また、グラフでは異常データの検出における適合率、再現率、精度(F値)を示している。

(1) ネットワークの深さの違いの影響

ネットワークの深さを変化させた場合の結果を示す。図5がネットワークの深さを2層、3層、5層とした場合の結果を示している。これらの結果はネットワークの深さ以外の条件は揃えたものである。これらを見るとネットワークが3層の場合の精度が良いことが分かる。

(2) 撮影時の照明条件の影響

次に、撮影時の照明条件(明・暗)ごとに学習・テストを行った場合と、すべてのデータをまとめて学習・テストを行った場合の結果を図6に示す。ここで




図5 ネットワークの深さの精度への影響




図6 照明条件の精度への影響

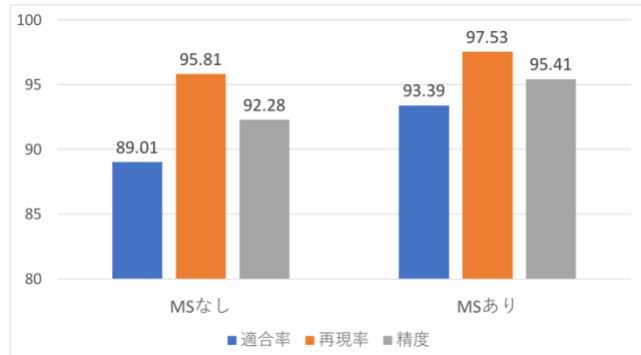


図7 前処理の有無の精度への影響

も、その他の条件は揃えて実験を行った。一般に、照明などの条件を揃えた方が識別精度が良くなると言えるが、今回は照明条件を揃えずに、すべての画像をまとめて学習・テストを行ってもそれほど精度低下がみられなかった。これは前処理の効果であると考えられる。

(3) 前処理の有無

図7に前処理で行ったMSの有無による精度の変化を示す。ここでも、MSの有無以外の条件は変化させていない。この結果からは明らかにMSによって精度が向上していることが分かる。図7の結果は先の(2)の中でもすべての照明条件をまとめて学習・テストを行ったものに相当する。(2)で述べた照明条件の変化をMSによって吸収できていることがここからも分かる。

以上をまとめると、2.節で述べた提案手法が不良検出に有効であることがわかる。また、提案手法は照明条件が異なる対象画像が混在していても良好な結果を示すことがわかった。

4. おわりに

本研究では、CNNによって医薬品包装の不良検出を行う手法を提案し、その有効性を確認した。

今後の課題として、対象画像の種類を増やした場合の性能評価や、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.