

深層学習を用いた枝豆内の異物検知 Detection of Foreign Objects in Green Soybeans Using Deep Learning

板東 千華[†]
Chika Bando

中井 悠斗[†]
Yuto Nakai

大津 朋也[†]
Tomoya Ohtsu

山口 堅三[†]
Kenzo Yamaguchi

大野 将樹[†]
Masaki Oono

獅々堀 正幹[†]
Masami Shishibori

笹原 由雅[‡]
Yoshimasa Sasahara

石寄 雄一[‡]
Yuichi Ishizaki

青木 仁史[‡]
Hitoshi Aoki

1. はじめに

食品への異物混入は、昔から続く深刻な問題である。この問題を解決するため、近年では、深層学習を用いた異物検知が主流となっている。先行研究[1]では、枝豆を豆単位に分割し、VGG16[2]を用いて豆単位で異物を検出していた。しかし、この手法では、豆単位に異物検知するため、画像内に複数の枝豆が写っている場合、異物検知に要する時間コストが多くなる、という問題があった。そこで本研究では、画像内の異物を高速に検知できる物体検出モデルである YOLOv5[3]を使用する。また、先行研究では行っていない、ランダムな位置に配置された枝豆画像を対象に、異物が混入した枝豆を高精度で検出する。本研究では、異物有り枝豆を管理しやすくするために枝豆を整列させて撮影した画像を準備する。その後、ランダムな角度、位置に枝豆を配置した画像を自動作成し、YOLOv5 を用いて異物を検出する。さらに、様々なパターンのランダム配置画像を自動作成することで、学習データをデータ拡張し、精度向上を目指す。

2. 撮影装置

本研究では、図 1(a)のような光学撮影装置を用いて、図 2 のような画像を撮影する。この撮影装置は、試料台を 2 枚の偏光板で挟む構造となっているため、光の吸収量だけでなく偏光度の違いも用いて、異物の検出を可能にする。また、第 1・第 2 偏光板のスリットの向きを、互いに並行な状態で撮影した画像を P 画像 (図 1(b))、垂直な状態で撮影した画像を C 画像 (図 1(c)) とそれぞれ呼ぶ。

本研究では、図 2 のような、1 枚の画像に 10 個の枝豆を整列させた P 画像を使用する。また、枝豆 1 サンプルにつき、表と裏の 2 種類の画像を撮影し、図 2(a)の向きを A 面、図 2(b)の向きを B 面と定義する。

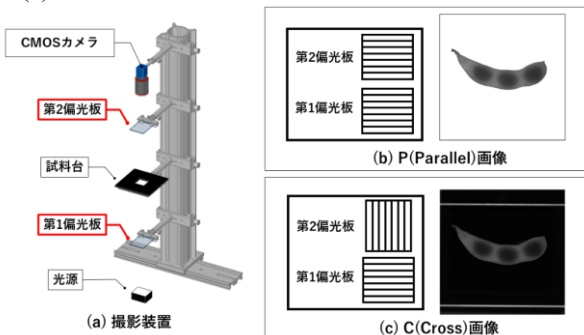


図 1 撮影装置と P 画像・C 画像

[†] 徳島大学 Tokushima University

[‡] 株式会社ニチレイフーズ Nichirei Foods Inc.




図 2 本研究で使用する枝豆 10 個の整列画像

3. 提案手法

3.1 学習データに関する問題点

YOLOv5 では画像を $N \times N$ のグリッドセルに分割し、セルごとに異物の有無を判定する。画像をグリッドセルに分割した例を図 3 に示す。図 3(a)のように整列した画像では、枝豆が横に配置されたグリッドセルのみになる。一方、図 3(b)のようにランダムに配置された画像では、枝豆が縦や斜めに配置されたグリッドセルになる。そのため、整列画像で学習したモデルは、豆部分が縦や斜めに伸びているランダム配置画像の異物有り枝豆を検出することが非常に困難である。

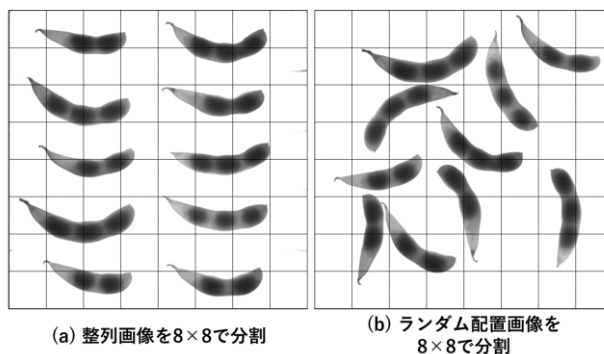


図 3 画像を 8×8 のグリッドセルに分割

3.2 学習データの作成

学習データに関する問題点は、枝豆がランダムに配置されたグリッドセルを学習することで解決できる。そのため、整列画像からランダムに配置した画像を自動作成し、自動作成した画像を学習する。整列画像からランダム配置画像を作成する流れを図 4 に示す。まず、整列画像に対して二値化処理を行い、枝豆 1 個の領域ごとに抽出する。次に、抽出した枝豆を中央へ移動させ、ランダムな角度回転させ

た後、ランダムな位置に移動させる。そして、作成した枝豆 1 個のランダム配置画像を、作成中の枝豆 10 個のランダム配置画像に追加する。すでに配置している枝豆と重複する場合、重複しなくなるまで、ランダム回転、ランダム移動させる。

この処理をすべての枝豆に対して行い、枝豆 10 個のランダム配置画像を作成する。また、同じ枝豆 10 個の整列画像から、枝豆の配置位置が異なる複数枚のランダム配置画像を作成することで、データ拡張を可能にする。




図 4 ランダム配置画像の作成方法

4. 評価

4.1 実験方法

実験に用いた枝豆の総数は 1,490 個で、内訳は異物有りが 176 個、異物無しが 1,314 個あり、すべてボイル済み枝豆を用いた。稼働計算機は、GPU が NVIDIA GeForce RTX 3050、メモリが 16.0GB である。

実験に使用した学習モデルは、整列画像から作成したモデル、ランダム配置画像から作成したモデル、ランダム配置画像を 3 倍、5 倍、10 倍にデータ拡張したモデルの合計 5 つのモデルで精度比較した。

また、2 回交差検定を行い、以下の基準に従って異物有無を計測した。

- 異物有り枝豆、異物無し枝豆ともに 1 サンプルごとに評価する
- 学習モデルに枝豆の A 面と B 面の 2 種類の画像を入力し、どちらか一方でも異物有り判定された場合、その枝豆を異物有り枝豆とみなす

評価指標として、以下の式で示される検出率と過剰検出率の 2 つの指標を用いる。

$$\text{検出率 [\%]} = \frac{\text{異物有り枝豆を異物有りと予測した個数}}{176} \times 100 \quad (1)$$

$$\text{過剰検出率 [\%]} = \frac{\text{異物無し枝豆を異物有りと予測した個数}}{1,314} \times 100 \quad (2)$$

4.2 実験結果

5 つのモデルで推論した結果を表 1 に示す。また、確信度の閾値 α は、過剰検出率 10%以下を満たすもののうち、最も検出率が高い値に設定した。

表 1 実験結果

学習モデル	検出率 (%)	過剰検出率 (%)
整列画像モデル	47.7	9.5
ランダム配置画像 (データ拡張 1 倍) モデル	64.8	9.5
データ拡張 3 倍モデル	77.3	8.5
データ拡張 5 倍モデル	84.1	6.8
データ拡張 10 倍モデル	85.2	6.8

表 1 の実験結果を比較すると、学習データをランダム配置画像に変えて、データ拡張の拡張倍率を高くすると、検出率は向上し、過剰検出率は改善されるという結果になった。また、ランダム配置画像 1 枚当たりの合計推論時間は 87.9ms となった。

また、データ拡張 10 倍モデルを使用して推論した結果を図 5 に示す。図 5(a)で検出ができなかった枝豆は、図 5(b)のように枝豆が密集している部分を分割することで検出できるようになった。そのため、枝豆が密集することで異物有り枝豆が検出できなくなることが分かる。

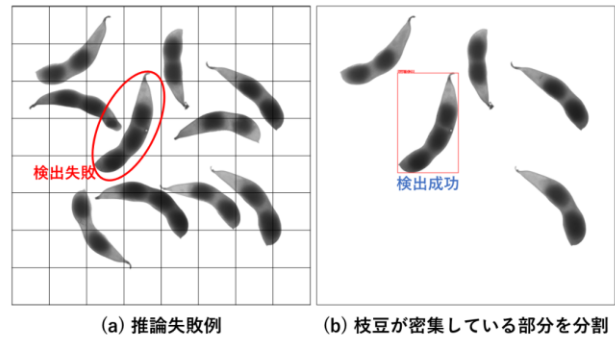


図 5 データ拡張 10 倍モデルの推論結果

5. おわりに

本稿では、ランダムに配置された枝豆内の異物を、YOLOv5 を用いて検知する手法を提案した。実験の結果、目標であった検出率 80%以上、過剰検出率 10%以下、画像 1 枚当たりの推論時間 1 秒以内をすべて満たすことができた。また、推論結果から、枝豆が密集している部分が枝豆の推論に悪影響を及ぼすことが分かった。

今回の実験では、ボイル枝豆を対象に実験を行ったが、生枝豆を対象に実験を行った場合でも、同様の結果になるのかについて検証する予定である。

参考文献

- [1] 中井悠斗, 高田裕介, 宮本遼二, 大津朋也, 山口堅三, 大野将樹, 獅々堀正幹, 石崎雄一, 荒井健太, 青木仁史, “光技術と深層学習を用いた枝豆内の異物検知”, 2023 年電気学会電子・情報・システム部門大会, No.PS1-8, pp.1627-1629, (2023).
- [2] Karen Simonyan, and Andrew Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition”, International Conference on Learning Representations, pp.1-14, (2015).
- [3] Glenn Jocher, <https://github.com/ultralytics/yolov5> (2024 年 6 月 2 日閲覧).