

学習ラベルの種類と数がユズ着果認識 CNN の精度に及ぼす影響

1240287 石橋 璃貴 【 知能情報学研究室 】

1 はじめに

画像内の着果数を自動で計測する畳み込みニューラルネットワーク (CNN) の研究が進められており, 少ないデータから敵対的生成ネットワークを用いて果実画像を生成する研究も行われている [1]. 分類器の分類性能は, 学習データとなるラベル付けやデータの数に影響されるものの, それらの影響は明らかでない部分が多い. そこで, 本研究では, ラベルの付け方の違いによる分類性能を調べるために成熟度が異なる果実, および一部が隠れた果実について, 別のラベルを付与し, それぞれで分類モデルを構築し, 比較する. また, YOLOv8 のモデルサイズによる比較も行う.

2 実験

2.1 ラベル付与と学習データセット作成

本実験では, 着果しているユズの木の画像 319 枚に黄色の果実 (Y), 緑の果実 (G), 葉などの障害物に隠れて半分程度しか見えない黄色の果実 (HY), 同様の緑の果実 (HG) の 4 種類でそれぞれ異なるラベルを付ける. 学習用データ 288 枚, 検証用データを 31 枚に分割する. その後, 50 枚, 100 枚, 150 枚, 200 枚を学習用データ 288 枚からランダムに抽出した学習データを作成する.

2.2 実験手順

YOLOv8 のモデルサイズは, n, s, m, l, x の 5 種類である. 各モデルサイズで学習用データ 288 枚を用いて学習を行う. 成熟度別ラベル付けしたモデルの性能評価として, 適合率と再現率の調和平均を求める F1 値, 予測領域と正解領域の重なりが 50%以上のものを正解とした, Average Precision (以下 AP0.5) を用いる. 次に, 各モデルサイズで学習用データ 5 種類を用いて学習を行う. モデルの性能評価には, GPU のメモリの使用量, F1 値を用いる.

3 実験結果・考察

もっとも性能が良かったモデルサイズ L のモデルの性能評価を表 1 に示す. 1 より, F1 値が最も高いのは, 予想通りラベル (Y) であるが, 葉との混同が予想された



図 1 4 種類のラベル付け例

表 1 成熟度別ラベル付けしたモデル L の性能評価

クラス	F1 値	AP50
黄果実 (Y)	0.680	0.723
緑果実 (G)	0.601	0.631
半黄果実 (HY)	0.488	0.491
半緑果実 (HG)	0.472	0.378




図 2 モデルサイズ別の F1 値

ラベル (G) についてもある程度の認識ができることが確認された. 一方で, (HY), (HG) は葉との混同が見られ性能が下がっている. モデル n, s, m, l, x の GPU メモリ使用量 (Mib) はそれぞれ, 10858, 13788, 19520, 24564, 30744 であった. また, 学習データ枚数別モデルごとの F1 値を図 2 に示す. 実験結果から, n は本実験では, サイズが小さいため性能が高くなかった. s は 100 枚以下の学習データに対して高い性能を持つことがわかった. m, l は全ての枚数で性能の向上が見られ 300 枚以上の学習データを用いるときに使用すると良いと考えられる. x の場合, 100 枚未満の場合は全く学習が出来なかったが, 100 枚でモデルが飽和し, 性能の伸びが悪くなった.

4 おわりに

本研究では, YOLOv8 を用いて成熟度別ラベル付けしたモデルの性能評価を行った. 結果より, 黄色ユズのみに高い F1 値を持つモデルとなった. モデルサイズ別の学習データセット枚数の検討では, 学習データ 100 未満の場合は, s が高い性能を持ち, 100 枚以上になると m, l, x が高い性能を持つことが確認できた. メモリの使用量, 演算時間を考慮すると m を用いた学習が適していることが確認できた.

参考文献

- [1] 三本他, “少データ状況下における敵対的生成ネットワークを用いた果実識別 AI の性能向上法,” 知能システムシンポジウム, 2023.