

令和 4 年度
修士学位論文

温度情報と可視画像を用いた 自然背景中の果実検出の検討

A Study on Fruit Detection in Natural Backgrounds
by Combining Thermal and Visible Image

1255097 稲井 喜基

指導教員 栗原徹

2023 年 2 月 3 日

高知工科大学大学院 工学研究科 基盤工学専攻
情報学コース

要 旨

温度情報と可視画像を用いた 自然背景中の果実検出の検討

稲井 喜基

近年農業従事者の減少の深刻化から農業の省力化，自動化のために，果実や野菜の果実に関する自動識別，自動収穫の技術が研究開発されている．自動識別における画像処理による手法の多くは RGB カメラを用いて行われており，果実の色彩特徴や形状特徴に着目して行われている．しかしピーマンのように緑色の果実は周囲に葉や茎といった緑色の物体が多いため，そのような自然背景中で果実特有の色彩特徴を用いることが難しい．

そこで我々は温度情報に注目した．葉の蒸散や果実の熱容量の影響などから，一定の時間に自然背景と果実に温度差が表れる．

本研究では市販のサーモグラフィカメラを用いた果実検出における，RGB に加えて温度情報による，自然背景中の果実識別精度向上について検討した．RGB と 4ch 目に 255 で埋めた画像を入力した場合と RGB と 4ch 目に温度情報を入力した場合を比較した結果，どの条件においても 4ch 目に温度情報を入力した場合の AP が比較的高い結果になった．

キーワード 果実検出，熱画像，自然背景，MaskR-CNN

Abstract

A Study on Fruit Detection in Natural Backgrounds by Combining Thermal and Visible Image

INAI Yoshiki

In recent years, due to the serious decrease in the number of farmers, research and development of automatic fruit identification and harvesting techniques for fruits and vegetables has been conducted to save labor and automate agriculture. Most image processing methods for automatic fruit identification use RGB cameras and focus on the color and shape characteristics of fruits. However, green fruits such as green pepper are surrounded by many green objects such as leaves and stems, and it is difficult to use color features specific to fruits in such natural backgrounds.

Therefore, we focused on temperature information. The temperature difference between the natural background and the fruit appears at a certain time due to the effects of leaf transpiration and the heat capacity of the fruit.

In this study, we investigated the use of temperature information in addition to RGB to improve the accuracy of fruit identification in natural backgrounds in fruit detection using a commercial thermal imaging camera.

Comparing the results of inputting RGB and an image with the fourth channel filled with 255 with RGB and temperature information in the fourth channel, the AP with temperature information in the fourth channel was relatively higher under all conditions.

key words Fruit detection, thermal image, natural background, MaskR-CNN

目次

第 1 章	はじめに	1
1.1	背景	1
1.2	目的	4
1.3	本論文の構成	5
第 2 章	関連技術	6
2.1	detectron2	6
2.2	MaskR-CNN	6
2.3	交差検証	8
2.4	AP(Average Precision)	8
第 3 章	予備実験・実験環境・実験機材	10
3.1	実験環境・実験機材	10
3.2	予備実験	11
3.3	モデルの 4ch 化	13
第 4 章	提案手法	14
4.1	学習の条件	14
第 5 章	結果・考察	16
5.1	結果	16
5.2	stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化	16
5.3	stem に 3ch モデルの stem を load しない	18
5.4	stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 stem を Freeze .	21
5.5	全体の結果と考察	23

目次

第 6 章 結論 25

謝辭 26

参考文献 27

目次

1.1	農業従事者人口の推移	3
1.2	RGB 画像	3
1.3	熱画像	4
1.4	2 台のカラーカメラとサーモカメラを搭載したフレーム	4
2.1	MaskR-CNN の構造 [5]	7
2.2	MaskR-CNN の詳細なネットワーク構造 [5]	8
2.3	IoU の計算式	9
3.1	E8-XT[9]	11
3.2	位置合わせ方法の流れ	12
5.1	stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 RGBT	17
5.2	stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 RGB255	18
5.3	stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 RGB0	18
5.4	stem に 3ch モデルの stem を load しない RGBT	19
5.5	stem に 3ch モデルの stem を load しない RGB255 閾値 0.6	20
5.6	stem に 3ch モデルの stem を load しない RGB255 閾値 0.4	20
5.7	stem に 3ch モデルの stem を load しない RGB0	21
5.8	stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 stem を Freeze RGBT	22
5.9	stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 stem を Freeze RGB255 閾値 0.6	22
5.10	stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 stem を Freeze RGB255 閾値 0.4	23

図目次

5.11 stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 stem を Freeze RGB0	23
--	----

表目次

3.1	config 設定	13
5.1	評価指標比較	17
5.2	評価指標比較	19
5.3	評価指標比較	22

第 1 章

はじめに

1.1 背景

近年農業従事者人口の減少と高齢化が深刻化している．農林水産省の調査結果によると図 1.1 に表れているように年々農業従事者人口の減少が見られている [1]．また仕事として主に自営農業時従事している基幹的農業従事者において，2009 年から 2019 年にかけて平均年齢が 65.7 歳から 66.8 歳，2023 年には 68.4 歳と高齢化も進んでいることがわかる．

そのため農作業の省力化，自動化が広く進められており，リモートセンシング技術や自動収穫ロボットなどのための果実や野菜の果実に関する自動識別，自動収穫の技術が研究開発されている．

植物は光合成により，光のエネルギーを利用して有機化合物を合成する．合成された有機化合物は果実に運搬され，植物の成長や再生のために貯蔵される．そのため果実を適切な数に摘果することで，適切に成長させるようにコントロールし，安定した収量を得ることができる．果実の数を育成状況に対してコントロールするためには，果実の数は自動検出できることが望ましい．

画像処理による手法の多くは RGB カメラで果実の色彩特徴や形状特徴に着目して行われている [2]．果実の色が緑ではない植物の場合は果実のみの検出を色彩特徴から容易に行えるが，ピーマンのように果実が緑色の場合，葉や茎といった自然背景と同色のため検出が難しい．

そこで我々は温度情報に注目した．植物は気温の高い日中，蒸散が盛んにおこなわれる．これは果実では行われず葉において行われるため，果実と比較して葉は温度が低くなりやす

1.1 背景

い。また果実は熱容量の差から葉と比べ温度低下が遅く、温度に差が起きやすい。実際に撮影した画像である図 1.2, 図 1.3 を見てみると葉の温度は果実と比較して低いことがわかる。葉は日光の当たり方によって蒸散の温度低下よりも直射日光による温度上昇が高い場合があるが、この場合葉の色は光の反射により白くなるためこれは色彩特徴によって区別できると考えている。

これらのことから可視画像と温度情報を用いて安定した果実検出が可能であると期待できる。

先行研究では 2 台のカラーカメラによる 3 次元計測とサーモカメラの合計 3 台のカメラを用いた果実検出手法が提案されている [3]。著者は図 1.4 のような、作成したフレームに搭載することで撮影時の位置関係を固定を可能にしている。この手法では図 1.4 のようにデバイスを作成する必要があるが、一般に普及するためには市販のカメラで果実検出できることが望ましい。そのため本研究では市販の可視画像と熱画像を同時に撮像できる赤外線カメラを用いた果実検出により実験を行っている。

1.1 背景




図 1.1: 農業従事者人口の推移



図 1.2: RGB 画像

1.2 目的



図 1.3: 熱画像



図 1.4: 2 台のカラーカメラとサーモカメラを搭載したフレーム

1.2 目的

1.1 節から本研究では可視画像と温度情報を利用した果実検出の検討を目的として、4ch による深層学習モデル生成を提案し、温度情報を含まない学習の場合と含む場合の学習の比較により、温度情報による精度の向上が見られるか検証した。

1.3 本論文の構成

本論文の構成として第 2 章で果実検出のための技術や評価指標について述べる．第 3 章では実験環境や機材について説明し，予備実験と学習モデルの 4ch 化について示している．第 4 章では提案手法について実験の条件や入力画像について述べる．第 5 章では結果と考察を述べる．第 6 章では結論を述べる．

第 2 章

関連技術

2.1 detectron2

detectron2 は Facebook AI Research が開発した，画像処理研究のために迅速な実装，評価を支援するために構築された，PyTorch ベースのライブラリである [4]．detectron2 には以下のような物体検出アルゴリズムの実装が存在する．

- Mask R-CNN
- RetinaNet
- Faster R-CNN
- RPN
- Fast R-CNN
- TensorMask
- PointRend
- DensePose
- etc...

本研究ではこの中で MaskR-CNN の実装を利用している．

2.2 MaskR-CNN

Mask R-CNN(Mask Region-based Convolutional Neural Network) は物体検出，およびインスタンスセグメンテーションのための深層学習モデルである．インスタンスセグメン

2.2 MaskR-CNN

セグメンテーションは画像中のセグメンテーションされた対象を塊ごとにクラス分けし、一つ一つの区別が可能である。その中でも Mask R-CNN は Faster R-CNN と呼ばれる物体検出モデルを拡張し提案されたモデルであり [5] [6], バウンディングボックスで検出後, そのバウンディングボックス内でセグメンテーションすることで精度向上を図っている。




図 2.1: MaskR-CNN の構造 [5]

基本的な構造は Faster R-CNN と同様であり, 異なる点として RoI Align と分類の際にセグメンテーションも行うことが挙げられる。RoI Align は RoI Pooling の際に, feature map が入力画像より解像度が低いために起こる RPN の領域と実際の対応した領域がずれてしまう問題を解決するために提案された手法である。RoI Pooling は検出した region proposal の領域を feature map から抽出する際に, CNN による影響で region proposal の領域の座標にサブピクセルのずれが発生することを解決するため, このずれを小さくするために行われる。基本的には座標の最大値や平均値を用いることで座標を割り当てるが, この場合セグメンテーションなど位置ずれが精度に影響のある場合に問題となる。そこで RoI Align では region proposal のサブピクセル座標を持つ座標の値を feature map の近傍 4 ピクセルから線形補間を用いて算出している。

2.3 交差検証




図 2.2: MaskR-CNN の詳細なネットワーク構造 [5]

2.3 交差検証

個々のモデルの汎化性能を評価する手法として交差検証 (cross validation) は用いられる [7]. 今回用いた K-分割交差検証では学習データを K 個に分割し分割したデータ群を入れ替えて K 回学習を行う. その後平均を取ることで精度を評価する. これを行うことで学習データとテストデータの差によっておこる評価の変化を平均化できるため, 汎化性能を検証することが可能になる.

2.4 AP(Average Precision)

AP(Average Precision) は一般にバウンディングボックス同士の図 2.3 のような形で算出される IoU を使用される. IoU は正解領域に対し検出された領域がどれだけ重なっているかを正解領域と検出された領域を足した領域の広さで除算することで求められる [8]. IoU に対して閾値を決め, 重なっている領域が閾値以上である検出を TruePositive, 閾値未満を

2.4 AP(Average Precision)

FalsePositive として precision と recall を算出し、その PR 曲線から AP は算出される。

MaskR-CNN では fastR-CNN によるバウンディングボックスでの物体検出の後セグメンテーションを行われるため、AP を利用することで物体検出タスクとセグメンテーションタスクの両方の精度を評価することが可能である。




図 2.3: IoU の計算式

第 3 章

予備実験・実験環境・実験機材

本章では撮影された可視画像と熱画像を用いて、果実検出を行うための実験方法を述べる。始めに実験環境と実験機材について述べ、その後実験を行うための予備実験や学習モデルの調整について述べている。

3.1 実験環境・実験機材

検証データとして高知工科大学 KUT ハウスのピーマンを対象に撮影されたものを使用する。撮影時間は果実部分の温度が高く、同時に葉部分が光合成による蒸散により温度が低くなる、正午に行った。撮影のための赤外線カメラには FLIR 社の E8-XT を用いた。主な仕様として熱画像解像度 320×240 、カラー画像解像度 640×480 、温度分解能 0.05°C 、熱画像視野角 $45^{\circ} \times 34^{\circ}$ 、カラー画像視野角 $55^{\circ} \times 43^{\circ}$ である [9]。提案手法は detectron2 を用いて実装した。各バージョンは Python3.8.8, PyTorch1.10.0+cu113 を用いて実装した。

3.2 予備実験



図 3.1: E8-XT[9]

3.2 予備実験

E8-XT で撮影された可視画像と温度画像は縮尺や画角が異なる．そのため可視画像に合わせて拡大し，そのまま重ね合わせても果実位置などはずれている．このことから可視画像と温度画像の位置合わせを行う必要があった．そこで撮影距離に応じた位置のずれを計測するために四角の金属板を用いて，実験を行った [10]．実験の結果からずれ幅の位置を x を 50px から 70px まで， y を 50px から 80px までと制約を加えることで位置合わせの成功が行いやすくなった．

結果として画角を合わせるために温度情報を 1.52 倍に拡大．その後輪郭情報を利用した位置合わせのために可視画像と拡大した温度情報をエッジ画像化し正規化相互相関を用いること利用可能な程度のずれで位置合わせを行うことが可能になった．おおよその処理の流れは図 3.2 のようになっている．

3.2 予備実験




図 3.2: 位置合わせ方法の流れ

3.3 モデルの 4ch 化

detectron2 における MaskR-CNN の仕様においてデフォルトでは 3ch での学習となっている。4ch で学習する際は config などから数値を調整する必要がある。4ch の学習自体は画像の format の指定と MODEL.PIXEL_MEAN, MODEL.PIXEL_STD の 4ch 化によって簡単に行うことができる。各設定は表 3.1 に示す。

ただし detectron2 は事前学習モデルの読み込み前提で作られており、事前学習モデルは 3ch で学習されたものであることからこのままではレイヤーに不適切な次元数で入力される関係で事前学習モデルのパラメータを利用できない。そこでパラメータを読み込む必要があるレイヤーは 3ch モデルであらかじめ学習し、その際各必要なレイヤーのパラメータを出力しておく。これを必要に応じて読み込むことで 4ch モデルでも事前学習モデルのパラメータの疑似的な利用を実現する。これは実際に利用できているかどうか実験で検証する。

表 3.1: config 設定

設定項目	設定内容
PIXEL_MEAN	[103.53, 116.28, 123.675, 0.0]
PIXEL_STD	[1.0, 1.0, 1.0, 1.0]
INPUT.FORMAT	"RGBA"

第 4 章

提案手法

本章では，3.1 章の環境で撮影された可視画像と熱画像を用いて，ピーマンの果実領域を検出する実験方法について述べる．実験では以下の条件を比較して行う．

- 入力画像
 - RGB の 3ch と 4ch 目を 255 で埋めた画像
 - RGB の 3ch と 4ch 目を 0 で埋めた画像
 - RGB の 3ch と 4ch 目を温度情報にした画像
- モデルの調整
 - stem に 3ch モデルの stem を load，4ch 目は 0 で初期化
 - stem に 3ch モデルの stem を load しない
 - stem に 3ch モデルの stem を load，4ch 目は 0 で初期化 stem を Freeze

4.1 学習の条件

学習画像は 3.1 章の環境で撮影された画像可視画像と温度情報を 4ch に統合し，温度情報を可視画像と同じ縮尺に変更，位置合わせを行った領域 486x364 の画像 75 枚を用いる．また学習には 60 枚，テストには 15 枚を用いて検証する．識別手法には機械学習の手法である MaskR-CNN を用いて検証する．学習時の Epoch は 300，学習率は 0.00025，バッチサイズは 2，ROI HEADS のバッチサイズは 128 とした．データ拡張として Horizontal Random Flip と短辺を 640, 672, 704, 736, 768, 800 からランダムでサイズを選択し，縦横比をそのままにリサイズする Random Resize を行っている．また事前学習モデルには detectron2

4.1 学習の条件

で提供されている”mask_rcnn_R_50_FPN_3x.yaml”を用いた．評価指標には適合率と再現率をもとに評価する AP(AveragePrecision) を使用する．AP はテスト時の出力結果から計算し，5 分割交差検証の結果から平均を表に示す．

第 5 章

結果・考察

本章では，検証の結果と考察について述べる．

5.1 結果

提案手法の検証結果において各入力画像，モデルの条件による精度を AP(Average Precision) により評価した．AP は正解画素をどの程度検出できているかを平均的に表す指標である．IoU を 0.5 から 0.95 まで 0.05 刻みで動かして計算した AP の平均を AP，IoU>0.5 で計算した AP を AP50，IoU>0.75 で計算した AP を AP75，小さい物体に対する AP を APs，APs より大きい物体に対する AP を APm として表に表す．

画像は可視画像に対して検出スコア，バウンディングボックス，セグメンテーションマスクが描写されている．また 4ch 目に数値が入っている都合上，透明度扱いになり，特に 4ch 目を 0 で埋めた場合は全画素透明であるため描写が全て白になっている．正解画像と検出結果を重ねた画像では赤が検出結果，青が正解画素になっており重なった場合紫で描写されている．

5.2 stem に 3ch モデルの stem を load，4ch 目は 0 で初期化


stem に 3ch モデルの stem を load，4ch 目は 0 で初期化した場合，3ch モデルと同様の結果が出力されることを期待した．

5.2 stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化


各 AP を表 5.1 に示す. 各入力画像の比較としては, RGBT が最も精度が高く, RGB0 はほとんど検出できていないといっている結果になった. 画像で比較した場合 RGBT の画像, 図 5.1a, 図 5.1b は一部誤検出と細かい未検出が見られるがおおよそ果実の検出が行えており果実の領域も正解からはみ出したり, 逆に一部欠けたりせず検出できている果実も存在する. RGB255 の画像, 図 5.2a, 図 5.2b は検出できている果実もあるが未検出の果実も見られる. ただこちらでは誤検出が見られなかった. RGB0 の画像, 図 5.3a, 図 5.3b は検出を行えていない結果になった.

表 5.1: 評価指標比較

ch	AP	AP50	AP75	APs	APm
RGBT	19.2278	48.58	17.4964	19.8938	22.4696
RGB255	5.6932	14.2132	3.8282	5.0208	8.2142
RGB0	0.0108	0.07	0	0.009	0.0154




(a) 検出結果




(b) 正解画素と検出結果を重ねた画像

図 5.1: stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 RGBT

5.3 stem に 3ch モデルの stem を load しない




(a) 検出結果




(b) 正解画素と検出結果を重ねた画像

図 5.2: stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 RGB255



(a) 検出結果



(b) 正解画素と検出結果を重ねた画像

図 5.3: stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 RGB0

5.3 stem に 3ch モデルの stem を load しない

stem に 3ch モデルの stem を load しない場合, 0 からの学習となるため温度情報の影響でどこまで精度上昇につながるかどうか確認した.

各 AP を表 5.2 に示す.

各入力画像の比較としては, 5.2 節と同様に RGBT が最も精度が高く, RGB0 はほとんど検出できていないといっていい結果になった. 画像で比較した場合, RGBT の画像図 5.4a, 図 5.4b では少し未検出が見られるがおおよそすべての果実領域を検出できていた. しかし

5.3 stem に 3ch モデルの stem を load しない


葉を果実と誤検出するケースが多く見られた。RGB255 ではこの画像では 0.6 の閾値で検出は見られなかった。そこで 0.4 の閾値の場合も図 5.6a, 図 5.6b に示す。こちらは一部検出できている果実もあるが誤検出もある結果になっていた。RGB0 の画像, 図 5.3a, 図 5.3b は検出を行えていない結果になった。

表 5.2: 評価指標比較

ch	AP	AP50	AP75	APs	APm
RGBT	22.6568	45.8014	21.0174	21.4168	26.3898
RGB255	1.5264	5.599	0.2692	2.702	1.7906
RGB0	0.0142	0.068	0	2.4984	0.0222



(a) 検出結果




(b) 正解画素と検出結果を重ねた画像

図 5.4: stem に 3ch モデルの stem を load しない RGBT

5.3 stem に 3ch モデルの stem を load しない



(a) 検出結果




(b) 正解画素と検出結果を重ねた画像

図 5.5: stem に 3ch モデルの stem を load しない RGB255 閾値 0.6




(a) 検出結果



(b) 正解画素と検出結果を重ねた画像

図 5.6: stem に 3ch モデルの stem を load しない RGB255 閾値 0.4

5.4 stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 stem を Freeze



(a) 検出結果

(b) 正解画素と検出結果を重ねた画像

図 5.7: stem に 3ch モデルの stem を load しない RGB0

5.4 stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 stem を Freeze

stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化して stem を Freeze した場合, stem の重みは 3ch モデルと同様の結果になることでその後の学習で精度が向上することを期待した.

各 AP を表 5.3 に示す.

各入力画像の比較としては, 5.2, 5.3 節と同様に RGBT が最も精度が高く, RGB0 はほとんど検出できていないといっている結果になった. 画像で比較した場合, RGBT の画像図 5.8a, 図 5.8b では未検出が多く見られた. また誤検出はほとんどない結果となった. RGB255 ではこの画像では 0.6 の閾値で果実一つ分の検出が見られたが多くは未検出という結果となった. 今回の条件も 0.4 の閾値の場合を図 5.10a, 図 5.10b に示す. こちらは一部検出できている果実も増加したが誤検出もある結果になっていた. RGB0 の画像, 図 5.11a, 図 5.11b は検出を行えていない結果になった.


5.4 stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 stem を Freeze

表 5.3: 評価指標比較

ch	AP	AP50	AP75	APs	APm
RGBT	3.922	11.5786	0.879	1.7198	5.2796
RGB255	3.421	8.9198	1.855	4.0906	5.06
RGB0	0.0182	0.1026	0	1.01	0.021



(a) 検出結果




(b) 正解画素と検出結果を重ねた画像

図 5.8: stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 stem を Freeze RGBT




(a) 検出結果




(b) 正解画素と検出結果を重ねた画像

図 5.9: stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 stem を Freeze RGB255 閾値 0.6

5.5 全体の結果と考察




(a) 検出結果



(b) 正解画素と検出結果を重ねた画像

図 5.10: stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 stem を Freeze RGB255 閾値 0.4



(a) 検出結果

(b) 正解画素と検出結果を重ねた画像

図 5.11: stem に 3ch モデルの stem を load, 4ch 目は 0 で初期化 stem を Freeze RGB0

5.5 全体の結果と考察

検証の結果、今回の条件では 5.3 節の入力画像 RGBT の場合が最も精度が高い結果となった。これは他の条件と比較して、未検出が少なかったためだと考える。ただし 5.2 節の RGBT と画像で比較して、誤検出が多い結果となっているため画像によっては、5.2 節の条件の場合が精度が高いと考える。また誤検出が低減されたのは、事前学習モデルのパラメータを利用できたためなのではないかと考える。

入力画像 RGB255 に関してはどの条件においても RGBT より検出精度が低い結果となっ

5.5 全体の結果と考察

たことから温度情報を加えることで精度向上につながる可能性を示した。

入力画像 RGB0 に関してはどの条件においても果実を検出できなかったことから 4ch 目は RGB の 3ch にも影響を及ぼしていることがわかった。

この結果から stem に 3ch モデルの stem を load することで、誤検出低減につながると考えている。また 5.2 節の条件での未検出部位は葉の隙間から見えている小さな果実の領域であるため、学習データの増加により、これも検出できるようになるのではないかと考えている。

第 6 章

結論

本研究では可視画像と温度情報を利用した果実検出の検討を目的として、4ch による深層学習モデル生成を提案し、温度情報を含まない学習の場合と含む場合の学習の比較により、温度情報による精度の向上が見られるか検証した。提案手法では、入力画像として RGB と温度情報、可視画像のみと同じ条件の RGB と 4ch 目を 255 で埋めたもの、4ch 目の影響を確認するための RGB と 4ch 目を 0 で埋めたものを入力し、条件としてモデルの stem を調整した場合を比較し評価した。

その結果どのモデルの条件においても入力画像に RGB と 4ch 目を 255 で埋めたものは、入力画像に RGB と温度情報の場合を精度でも検出画像としても上回ることはなかったことから、可視画像に温度情報を加えることによる精度向上の可能性を示した。またモデルの stem を調整した場合に RGBT の検出の表れ方が異なったことからモデルのさらなる 4ch への最適化により精度向上が見られるのではないかと考える。

謝辞

本研究を進めるにあたり，御丁寧な御指導いただきました栗原徹教授に心から感謝を申し上げます．そしてお忙しい中，本研究の副査を引き受けていただきました妻鳥貴彦准教授，吉田真一教授に御礼申し上げます．

参考文献

- [1] 農林水産省, ”農業構造動態調査結果”, ”<https://www.maff.go.jp/j/tokei/kouhyou/noukou/>”(参照 2023-02-03).
- [2] 池田 善郎, Limsiroratana S., “自然背景中の果実検出 (1), ” 農業機械學會誌, 67 巻, 4 号, p. 73-80, 2005.
- [3] Hao Gan, Won Suk Lee, Victor Alchanatis, ”A photogrammetry-based image registration method for multi-camera systems - With applications in images of a tree crop,” Biosystems Engineering, Vol. 174, pp.89-106, 2018.
- [4] MetaAI, ”Detectron2”, ”<https://ai.facebook.com/tools/detectron2/>, ”(参照 2023-02-03).
- [5] Kaiming He, Georgia Gkioxari, Piotr Dollár, and Ross Girshick. “MaskR-CNN, ”IEEE International Conference on Computer Vision (ICCV), 2017.
- [6] Shaoqing Ren, Kaiming He, Ross Girshick, Jian Sun. “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, ” IEEE Trans. Pattern Anal. Mach. Intell. 2016, 39, 1137–1149.
- [7] scikit-learn, ”Cross-validation: evaluating estimator performance”, ”https://scikit-learn.org/stable/modules/cross_validation.html, ”(参照 2023-03-06).
- [8] Jonathan Hui, ”mAP (mean Average Precision) for Object Detection”, ”<https://jonathan-hui.medium.com/map-mean-average-precision-for-object-detection-45c121a31173>, ”(参照 2023-03-06).
- [9] FLIR, ”FLIR E8-XT”, ”<https://www.flir.jp/products/e8-xt/?vertical=condition+monitoring&segment=solutions>, ”(参照 2023-02-03).

参考文献

- [10] 稲井ら, “熱画像とカラー画像の位置合わせに関する基礎的検討,” 第 25 回パターン計測シンポジウム, PM105_01, 2020.