

# 遠赤外線カメラを用いたハウス内ピーマンの果実認識

## Recognition of sweet pepper fruit in green house using far-infrared camera

知能機械工学コース

機械・航空システム制御研究室 1255015 多田 直矢

### 1. 緒言

農業従事者の減少<sup>(1)</sup>による、農作業の一人当たりの労働の負担は大きくなっている。その問題に対処するために農林水産省はスマート農業<sup>(2)</sup>を推進するなど、農業における自動化技術の導入が望まれている。高知県のハウス園芸において生産が盛んなピーマンの自動収穫を目的とした果実の認識では、葉と果実の色が近いため、RGBカメラを用いた方法だけでは難しい。そのために葉と果実の温度の違いに基づく遠赤外線カメラを用いた方法が提案されており、有効性が示されている<sup>(3)</sup>。

本研究では遠赤外線カメラによる温度情報に基づいて、果実の認識率の向上のためにAI技術を用いた提案を行う。具体的には処理を行う際に室温や湿度を用いたしきい値処理を自動で行い、赤外線画像の処理精度を向上させる。

第2章では遠赤外線カメラによる検出方法、第3章では検出結果の評価方法、第4章では冬季の夜間における検出方法及び結果について述べる。第5章では機械学習を用いた昼間の検出方法及び結果について述べる。

### 2. 検出方法

#### 2.1 遠赤外線カメラによる検出

葉と果実を区別し検出する方法として蒸散作用<sup>(4)</sup>と葉と果実の熱容量の違いによる温度差を利用することが提案されている<sup>(3)</sup>。昼間のハウス内のように照度が大きく湿度が低いときには多くの蒸散作用が発生し葉の温度が低くなることが知られている。また果実は中が空洞で空気が入っているため熱容量が大きく、葉は薄いため熱容量が小さいことから、果実より葉の方が温度は変化しやすい。

上記の温度特性に対して有効な検出方法として遠赤外線カメラを用いて果実を検出する方法が挙げられる。遠赤外線カメラは撮影した画像内の1ピクセルごとの温度情報が取得可能である。図1に1日のハウス、葉及び果実の温度のグラフを示す。赤がハウス、緑が葉、青が果実の温度である。ハウスの温度は温度計、葉と果実の温度は遠赤外線カメラで測定した。遠赤外線カメラを用いて葉と果実の温度差を利用し、ハウス温度に基づいて果実の検出を行う。

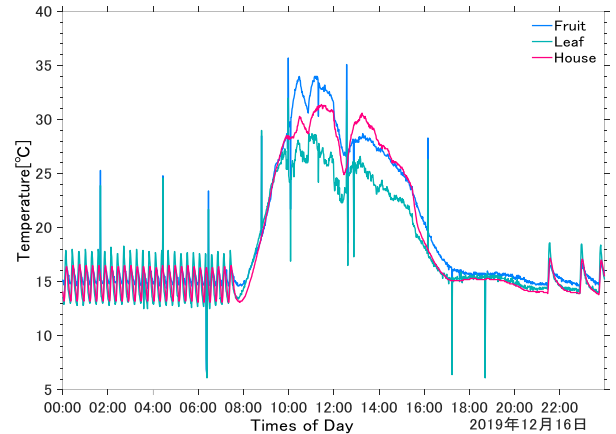


Fig.1 Daily temperature

#### 2.2 自動検出方法

自動検出方法はピーマンの遠赤外線データに対して温度のしきい値処理などを行い果実を検出する。しきい値処理は遠赤外線データの中で指定した温度範囲のピクセルを検出し二値画像を生成する。しきい値はハウス内の温度の温度を基準とした値で、理想的にはピーマンの果実の温度の範囲であり、自動で決定する必要があるが昼間と夜間ではしきい値の決定方法は異なる。

昼間の場合、機械学習を用いてしきい値を決定する。まず学習用のデータに対して複数のパターンのしきい値すべてに対して画像処理を試行し、画像処理過程で検出率の評価を行う。評価結果のよいしきい値を用いて機械学習を行い、学習したモデルにより学習に用いていないデータに対して最適なしきい値を推定する。推定したしきい値を用いて画像処理を行うことで果実を自動検出するという手順で行った。

機械学習の詳細は第5章で述べる。夜間のしきい値の決定方法は第4章で述べる。

#### 2.3 画像処理

遠赤外線カメラで取得した温度情報のみで検出を行うとハウスのビニールの部分など果実以外の箇所が多く検出されるという問題がある。画像処理を行うことで視覚的に果実を判別しやすく、果実以外の不必要な箇所を比較的容易に削除することができる。最初にしきい値処理を行った。処理過程でモルフォロジー変換<sup>(5)</sup>等の手法を用いた。

### 3. 画像処理結果の評価

#### 3.1 評価方法

2.2 節で述べた温度のしきい値処理は自動化する必要がある。昼間の機械学習に使用する教師データ作成のために処理画像の評価を行った。画像処理結果自体の評価も行う。評価方法としては、まず図2に示すような評価元となる赤外線画像内の対象となる果実を手動で指定する。次に評価を行う画像と比較してピクセルごとに真陽性(*TP*)、偽陽性(*FP*)、真陰性(*TN*)、偽陰性(*FN*)<sup>(6)(7)</sup>の判別を行う。さらに式(1)(2)(3)に示すように誤検出の評価をする再現率(*Recall*)と見逃しの評価をする適合率(*Precision*)、再現率と適合率の調和平均をとるF値(*F-Measure*)<sup>(6)(7)</sup>を求めた。F値を求める理由としては、再現率と適合率はトレードオフの関係であるものの、どちらか一方の数値が高いだけでは必ずしも良い検出結果は得られないためである。

$$Recall = \frac{TP}{TP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$F - Measure = \frac{2}{\frac{1}{Recall} + \frac{1}{Precision}} = \frac{2TP}{2TP + FP + FN} \quad (3)$$



Fig.2 Example of an image from which it is evaluated

### 4. 冬季の夜間における検出

#### 4.1 ボイラを使用した際の温度

冬季の夜間においてはピーマンの温度が低下した場合に病害が発生する可能性があり、それを防止するためにハウス内でボイラを焚く必要がある。ボイラはハウス内の温度が設定された温度以下になると作動し、その後設定された温度まで上昇すると停止する。例えば13℃で作動し16℃まで上昇すると停止する。この時、葉と果実にも温度変化が生じる。図3にボイラを使用した際の夜間のハウス、葉、果実の温度のグラフを示す。




Fig.3 Temperature when using the boiler.

#### 4.2 冬季夜間の検出方法

図3よりハウスの温度の最大値と最小値はほぼ変化しておらずボイラによって適切に温度管理されていることがわかる。ハウスの温度が上昇した際に葉の温度がハウスの温度の最大値より1℃~2℃高い。果実は葉ほど大きく温度変化せずハウスの温度が変化する範囲にほぼ収まっている。遠赤外線カメラを用いて定点で撮影すれば葉と果実の温度変化を測定可能である。画像内の1ピクセルごとの温度を一定時間観測しその間の温度がハウス温度の最大値と最小値の範囲に収まっていれば果実、それ以外は果実でないとしきい値を決定することで検出可能であると考えた。今回は検出する時刻から過去30分の温度データを使用して検出を行った。

#### 4.3 検出結果と考察

図4に検出結果の画像、表1に結果の評価値を示す。すべての時間でF値は85%を超えており、画像を見ても対象物の形をほぼ正確に検出できている。それぞれの時間におけるハウス内温度は違いがあるがしきい値は13.5~16.3℃程度でほとんど一定である。背景のビニール部分も外気によって温度が低下するため検出されないと考える。

この検出方法は一定の有効性はあると考えるが、今回の場合検出するために20~30分必要という点が課題である。外の気温が低い場合ハウスの温度もより早く低下するため、ボイラの作動間隔も短くなることで短時間での検出は可能であると考えられる。外の気温があまり低くない場合はボイラの作動回数も少なくなるため検出できる時間帯は少ない。ただ、ボイラ作動後に温度が上昇するまでの時間は短いためボイラが停止した直後であれば検出可能であると考えられる。




Fig.4 Detection results

Table.1 Evaluation results

Time	Inside the house temperature (°C)	Threshold temperature range (°C)	F-measure (%)
1:00	15.8	13.6 ~ 16.3	85.7
2:00	14.4	13.4 ~ 16.3	89.5
3:00	16.3	13.5 ~ 16.3	85.8

## 5. 機械学習

### 5.1 学習方法

3.1 節の評価結果を用いて温度のしきい値を推定するために機械学習を行った。機械学習の種類として教師あり学習の分類問題を用いた。ソフトウェアは MATLAB の分類学習器アプリケーションを用いた。予測対象である目的変数はしきい値の上限と下限とした。予測を行うために必要な特徴量はハウス内の温度、湿度、照度、紫外線強度を用いた。それらの特徴量を含め予測する時間から 1, 5, 10, 15, 30, 60 分前までの平均、差分、最大、最少、分散、標準偏差など合計して約 140 個の特徴量を使用する候補とし、その中から Minimum Redundancy Maximum Relevance(MRMR)アルゴリズム<sup>(45)</sup>という特徴量選択方法を用いて算出されたスコアの上位 20 個の特徴量を選択した。平均などを使用する理由は温度などの変化によってしきい値の傾向が変化するためである。学習に用いたデータセットは 2022 年 12 月 7,8,10,11,12,14,15,16,17 の 9 日間、10:00~16:59 の一分毎のデータであり F 値が最大である時のしきい値を教師データとする。データセットの個数は約 3200 個である。

学習方法はアンサンブル学習のバギング<sup>(9)</sup>と重み付き K-近傍法<sup>(7)</sup>を用いた。バギングは少数のランダムなデータセットを選択し弱学習器、つまり小さな学習データを作成する。これを繰り返し弱学習器を組み合わせることで学習結果を得る。K-近傍法は変数の数に応じた N 次元座標系のある点から K 個の近傍点を見ることで、その点がどのグループにあるか分類する方法である。どちらも他の学習方法に比べて短時間の学習で精度が高い。

### 5.2 学習精度

学習結果に対して、学習元データの特徴量を用いて推定を行うことで推定して得られた目的変数と教師データが一致するか精度検証を行った。検証方法は交差検証<sup>(7)</sup>を用いる。交差検証はデータセットを特定の数に分割し、ランダムに振り分けられたセットを作成する。分割したうちの 1 つを精度の検証に使用し、それを分割した数だけ順番に繰り返すという方法である。今回の検証では 5 分割とした。表 2 に推定に使用する学習結果の精度を示す。

### 5.3 画像処理過程の変更点

ピーマンを収穫する際に遠くにある果実はロボットの手先が届かない場合がある。深度情報を用いることで手先の届く範囲のみを検出し、無駄な動作を削減できると考えた。図

5 に深度画像の例を示す。青い方がカメラからの距離が近く、赤い方が遠い。深度データを利用するために画像処理過程の変更を行った。4 章で述べた画像処理過程のしきい値処理の後に指定した深度以上（今回は 700mm 以上）のピクセルを削除する処理を追加した。ここに追加することで距離が遠く検出対象から外れる部分を削除し、ノイズの少ない検出結果が得られると考えた。

Table.2 Learning accuracy

Algorithm	Upper threshold limit(%)	Lower threshold limit(%)
Bagging	59.5	69.8
KNN	54.2	64.8




Fig.5 Example of depth image

### 5.4 しきい値推定結果と考察

2022 年 12 月 7, 8, 10~12, 14~17 日の 9 日間のデータを用いて機械学習を行い学習モデルを作成し、9, 13, 18 日のデータを使用して果実の検出を行った。図 6 と図 7 にバギングと K-近傍法の学習モデルで推定したしきい値での 12 月 9 日の検出結果の画像、表 3 にしきい値と評価結果を示す。1 番右の検出対象の果実は大きさが小さいが左の果実に近く現状の処理過程では削除できないため対象物としている。

両方のモデルで 14:00 において画像ではよい検出結果とはいえないものの、F 値は 50%程度だった。検出結果が良好でない理由は画像から葉と果実の両方が白く温度差が小さいため検出に適した状態でないためだと考える。しきい値に関してバギングと K-近傍法で上限だけが違う際は、評価結果にはほぼ差はみられないが、下限も違う際は評価結果に違いが見られる。画像では下の果実が検出できておらず、下の果実は大きさが小さく、しきい値処理の時点で検出された面積が小さい場合途中で削除されてしまう場合があるためであると考える。14:00 以外では F 値は 60%以上であり、画像を見ても形は良くない場合もあるが指定した箇所は検出できていることから、果実の温度範囲をしきい値として推定するという点では、おおむね良好な検出結果が得られたと考える。バギングと K-近傍法では学習モデルの精度はバギングの方が 5%程度高いが、実際に推定を行った際の精度はあまり差がなく現状ではどちらが有効であるとは一概に言えない。



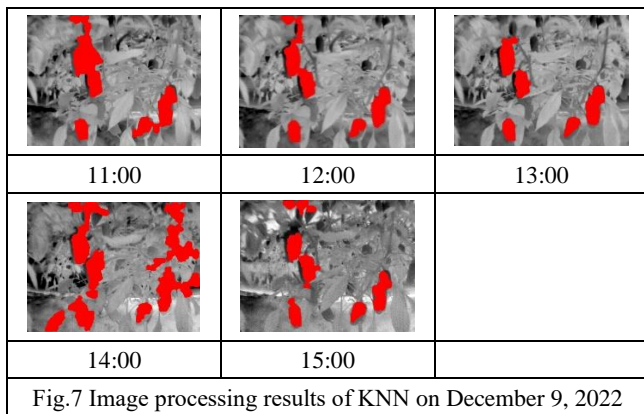
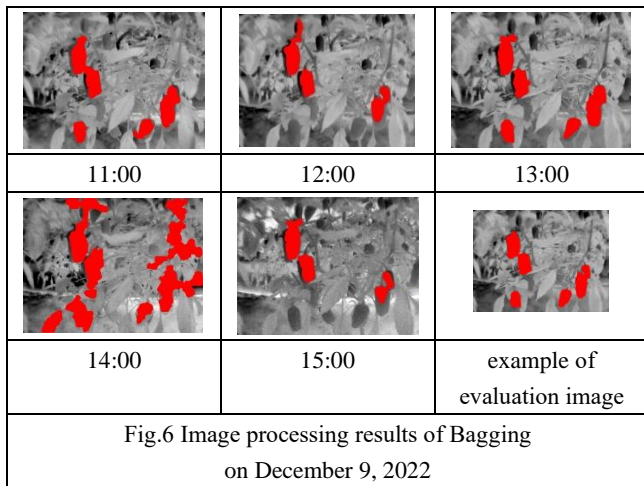


Table.3 Thresholds and evaluation results

Algorithm	Time	House temperature (°C)	Threshold temperature range (°C)	F-measure (%)
Bagging	11:00	26.6	-3.0 ~ 1.5	83.0
	12:00	26.2	-2.5 ~ 2.5	64.1
	13:00	26.0	-2.5 ~ 1.0	86.0
	14:00	26.9	-3.0 ~ 1.0	50.9
	15:00	25.4	-1.0 ~ 1.5	64.7
KNN	11:00	26.6	-3.5 ~ 1.5	71.4
	12:00	26.2	-3.0 ~ 4.0	79.8
	13:00	26.0	-2.5 ~ 2.5	86.2
	14:00	26.9	-3.0 ~ 1.5	50.9
	15:00	25.4	-1.5 ~ 0	75.7

## 6. 結言

本研究では温度情報を取得可能な遠赤外線カメラを用いたピーマン果実の検出方法について検討し、AI 技術を用いた提案を行った。果実の検出方法として温度のしきい値処理を主とした画像処理を行った。画像処理過程でモルフォロジー変換<sup>6)</sup>等の手法を用いた。機械学習の教師データを作成す

るために再現率、適合率、F 値<sup>13)</sup>という評価指標を定め、画像処理途中で評価を行った。

冬季の夜間において温度低下防止のためにボイラを作動させた際に検出を行った。結果として対象物 2 個を検出でき F 値は 80% 台であった。しきい値を自動的に決定するために昼間は機械学習を用いてしきい値を推定することを提案した。深度情報を利用し、画像処理過程に処理を追加した画像処理を行った。F 値は 50~80% だった。

今後の展望として果実の検出は 2 次元の画像として検出しているため深度情報を用いた 3 次元での位置特定と、ロボットによる摘み取りを行うための摘み取り位置の検出または推定を行いたい。

## 謝辞

本研究を行うにあたって、懇切丁寧にご指導いただきました岡宏一教授に感謝申し上げます。ご助言いただきました原田明德准教授に感謝申し上げます。相談に乗ってくださった研究室のみなさまに感謝申し上げます。実験にご協力いただいた北村様に感謝申し上げます。

本研究は高知県の「IoP が導く Next 次世代型施設園芸農業への進化プロジェクト」の助成を受けております。この場をお借りして感謝申し上げます。

## 参考文献

- [1] 農林水産省ホームページ：農業労働力に関する統計  
<https://www.maff.go.jp/j/tokei/sihyo/data/08.html>  
(参照日 2023 年 1 月 6 日)
- [2] 農林水産省ホームページ：スマート農業  
<https://www.maff.go.jp/j/kanbo/smart/>  
(参照日 2023 年 1 月 6 日)
- [3] 多田敬佑, 岡宏一, 原田明德, “赤外線カメラを利用したハウス内ピーマンの検出”  
修士学位論文, 高知工科大学(2020)
- [4] 増田芳雄 “絵とき 植物生理学入門”, (1988), オーム社
- [5] 田中敏幸, “画像情報処理の基礎”, (2019), コロナ社
- [6] 中川裕志, “東京大学工学教程 情報工学 機械学習”, (2015), 丸善出版
- [7] 秋庭伸也, 杉山阿聖, 寺田学, “見て試してわかる 機械学習アルゴリズムの仕組み 機械学習図鑑”, (2019), 翔泳社
- [8] MathWorks: Minimum Redundancy Maximum Relevance (MRMR) アルゴリズムを使用した分類用の特徴量のランク付け  
<https://jp.mathworks.com/help/stats/fscmr.html>  
(参照日 2023 年 1 月 6 日)
- [9] Zhou, Zhi-Hua, 宮岡悦良, 下川朝有, “アンサンブル法による機械学習—基礎とアルゴリズム—”, (2017), 近代科学社