

令和3年度
修士学位論文

葉の動きを利用したショウガ根茎腐敗病 発病株の早期検出手法

An Early Detection Method for Ginger Rhizome Rot
Using Leaf Movement

1245120 窪田 伊織

指導教員 栗原 徹

2022年3月7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

葉の動きを利用したショウガ根茎腐敗病発病株の早期検出手法

窪田 伊織

ショウガ根茎腐敗病は、ショウガに発生する病害の中でも被害の大きいものの一つである。この病害は発病株を中心に周辺の株へと二次伝染しやすいという特徴があるため、発病が確認された場合にはできる限り早い段階で発病株を取り除く必要がある。しかし、現状では目に見える症状を基に病害を判断する 경우가多く、目視で症状が確認できるころには感染が広がっていることも多くある。このため、症状が出る前に発病株を検出する方法が求められている。

そこで本研究では、ショウガ根茎腐敗病の発病株を早期に検出するため、ショウガの葉の動きを利用して発病株を検出する方法について提案を行った。著者らは研究過程において病原菌を意図的に接種した接種株の方が接種していない無接種株よりも葉の動きが小さくなるという傾向を発見した。このため、葉の動きを定量化する方法を提案し、それらの方法から接種株と無接種株を判別可能か ROC 曲線や AUC などを用いて評価した。結果として、提案した葉の動きの定量化手法の中で最も良好であった手法の AUC は 0.989 で、この場合、Youden's Index における最良の閾値による判別の正答率は 96.08%、接種株を陽性とした場合の真陽性率は 92.59%、偽陽性率は 0%となった。このとき、真陽性率が 100%となるように閾値を決めた場合、偽陽性率の最小値は 16.67%となった。

キーワード ショウガ根茎腐敗病, 葉の動き, サポートベクターマシン, ROC 曲線, AUC, Youden's Index

Abstract

An Early Detection Method for Ginger Rhizome Rot Using Leaf Movement

KUBOTA, Iori

Ginger rhizome rot is one of the most damaging diseases that occur on ginger. This disease is characterized by a tendency for secondary transmission from the diseased plant to neighboring plants, so it is necessary to remove diseased plants as soon as possible after the disease is confirmed. However, at present, the disease is often judged based on visible symptoms, and by the time visible symptoms appear, the infection has often spread. Therefore, there is a need to detect diseased plants before symptoms appear.

In this study, we proposed a method of detecting diseased ginger plants by using leaf movement to identify diseased ginger plants at an early stage of rhizome rot. We found a tendency for inoculated plants that were intentionally inoculated with the rhizome rot pathogen to have less leaf movement than uninoculated plants. For this reason, we proposed a method to quantify leaf movement and evaluated whether these methods could discriminate between inoculated and uninoculated plants using ROC curves and AUCs. As a result, the AUC of the best method among the proposed approach for quantifying leaf movement was 0.989. In this case, the accuracy rate for discrimination by the best threshold in Youden's Index was 96.08%. The true positive rate was 92.59%. The false positive rate was 0% when the inoculated plants were considered positive. When the threshold value was set so that the true positive rate was 100%, the minimum false positive rate was 16.67%.

key words Ginger Rhizome Rot, Leaf Movement, Support Vector Machine, Receiver Operating Characteristic Curve, Area Under the Curve, Youden's Index

目次

第 1 章	序論	1
1.1	背景	1
1.2	目的	2
1.3	本論文の構成	2
第 2 章	関連技術	3
2.1	Support Vector Machine	3
2.1.1	カーネルトリック	4
2.1.2	グリッドサーチ	5
2.1.3	交差検証	5
2.2	ROC 曲線	6
2.2.1	AUC	6
2.2.2	Youden’s Index	7
第 3 章	提案手法	8
3.1	提案手法の概要	8
3.2	葉領域の検出	9
3.3	葉の動きの検出	10
3.3.1	1 時間ごとに葉の動きを求める方法	11
3.3.2	6 時の画像を基準として葉の動きを求める方法	11
3.3.3	12 時の画像を基準として葉の動きを求める方法	12
3.4	分母となる葉領域の検出	13
3.5	葉の動きの割合の定量化	13
第 4 章	検証	15

目次

4.1	検証データ	15
4.1.1	撮影環境	15
4.1.2	撮影期間・発病状況	16
4.1.3	検証に使用するデータの期間	17
4.2	検証条件	17
4.2.1	葉領域の検出における教師画像と学習モデルの作成	18
4.2.2	葉の動きの割合を求める際の接種株と無接種株の定義	20
4.2.3	午前と午後の葉の動きの割合の違いにおける検証条件の追加	21
4.3	検証内容	23
第5章	結果・考察	24
5.1	結果	24
5.1.1	1時間ごとに葉の動きを求める方法	24
5.1.2	6時の画像を基準として葉の動きを求める方法	25
5.1.3	12時の画像を基準として葉の動きを求める方法	27
5.2	考察	28
5.2.1	午前と午後の葉の動きの割合の違いが現れた要因	30
5.2.2	葉領域検出における誤検出の影響	31
第6章	結論	36
	謝辞	37
	参考文献	38
付録A	検証データにおける各時刻の葉の動きの割合	40
A.1	1時間ごとの葉の動きを求める方法	41
A.1.1	期間①	41

目次

A.1.2	期間②	44
A.1.3	期間③	46
A.2	6時の画像を基準として葉の動きを求める方法	48
A.2.1	期間①	48
A.2.2	期間②	51
A.2.3	期間③	53
A.3	12時の画像を基準として葉の動きを求める方法	55
A.3.1	期間①	55
A.3.2	期間②	58
A.3.3	期間③	60
付録 B	検証データにおける各日の葉の動きの割合	62
B.1	1時間ごとに葉の動きを求める方法	63
B.1.1	期間①	63
B.1.2	期間②	66
B.1.3	期間③	68
B.2	6時の画像を基準として葉の動きを求める方法	70
B.2.1	期間①	70
B.2.2	期間②	73
B.2.3	期間③	75
B.3	12時の画像を基準として葉の動きを求める方法	77
B.3.1	期間①	77
B.3.2	期間②	80
B.3.3	期間③	82
付録 C	検証データにおける日射量と気温	84
C.1	期間①	84

目次

C.2	期間②	85
C.3	期間③	85

目次

2.1	SVM における識別境界の例	3
2.2	ROC 曲線の例	6
2.3	ROC 曲線 (AUC=1)	7
2.4	ROC 曲線 (AUC=0.5)	7
2.5	ROC 曲線上の Youden's Index	7
3.1	提案手法の流れ	8
3.2	葉の動きの検出の流れ	10
3.3	1 時間ごとに葉の動きを求める方法の流れ	11
3.4	6 時の画像を基準として葉の動きを求める方法の流れ	12
3.5	12 時の画像を基準として葉の動きを求める方法の流れ	12
3.6	接種株と無接種株における各時刻の葉の動きの割合を求める流れ	13
3.7	各時刻の葉の動きの割合から各日の葉の動きの割合を求める流れ	14
4.1	撮影の様子	16
4.2	撮影した画像の例	16
4.3	検証に使用した教師画像 (7 月 27 日 10 時 15 分) (黒色:背景, 白色:葉, 赤色: 除外)	18
4.4	検証に使用した教師画像 (7 月 29 日 7 時 40 分) (黒色:背景, 白色:葉, 赤色: 除外)	18
4.5	葉領域検出の際の SVM による識別境界 (C=100, gamma=100)	19
4.6	期間①の各セルの定義 (赤色: 無接種株, 青色: 接種株, 灰色: 背景, 緑色: 不明)	20

図目次

4.7	期間②の各セルの定義 (赤色: 無接種株, 青色: 接種株, 灰色: 背景, 緑色: 不明)	21
4.8	期間③の各セルの定義 (赤色: 無接種株, 青色: 接種株, 灰色: 背景, 緑色: 不明)	21
4.9	午前と午後の各時刻の葉の動きの割合の違いの例	22
5.1	1時間ごとに葉の動きを求める方法における ROC 曲線	25
5.2	6時の画像を基準として葉の動きを求める方法における ROC 曲線	26
5.3	12時の画像を基準として葉の動きを求める方法における ROC 曲線	28
5.4	3つの手法における午前と午後の各時刻の葉の動きの割合の違いの例	29
5.5	7月31日の日射量と気温	30
5.6	8月15日の日射量と気温	30
5.7	8月16日の日射量と気温	31
5.8	葉領域の誤検出における各時刻の葉の動きの割合への影響 (8月31日)	32
5.9	葉領域の誤検出 (8月31日 11時35分)	32
5.10	葉領域の誤検出 (8月31日 18時50分)	33
5.11	葉領域の誤検出 (8月31日 7時20分)	33
A.1	(1時間ごと) 期間①7月31日の各時刻の葉の動きの割合	41
A.2	(1時間ごと) 期間①8月1日の各時刻の葉の動きの割合	42
A.3	(1時間ごと) 期間①8月2日の各時刻の葉の動きの割合	43
A.4	(1時間ごと) 期間②8月15日の各時刻の葉の動きの割合	44
A.5	(1時間ごと) 期間②8月16日の各時刻の葉の動きの割合	45
A.6	(1時間ごと) 期間③8月30日の各時刻の葉の動きの割合	46
A.7	(1時間ごと) 期間③8月31日の各時刻の葉の動きの割合	47
A.8	(6時基準) 期間①7月31日の各時刻の葉の動きの割合	48
A.9	(6時基準) 期間①8月1日の各時刻の葉の動きの割合	49

図目次

A.10 (6時基準) 期間①8月2日の各時刻の葉の動きの割合	50
A.11 (6時基準) 期間②8月15日の各時刻の葉の動きの割合	51
A.12 (6時基準) 期間②8月16日の各時刻の葉の動きの割合	52
A.13 (6時基準) 期間③8月30日の各時刻の葉の動きの割合	53
A.14 (6時基準) 期間③8月31日の各時刻の葉の動きの割合	54
A.15 (12時基準) 期間①7月31日の各時刻の葉の動きの割合	55
A.16 (12時基準) 期間①8月1日の各時刻の葉の動きの割合	56
A.17 (12時基準) 期間①8月2日の各時刻の葉の動きの割合	57
A.18 (12時基準) 期間②8月15日の各時刻の葉の動きの割合	58
A.19 (12時基準) 期間②8月16日の各時刻の葉の動きの割合	59
A.20 (12時基準) 期間③8月30日の各時刻の葉の動きの割合	60
A.21 (12時基準) 期間③8月31日の各時刻の葉の動きの割合	61
B.1 (1時間ごと) 期間①7月31日の各日の葉の動きの割合	63
B.2 (1時間ごと) 期間①8月1日の各日の葉の動きの割合	64
B.3 (1時間ごと) 期間①8月2日の各日の葉の動きの割合	65
B.4 (1時間ごと) 期間②8月15日の各日の葉の動きの割合	66
B.5 (1時間ごと) 期間②8月16日の各日の葉の動きの割合	67
B.6 (1時間ごと) 期間③8月30日の各日の葉の動きの割合	68
B.7 (1時間ごと) 期間③8月31日の各日の葉の動きの割合	69
B.8 (6時基準) 期間①7月31日の各日の葉の動きの割合	70
B.9 (6時基準) 期間①8月1日の各日の葉の動きの割合	71
B.10 (6時基準) 期間①8月2日の各日の葉の動きの割合	72
B.11 (6時基準) 期間②8月15日の各日の葉の動きの割合	73
B.12 (6時基準) 期間②8月16日の各日の葉の動きの割合	74
B.13 (6時基準) 期間③8月30日の各日の葉の動きの割合	75

図目次

B.14 (6時基準) 期間③8月31日の各日の葉の動きの割合	76
B.15 (12時基準) 期間①7月31日の各日の葉の動きの割合	77
B.16 (12時基準) 期間①8月1日の各日の葉の動きの割合	78
B.17 (12時基準) 期間①8月2日の各日の葉の動きの割合	79
B.18 (12時基準) 期間②8月15日の各日の葉の動きの割合	80
B.19 (12時基準) 期間②8月16日の各日の葉の動きの割合	81
B.20 (12時基準) 期間③8月30日の各日の葉の動きの割合	82
B.21 (12時基準) 期間③8月31日の各日の葉の動きの割合	83
C.1 期間① 7月31日の日射量と気温	84
C.2 期間① 8月1日の日射量と気温	84
C.3 期間① 8月2日の日射量と気温	85
C.4 期間② 8月15日の日射量と気温	85
C.5 期間② 8月16日の日射量と気温	85
C.6 期間③ 8月30日の日射量と気温	85
C.7 期間③ 8月31日の日射量と気温	85

表目次

4.1 各期間における撮影期間，接種日，発病確認日	16
-------------------------------------	----

第 1 章

序論

1.1 背景

ショウガに発生する病害の中でも被害の大きい病害の一つとして根茎腐敗病があげられる。ショウガ栽培が盛んな高知県においては、平成 29 年度から令和 2 年度までの 4 年間のデータにおいて施設栽培と露地栽培合わせて毎年 30%から 35%程度の被害が報告されている [1]。この病害は土壌伝染、種子伝染、水媒伝染により感染し、特に水媒伝染では、大雨などにより病原菌が混入した水が圃場内に侵入して感染源となるほか、発病株から周辺の株へと二次伝染するなど被害が拡大しやすいという特徴があるため、栽培現場では非常に警戒されている。根茎腐敗病に感染したショウガはできる限り早い段階で取り除く必要があるが、栽培現場では現状、根茎腐敗病に感染した株について葉の黄化などの特有の症状を基に判断を行っており、症状が見られる頃には既に周辺株に感染が広がっていることが多いという問題があった。このため、根茎腐敗病の症状が現れる前の段階で感染したショウガを早期に検出する方法が求められている。

このショウガ根茎腐敗病を早期に検出するため、著者らは以前から病原菌を意図的に接種した株（以下、接種株とする）と病原菌を接種していない株（以下、無接種株とする）を用意した上で、熱画像を用いた早期検出方法について検討を行っており [2][3]、この研究の過程で、ショウガの葉に 1 日の中で閉じる、広がるといった周期的な動きがあることを発見した。この動きは、同じショウガ科に属するマンゴー・ジンジャーにおいても見られるものであり、これらの葉の動きは日光や温度との関係性が指摘されている [4]。この葉の動きはショウガにおいて一般的に行われているものであると考えられるが、今回著者らは接種株におい

1.2 目的

て接種日から日が進むにつれてこの葉の動きがあまり見られなくなることを確認した。この傾向は、病害によって日常的に行われている葉の動きが阻害されるために現れるものであると著者らは考え、この葉の動きの違いを根茎腐敗病に感染したショウガの検出に応用できると考えた。

1.2 目的

1.1 節から本報告では、ショウガ根茎腐敗病の早期検出を目的として、病原菌接種株と無接種株において葉の動きを定量化する方法について提案し、提案手法が接種株と無接種株を判別する上で有効であるか検証した。

1.3 本論文の構成

本論文では、はじめに本研究にて扱った関連技術について2章で述べる。その後、提案手法として接種株と無接種株において葉の動きを定量化する方法について3章で述べる。提案手法における接種株と無接種株の判別精度の検証のために使用したデータや、検証条件などを4章で述べ、検証によって得られた検証結果や考察を5章で述べる。最後に6章にて本研究における結論について述べる。

第 2 章

関連技術

2.1 Support Vector Machine

Support Vector Machine(以下, SVM とする) は 2 クラス分類を行う教師有りの機械学習手法の一つである. SVM は学習データにおける特徴量空間において, クラスの境界付近にそれらしい超平面を引くことでそれを識別境界とし, その識別境界を基にして識別を行う. 超平面は特徴量の次元数 n に対して $n - 1$ の次元における空間のことであり, 例えば特徴量の次元数が 2 次元の場合, 1 次元の境界である直線をひき, それを識別境界とする. SVM はマージンの最大化と呼ばれる考え方をを用いて学習を行う. これはサポートベクタと呼ばれる識別境界に最も近いデータと, 識別境界の間の距離が最も大きくなるように学習させるものである [5].

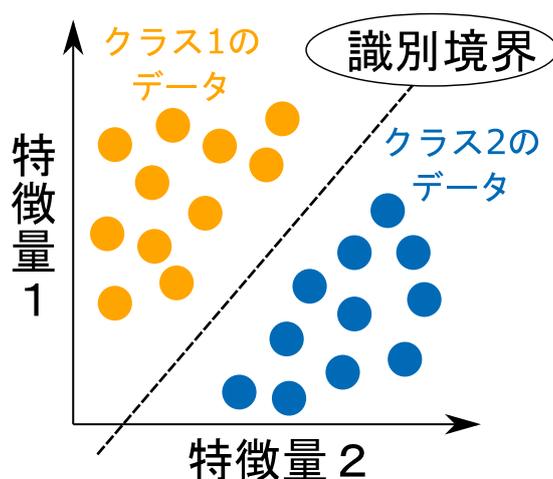


図 2.1: SVM における識別境界の例

2.1 Support Vector Machine

SVMでは、複数の特徴量とそれらに対応するクラスから最良の識別境界を引くことになる。学習データにおける n 次元の特徴量のベクトル $\mathbf{x} = (x_1, x_2, \dots, x_n)^\top$ と識別境界における重み係数のベクトル $\mathbf{w} = (w_1, w_2, \dots, w_n)^\top$ 、バイアス項 b を考えたとき、識別関数は式 (2.1) で表される [5]。 $\text{sgn}(\mathbf{w}^\top \mathbf{x} + b)$ は、 $\mathbf{w}^\top \mathbf{x} + b > 0$ なら $+1$ 、 $\mathbf{w}^\top \mathbf{x} + b \leq 0$ なら -1 を出力するものである。

$$f(\mathbf{x}) = \text{sgn}(\mathbf{w}^\top \mathbf{x} + b) \quad (2.1)$$

このとき、識別境界とサポートベクタにおける距離を考える場合、学習データの各データ \mathbf{x}_i における識別境界との距離 d_i は式 (2.2) で表される [5]。 y_i は各データにおけるクラスを表しており、このクラスは2クラスであることを考慮して、 $y_i \in \{-1, +1\}$ であるとす。このとき求められる距離はクラス $y_i \in \{-1, +1\}$ を用いて表現される符号付きの距離となる。

$$d_i = y_i \frac{(\mathbf{w}^\top \mathbf{x}_i + b)}{\|\mathbf{w}\|} \quad (2.2)$$

マージンの最大化の考え方に基づいてサポートベクタにおける識別境界との距離が最大になるように最適化問題を解き、重み係数のベクトル \mathbf{w} とバイアス項 b を求めることで識別境界を求める。最適化問題を解く際には、学習データにおける特徴点が識別境界によって完全に2クラスに分かれることを前提として制約条件を設けるが、現実のデータでは識別境界によって完全に2クラスに分かれる場合は少ないため、ある程度クラス内の特徴量の誤差を許容するために、コストパラメータなどのパラメータを導入して求める処理が必要となる [5]。

2.1.1 カーネルトリック

SVMにおいて識別境界を学習させる際には、学習データの2クラスのデータを線形の超平面で分離できると考えて学習を行うが、学習データによっては特徴量の分布が複雑になり線形の超平面で分離できない場合も存在する。このとき、学習データにおける特徴量空間を非線形写像により高次元空間に写像することで、線形の超平面で分離できるようにして識別境界を学習させる。このとき、高次元空間に写像する処理を経由せず、その処理において

2.1 Support Vector Machine

必要となる特徴量空間における内積の計算をカーネル関数に置き換えて計算させる方法をカーネルトリックという [6]. カーネル関数を導入した識別関数は次の式 (2.3) によって表される. このカーネル関数には多項式カーネルや RBF カーネルなど様々な種類があり, 学習データの性質などを踏まえて開発者が決定する必要がある [7]. p 次の多項式カーネルを式 (2.4), RBF カーネルを式 (2.5) に示す [7].

- カーネル関数を導入した識別関数

$$f(x) = \text{sgn}\left(\sum_{i=1}^m w_i K(\mathbf{x}, \mathbf{x}_i) + b\right) \quad (2.3)$$

- 多項式カーネル

$$K(\mathbf{x}, \mathbf{x}_i) = (1 + \mathbf{x}^\top \mathbf{x}_i)^p \quad (2.4)$$

- RBF カーネル

$$K(\mathbf{x}, \mathbf{x}_i) = \exp(-\gamma \|\mathbf{x} - \mathbf{x}_i\|^2) \quad (2.5)$$

2.1.2 グリッドサーチ

SVM などの機械学習手法において学習モデルを作成する際には, ハイパーパラメータと呼ばれる人の手によって指定する必要があるパラメータが存在する. このハイパーパラメータを探索する方法の一つにグリッドサーチがある. この方法は複数のハイパーパラメータの候補に対してそれらの組み合わせを 1 つずつ総当たりで検証することによって最良のハイパーパラメータを探索する.

2.1.3 交差検証

グリッドサーチによるハイパーパラメータを探索する上で良く用いられる検証方法に交差検証がある. 交差検証は使用するデータを k 個に分割し, そのうち $k - 1$ 個を学習データ, 残りの 1 つを評価データとした上で, 学習データと評価データを 1 つずつ入れ替えながら k 個に分割したデータ全てにおける評価を行い, これらの評価の平均値を最終的な評価として出力するものである.

2.2 ROC 曲線

2.2 ROC 曲線

ROC 曲線とは Receiver Operating Characteristic Curve の略称で、特定の指標から 2 つのクラスを判別する場合の性能をグラフ上に表したものである。対象となる指標について 2 つのクラスの境界となる閾値をずらしながら判別を行い、実際の正解クラスと比較した場合の真陽性率をグラフの縦軸、偽陽性率をグラフの横軸にとってグラフ化したものである。ROC 曲線の例を図 2.2 に示す。

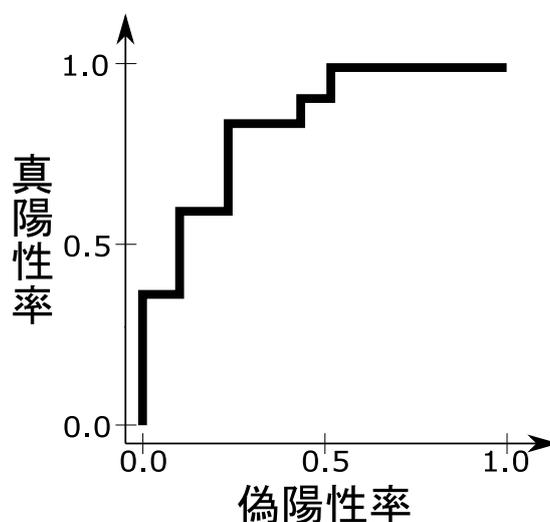


図 2.2: ROC 曲線の例

2.2.1 AUC

ROC 曲線における曲線下の面積は Area Under the Curve(以下、AUC と呼ぶ) と呼ばれ、特定の指標から 2 つのクラスを判別する場合の性能を数値化したものとして扱われる。AUC の最高値は 1 で、この場合は特定の閾値で真陽性率 100%、偽陽性率 0%を実現でき、全てのデータを正確に判別できることを示す。逆に判別性能が悪いと AUC は 0.5 に近づき、どの閾値においてもデータを正確に判別できないことを示す。これらの AUC が 1 の場合と AUC が 0.5 の場合の ROC 曲線の例を図 2.3 と図 2.4 に示す。

2.2 ROC 曲線

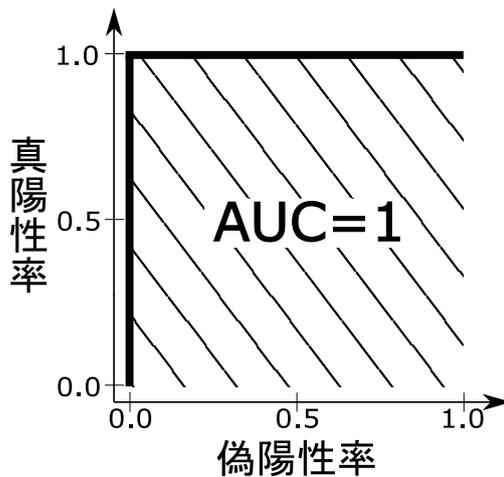


図 2.3: ROC 曲線 (AUC=1)

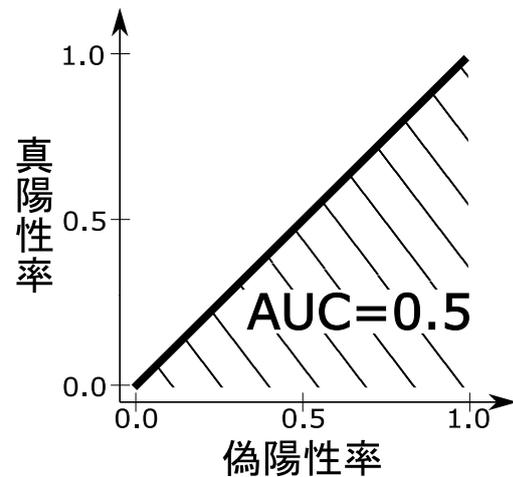


図 2.4: ROC 曲線 (AUC=0.5)

2.2.2 Youden's Index

Youden's Index は、W.J.Youden によって提案された判別精度を評価する方法の一つである [8]。ROC 曲線から最も真陽性率と偽陽性率のバランスがよい最良の閾値を探索する方法として使用される。Youden's Index は真陽性率+特異度-1 で表される値であり、ROC 曲線においては、AUC が 0.5 となる ROC 曲線と求めた ROC 曲線の間の長さと同じ。この例を図 2.5 に示す。ROC 曲線から最良の閾値を探索する場合、この Youden's Index が最大になる点における閾値を最良閾値として設定する。

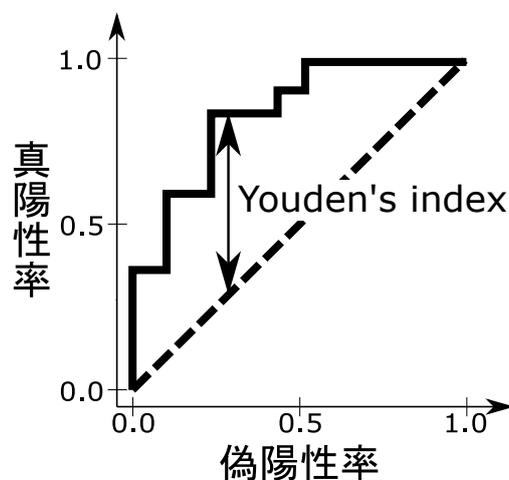


図 2.5: ROC 曲線上の Youden's Index

第3章

提案手法

本章では提案手法の全体の流れや各工程について詳細に述べる。

3.1 提案手法の概要

提案手法では、接種株と無接種株における葉領域に対する葉の動きの割合を求めることで定量化を行う。ショウガを撮影した各時刻の画像データから葉領域を検出し、それらの葉領域から葉の動きと分母となる葉領域を検出した上で、分母となる葉領域に対する葉の動きの割合を求めることで各時刻の葉の動きの割合を定量化する。この各時刻の葉の動きの割合について時間方向に累積をとることによって日ごとに葉の動きの割合を求め、これを接種株と無接種株を判別するための指標とする。提案手法の流れを図3.1に示す。

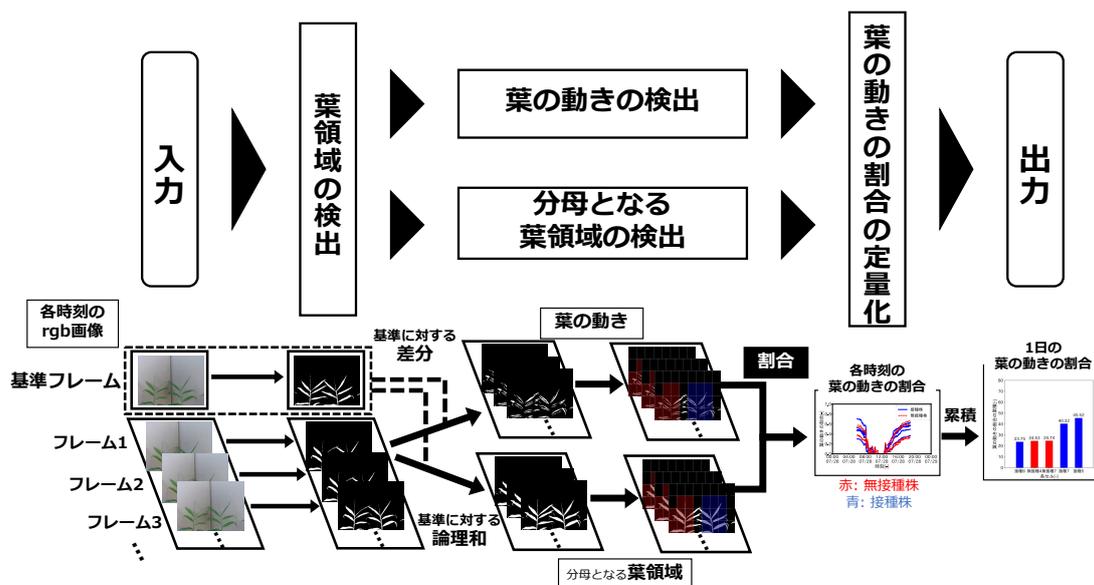


図 3.1: 提案手法の流れ

3.2 葉領域の検出

はじめに各時刻において撮影された画像から画素ごとに葉領域を検出する。葉領域の検出では、主に Excess green と呼ばれる指標を用いて検出を行う。

Excess green(以下, ExG とする) は, D.M.Woebbecke らによって提案された土壌などの背景と葉領域を分離する上で有効とされている指標である [9]。この ExG と判別分析法を用いて葉領域を抽出し, 葉のしおれを検出する方法が提案されており [10], 今回著者らは ExG を使用した葉領域の検出を行った。

ExG は次の式 (3.1) で表される。

$$\text{ExG} = 2g - r - b \quad (3.1)$$

式 (3.1) における r , g , b は色度座標を示しており, 各画素における RGB 値である R , G , B をそれぞれ RGB 値の総和で正規化したものによって表される。 r , g , b は次の式 (3.2), (3.3), (3.4) で表され, これらの値には次の式 (3.5) の関係が成り立つ。

$$r = \frac{R}{R + G + B} \quad (3.2)$$

$$g = \frac{G}{R + G + B} \quad (3.3)$$

$$b = \frac{B}{R + G + B} \quad (3.4)$$

$$r + b + g = 1 \quad (3.5)$$

このとき, 色度座標 r , g , b は RGB 色空間における座標 $(1,0,0)$, $(0,1,0)$, $(0,0,1)$ を通る面における交点を示しており, これらの色度座標は明度を無視して色相と彩度のみで色を表現することになる [11]。

ExG はこれらの色度座標を使用した指標であることから, 本質的に明度の情報が考慮されておらず, ExG のみを用いる方法では照明環境が異なる場合には適さないと考えられた。このため今回著者らは, ExG と明度を特徴量として SVM を用いて葉領域の特徴を学習させ, 学習したモデルから画素ごとに葉領域を検出する方法を用いた。今回は教師画像として

3.3 葉の動きの検出

葉領域と背景領域を著者らが手動で塗りつぶした画像を用意し、この画像によって各画素のクラスを定義した上で、それらのクラスの特徴量から学習を行い、葉領域の検出を行った。

そして今回は各日の 6 時から 18 時 55 分までに 5 分ごとに撮影された画像において葉領域を検出し、検出結果から葉の動きや分母となる葉領域を求め、葉の動きの割合を求める。

3.3 葉の動きの検出

各時刻の葉領域を用いて葉の動きを検出する。ここでは基準となるフレームと各時刻のフレームの葉領域の差分を求め、ノイズを除去した上で葉の動きを求める。この葉の動きの検出の流れを図 3.2 に示す。

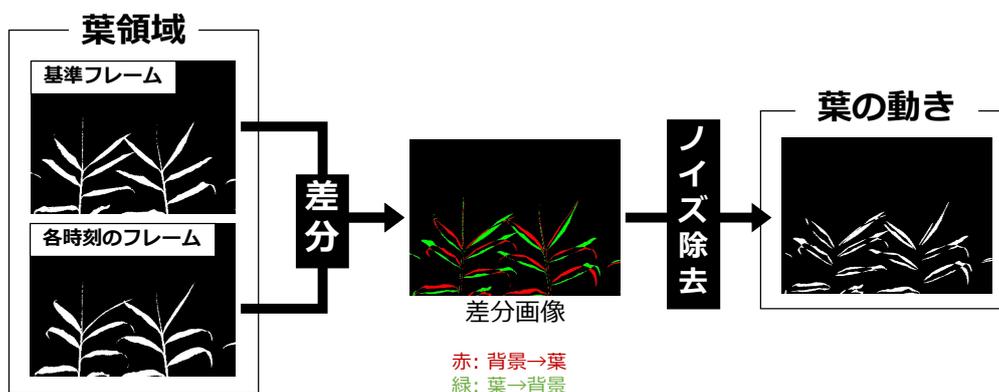


図 3.2: 葉の動きの検出の流れ

はじめに各日の 6 時から 18 時 55 分までに 5 分ごとに撮影された画像において、基準となるフレームと各時刻のフレームにおける葉領域の差分を取る。差分を取る際には、背景から葉となった領域と葉から背景となった領域が存在するため、これらを葉の動きとして扱う。

差分を求める際には、葉領域の検出結果によって細かなノイズが発生する可能性がある。このため、差分を取った後の画像においてラベリングにより連結している領域を求め、この領域が閾値 30 以下であるものをノイズとして除去する。この閾値 30 は著者らが実際の撮影画像から葉の動きを確認した上で主観により決定した。ノイズを除去する際には、差分を取る際に発生した背景から葉になった領域と、葉から背景となった領域を別々の領域とみな

3.3 葉の動きの検出

して連結領域を求め、ノイズ除去を行っている。ノイズ除去後の葉の動きは背景から葉、葉から背景となった領域ともに同じ葉の動きとして扱う。

また、今回は日中である6時から18時55分までに5分ごとに撮影された画像において葉の動きの差分を求めるが、差分の取得方法の異なる3つの方法を提案した。

3.3.1 1時間ごとに葉の動きを求める方法

差分をとるフレームの時間差が1時間となるようにして差分をとり、葉の動きを求める方法である。6時の画像の葉領域と、7時の画像の葉領域の差分をとり、7時の葉の動きとして記録する。次に、6時5分の画像の葉領域、7時5分の画像の葉領域の差分をとり、7時5分の葉の動きとして記録する。同様に5分ずつずらしながら、18時55分までの葉の動きを求める。この流れを図3.3に示す。

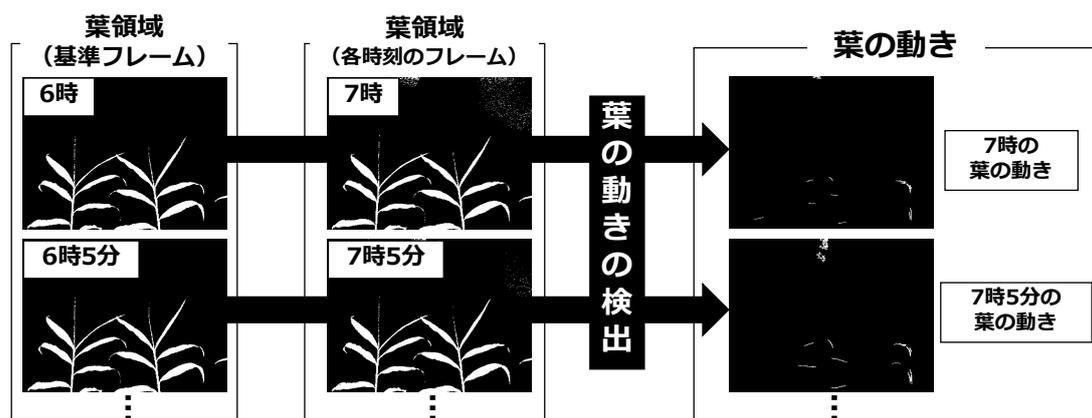


図 3.3: 1時間ごとに葉の動きを求める方法の流れ

3.3.2 6時の画像を基準として葉の動きを求める方法

各日の6時の画像を基準フレームとして、各時刻フレームとの差分をとって葉の動きを求める。基準フレームである6時の画像の葉領域と、6時の画像の葉領域の差分をとり、6時の葉の動きとして記録する。次に、基準フレームである6時の画像の葉領域、6時5分の画像の葉領域の差分をとり、6時5分の葉の動きとして記録する。同様に5分ずつずらしながら、18時55分までの葉の動きを求める。この流れを図3.4に示す。

3.3 葉の動きの検出

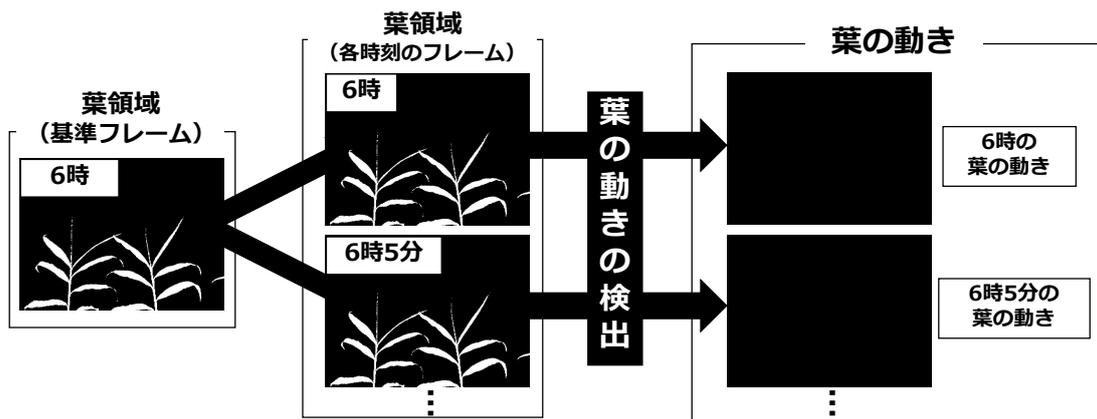


図 3.4: 6 時の画像を基準として葉の動きを求める方法の流れ

3.3.3 12 時の画像を基準として葉の動きを求める方法

各日の 12 時の画像を基準フレームとして、各時刻フレームとの差分をとって葉の動きを求める。基準フレームである 12 時の画像の葉領域と、6 時の画像の葉領域の差分をとり、6 時の葉の動きとして記録する。次に、基準フレームである 12 時の画像の葉領域、6 時 5 分の画像の葉領域の差分をとり、6 時 5 分の葉の動きとして記録する。同様に 5 分ずつずらしながら、18 時 55 分までの葉の動きを求める。この流れを図 3.5 に示す。

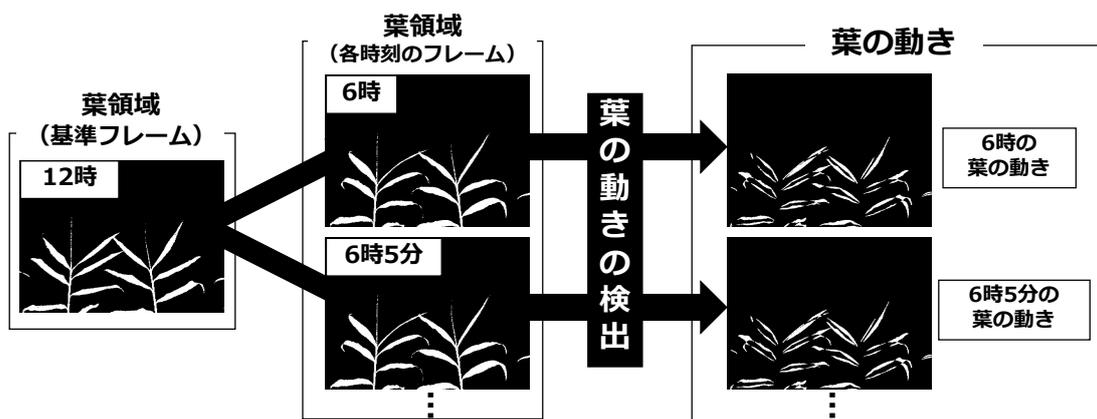


図 3.5: 12 時の画像を基準として葉の動きを求める方法の流れ

3.4 分母となる葉領域の検出

3.4 分母となる葉領域の検出

今回は、分母となる葉領域に対する葉の動きの割合を求めて定量化を行うため、葉の動きに対応する分母となる葉領域を求める必要がある。ここでは、葉の動きを求める際に使用した2枚の画像の葉領域の論理和をとることで分母となる葉領域を求める。例えば、12時の画像の葉領域と、6時の画像の葉領域の差分をとり、6時の葉の動きとして記録した場合は、12時の画像の葉領域と、6時の画像の葉領域の論理和を分母となる葉領域とする。

3.5 葉の動きの割合の定量化

求めた各時刻の葉の動きと分母となる葉領域を基に葉の動きの割合を求め、定量化を行う。6時から18時55分までに5分ごとに撮影された画像において、それぞれ3つの方法で各時刻の葉の動きと分母となる葉領域を求め、それらの画像を接種株と無接種株のセルに分けた上で、各セルの分母となる葉領域の画素数に対して求めた葉の動きの画素数の割合を求めることで接種株と無接種株の各セルにおける各時刻の葉の動きの割合を求める。この流れを図3.6に示す。

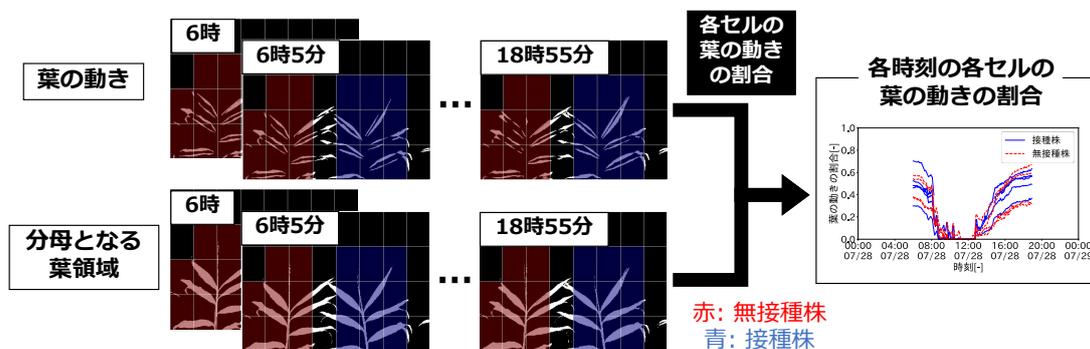


図 3.6: 接種株と無接種株における各時刻の葉の動きの割合を求める流れ

このとき、セル内の分母となる葉領域が小さすぎるために、定量化した葉の動きの割合が極端に大きくなることを防ぐため、各セル内の分母となる葉領域の割合が20%に満たない場合は、葉の動きの割合が正しく定量化できないと判断し、欠損値として扱う。

各時刻の葉の動きの割合を求めた後、この値について日ごとに時間方向に累積をとること

3.5 葉の動きの割合の定量化

によって、各日の葉の動きの割合を求め、これを接種株と無接種株を判別するための指標とする。この流れを図 3.7 に示す。

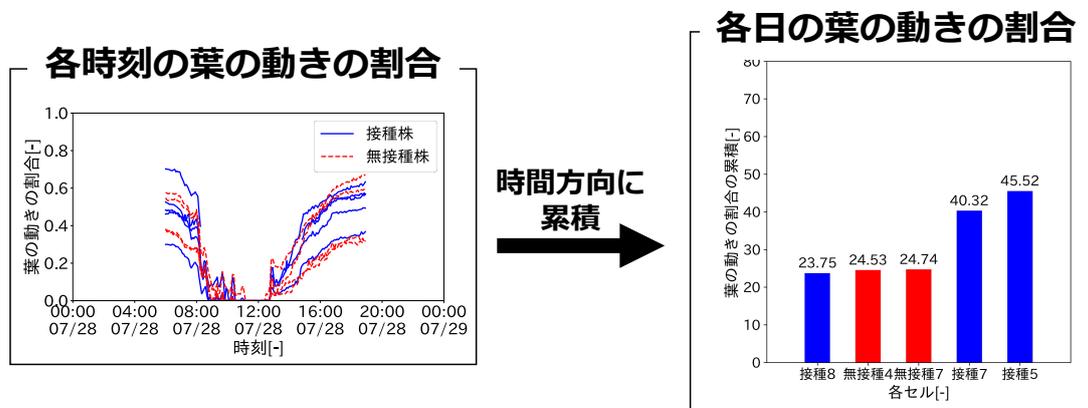


図 3.7: 各時刻の葉の動きの割合から各日の葉の動きの割合を求める流れ

このとき、各時刻の葉の動きの割合を求める際に欠損値が発生しているセルがある場合、そのセルの値は判定に使用しないものとする。

第 4 章

検証

本章では提案手法を検証するための検証データや、検証条件、検証内容について述べる。

4.1 検証データ

今回提案手法において葉の動きを定量化するにあたり、ガラスハウスにて病原菌接種株と無接種株を撮影した画像を用いた。このデータにおける撮影環境や撮影期間、発病状況などを以下で述べる。

4.1.1 撮影環境

今回は検証データとして高知県農業技術センター内のガラスハウスにて撮影されたものを使用する。撮影では、ショウガの株を正面から撮影する web カメラ 1 台、斜めから撮影する web カメラおよび赤外線カメラそれぞれ 1 台の合計 3 台を用いて撮影を行った。今回はショウガの株を正面から撮影した画像を検証に使用し、斜めから撮影した画像や赤外線カメラによって撮影された熱画像は葉の動きや温度を確認する補助的な要素として使用した。撮影に使用した web カメラは BUFFALO 社製 BSW50KM02 で、撮影は python により作成したプログラムを用いて行った。この撮影の様子を図 4.1、今回使用する正面から株を撮影した画像の例を図 4.2 に示す。ここでは背景に板を設置した状態で、接種株が画像の右側、無接種株が画像の左側に 1 株ずつ写るように設置して撮影を行っている。

4.1 検証データ



図 4.1: 撮影の様子

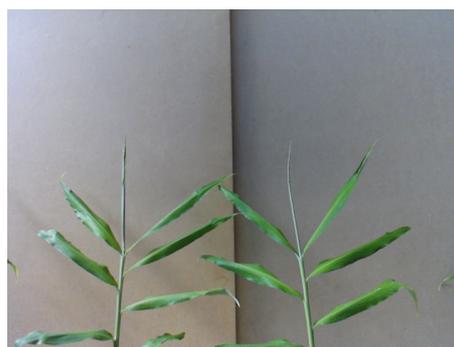


図 4.2: 撮影した画像の例

4.1.2 撮影期間・発病状況

今回は 2021 年 7 月 27 日から 9 月 2 日までの期間において病原菌接種株と無接種株を入れ替えながら 3 期間分撮影を行った。撮影では、接種株において病原菌を接種した日から発病確認日の翌日までの期間において撮影を行ったものを 1 期間としてカウントし、撮影が終わるごとに新たな無接種株、および新たに病原菌を接種した接種株に入れ替えながら 3 期間分撮影を行っている。また、それぞれの期間において撮影は 5 分ごとに行っている。今回検証に用いる 3 期間のデータにおける撮影期間、接種日、発病確認日を以下の表 4.1 に示す。表 4.1 では、各期間を①～③の丸数字として表現しており、以降では各期間の接種日や撮影期間、発病確認日を省略し、これらの丸数字によって各期間を示す。この発病確認日は高知県農業技術センター病理担当職員が評価し、判定したデータを用いている。

表 4.1: 各期間における撮影期間、接種日、発病確認日

期間	撮影期間	病原菌接種日	発病確認日
①	7月27日 10時15分～8月3日 10時5分	7月27日	8月2日
②	8月3日 10時30分～8月17日 13時5分	8月3日	8月16日
③	8月25日 13時30分～9月2日 13時5分	8月25日	9月1日

4.2 検証条件

4.1.3 検証に使用するデータの期間

今回撮影された画像データのうち、発病確認日 2 日または 3 日前から無接種株よりも接種株の方が葉の動きが小さくなることを著者らが確認したため、発病確認日 3 日前から発病確認日までの葉の動きを定量化し、接種株と無接種株を判別した場合の精度を評価する。また、今回は提案手法の前提条件として日中 6 時から 18 時 55 分のデータを使用して 1 日の葉の動きを定量化するため、この時刻のデータがない日は検証の対象から除外する。加えて、人が株を動かすなどの別の要因で葉が動いた日や雨など天候により明らかに葉の動きが小さくなっていると著者らが確認した日は除外して検証を行う。このため撮影した期間のうち、上記の条件に当てはまる日付は次の 7 日間で、今回はこれらの 7 日間のデータを使用して検証を行う。

各期間において検証に使用するデータ

- 期間①: 7 月 31 日, 8 月 1 日, 8 月 2 日
- 期間②: 8 月 15 日, 8 月 16 日
- 期間③: 8 月 30 日, 8 月 31 日

4.2 検証条件

上記で述べた検証データを使用して提案手法による葉の動きの定量化を行う際に、提案手法の各工程において使用するデータ、条件について述べる。ここでは、葉領域の検出における教師画像や SVM による学習モデル作成の条件、葉の動きの割合を求める際の接種株と無接種株の各セルの定義について述べている。また、提案手法を用いて各時刻の葉の動きを求めた際に、午前と午後の葉の動きの割合が異なることを発見したため、これを検証の条件として追加することについても述べている。

また、今回は提案手法の実装にあたり、python を使用した。葉領域の検出において使用する SVM は機械学習ライブラリである scikit-learn を用いて検出を行っている。

4.2 検証条件

4.2.1 葉領域の検出における教師画像と学習モデルの作成

提案手法における葉領域の検出の際には、著者らが葉領域を手動で塗りつぶした教師画像を用いて学習データにおけるクラスを定義した上で、SVMにより葉領域の特徴量を学習させ、作成したモデルから検出を行う。今回検証データのうち学習に使用する教師画像は、日の当たり方による葉領域の誤検出を防ぐ目的から、日の当たり方が異なる7月27日10時15分の画像と、7月29日7時40分の画像の2枚を用いた。この画像をそれぞれ図4.3と図4.4に示す。この画像における黒の領域は背景であり、白の領域は葉を示している。また、赤の領域は除外領域を示している。この除外領域とは、葉と背景の境界付近の画素のことで、今回は境界に最も近い葉側の1画素と背景側の1画素を除外領域としている。この領域は葉と背景どちらの特徴をもっていることが多いと考えたため、学習対象から除外している。

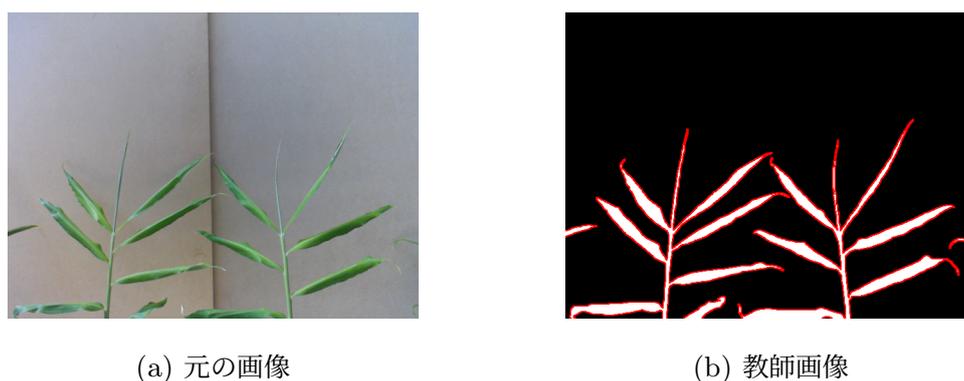


図 4.3: 検証に使用した教師画像 (7月27日10時15分) (黒色:背景, 白色:葉, 赤色:除外)



図 4.4: 検証に使用した教師画像 (7月29日7時40分) (黒色:背景, 白色:葉, 赤色:除外)

4.2 検証条件

今回学習の際には RBF カーネルを用いてモデルを作成し、学習に必要なパラメータであるコストパラメータ C と RBF カーネルのパラメータ γ はグリッドサーチによって決定した。これらは python の scikit-learn によって実装を行っている。

今回グリッドサーチにおいて指定したハイパーパラメータは実装に使用した python の scikit-learn のデフォルト値である $C=1$, $\text{gamma}='scale'$ より、 $C=0.01, 0.1, 1, 10, 100$, $\text{gamma}=0.01, 0.1, 1, 'scale', 10, 100$ とし、この中から最適なハイパーパラメータを決定した。 gamma における $'scale'$ は、 $1/(\text{データの分散} \times \text{データ数})$ から求められるものである。今回はデータを 3 分割して交差検証を行って評価しており、評価指標には背景として誤検出される葉領域を減らす目的から再現率を用いた。グリッドサーチで使用するデータは、前述した 2 枚の教師画像から得られたクラスと特徴量のデータのうち、モデルの学習用に 75%、モデルの評価用に 25% のデータを使用して評価している。

教師画像からクラスと特徴量を定義して学習を行った場合、最良のパラメータは $C=100$, $\text{gamma}=100$ となり、このパラメータにおける SVM の識別境界は図 4.5 となった。

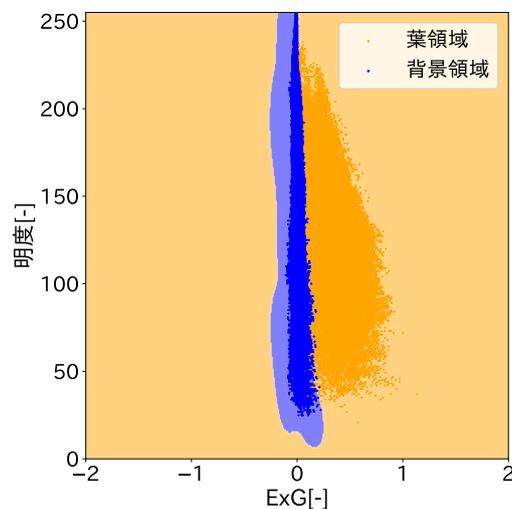


図 4.5: 葉領域検出の際の SVM による識別境界 ($C=100$, $\text{gamma}=100$)

図 4.5 における橙と青の点が学習データにおける葉と背景の領域の値を示しており、これによって求められた橙と青の境界が識別境界にあたる。この識別境界における学習データと評価データの正答率はそれぞれ小数点以下第 4 位を四捨五入した場合、99.657%と 99.673%

4.2 検証条件

であった。今回はこのパラメータによって作成された SVM のモデルを使用して画素ごとに葉領域の検出を行う。

4.2.2 葉の動きの割合を求める際の接種株と無接種株の定義

提案手法では葉の動きの割合を求める際に、接種株と無接種株のセルを著者らが手動で決めた上で、各セルにおける分母となる葉領域の画素数に対する葉の動きの画素数の割合を求めることで、各時刻の葉の動きの割合を求める。ここで使用する各セルの定義は検証データの期間ごとに異なるものである。期間ごとに特定の1枚の画像から著者らが各セルの接種株や無接種株の定義を決め、期間ごとに接種株と無接種株の葉の動きの割合を求めている。各期間の各セルの定義を図4.6, 4.7, 4.8に示す。各セルの定義は、画像を 8×4 のセルに分割した上で、著者らの主観により無接種株・接種株・背景・不明の4つのセルに手動で分けて決めている。背景は葉領域がほとんどないと思われるセルで、不明は無接種株と接種株の葉が同じセル内に存在しているものであり、これらのセルは葉の動きの割合を求める対象から除外する。接種株と無接種株の各セルには番号を割り振っており、これにより各セルの値を管理している。

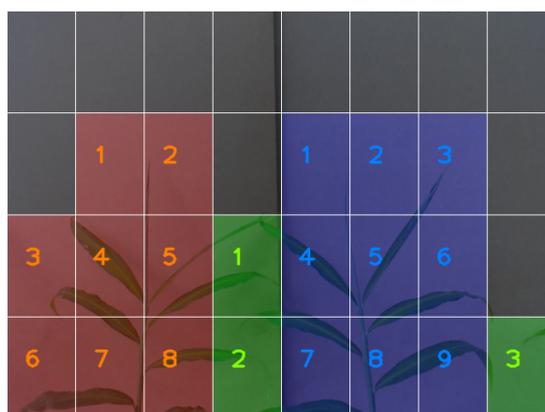


図 4.6: 期間①の各セルの定義 (赤色: 無接種株, 青色: 接種株, 灰色: 背景, 緑色: 不明)

4.2 検証条件

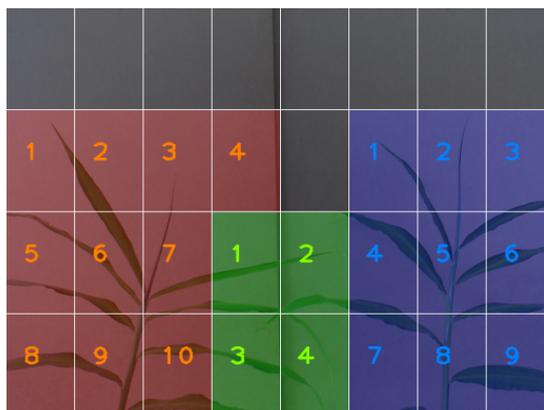


図 4.7: 期間②の各セルの定義 (赤色: 無接種株, 青色: 接種株, 灰色: 背景, 緑色: 不明)

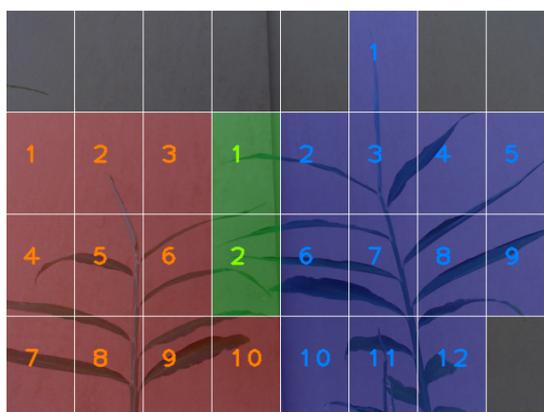


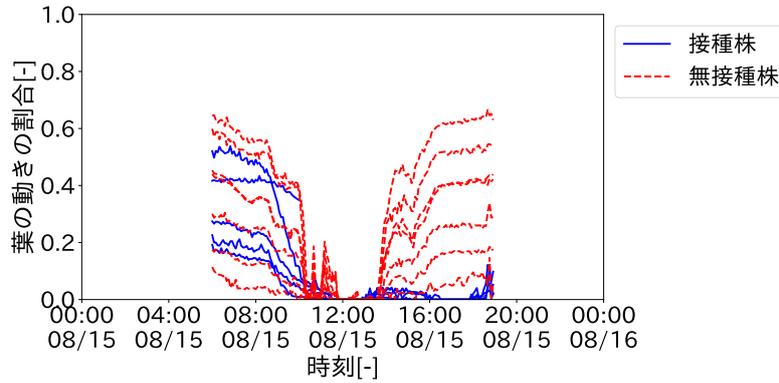
図 4.8: 期間③の各セルの定義 (赤色: 無接種株, 青色: 接種株, 灰色: 背景, 緑色: 不明)

4.2.3 午前と午後の葉の動きの割合の違いにおける検証条件の追加

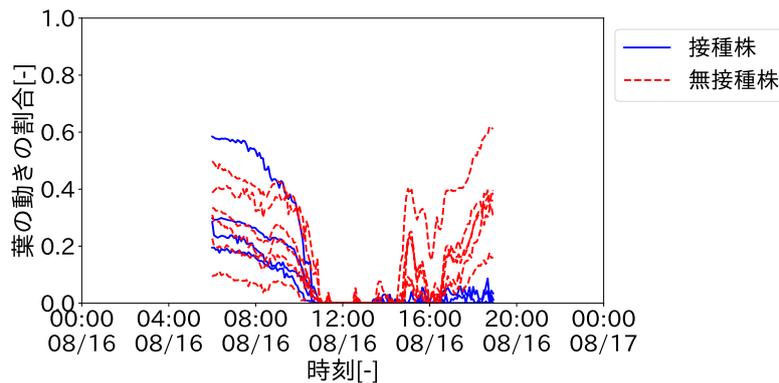
今回著者らは、検証を行う前に検証データにおける日中6時から18時55分の各時刻における葉の動きの割合を求め、グラフに出力して観察した。このとき、各日の12時の画像を基準として葉の動きを求める場合の期間②の8月15日と8月16日の結果において、午後になると接種株の葉の動きが無接種株よりも小さくなるセルが多いことを確認した。この傾向が確認された期間②の8月15日と8月16日の各時刻の葉の動きの割合のグラフを図4.9に示す。図4.9における赤の破線が無接種株のセルにおける葉の動きの割合であり、青の線が接種株のセルにおける葉の動きの割合を示している。無接種株の赤の破線と接種株の青の線はグラフ上に複数あるが、これらは接種株と無接種株の各セルにおける各時刻の葉の

4.2 検証条件

動きの割合を示している。このグラフを見ると、6時から12時までの午前中の葉の動きの割合は接種株も無接種株も同じように大きいですが、午後になると接種株のセルのみ葉の動きの割合が小さくなっていることがわかる。



(a) 8月15日



(b) 8月16日

図 4.9: 午前と午後の各時刻の葉の動きの割合の違いの例

この葉の動きは実際の画像においても確認されるものであり、これが判別に影響を与えると考えたため、午前中のデータを除外し、12時から18時55分までの時刻において葉の動きの割合を求めた上で時間方向に累積をとって各日の葉の動きの割合とした場合についても判別精度を評価した。

4.3 検証内容

上記の検証データ、検証条件を基にして検証を行う。検証では、提案手法において提案した葉の動きの求め方が異なる3つの方法によって各日の葉の動きの割合を定量化し、それぞれ接種株と無接種株の判別精度の比較を行う。また、前節において午前と午後で各時刻の葉の動きの割合が違うことが確認されたため、これを考慮して日中6時から18時55分の各時刻の葉の動きの割合を求めて時間方向に累積をとり、各日の葉の動きの割合を求める場合と、午前中を除外した12時から18時55分の各時刻の葉の動きの割合を求めて時間方向に累積をとり、各日の葉の動きの割合を求めた場合についても比較を行う。

今回各手法において接種株と無接種株の判別精度を評価する際には、ROC曲線とAUCを用いて評価を行い、Youden's Indexによる最良閾値を用いた場合の正答率、真陽性率、偽陽性率についても評価を行った。また、今回は提案手法で求めた接種株と無接種株の葉の動きの割合について、閾値を0.01ずつ変化させながら真陽性率と偽陽性率を求めてROC曲線を求めており、これによりYouden's Indexで得られる最良閾値も小数点第2位までの数値となっている。

第 5 章

結果・考察

本章では、提案手法における検証の結果と考察について述べる。

5.1 結果

提案手法において、葉の動きを求める範囲の異なる 3 つの方法における接種株と無接種株の判別精度を ROC 曲線と AUC, Youden's Index による最良閾値における正答率, 真陽性率, 偽陽性率により評価した。また, 午前と午後で各時刻の葉の動きの割合が違うことを考慮し, 日中全てもしくは午前中を除外した場合の各時刻の葉の動きの割合から各日の葉の動きの割合を求めた場合における判別精度も評価した。なお, AUC は小数点以下第 4 位を四捨五入して表記し, それ以外の値は小数点以下第 3 位を四捨五入して表記している。

5.1.1 1 時間ごとに葉の動きを求める方法

1 時間ごとに葉の動きを求めた場合の ROC 曲線と AUC, Youden's Index による最良閾値における正答率, 真陽性率, 偽陽性率を次に示す。

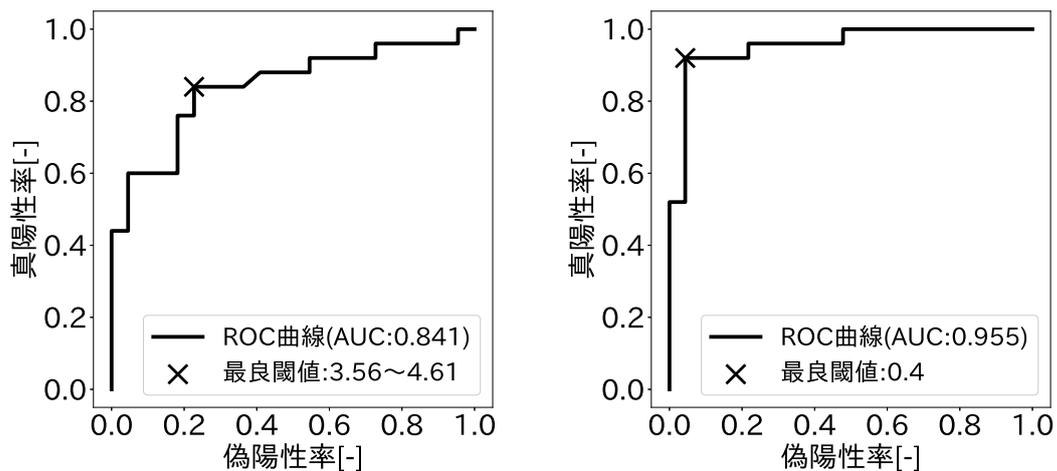
日中の各時刻の葉の動きの割合を用いて各日の葉の動きの割合を求めた場合, ROC 曲線は図 5.1(a) となり, AUC は 0.841 となった。この場合, Youden's Index より求められた最良の閾値は 3.56 付近の値となり, この閾値による正答率は 80.85%, 接種株を陽性とした場合の真陽性率は 84%, 偽陽性率は 22.73% となった。このとき, 真陽性率が 100% となるように閾値を決めた場合, 偽陽性率の最小値は 95.45% となった。

午後の各時刻の葉の動きの割合を用いて各日の葉の動きの割合を求めた場合, ROC 曲線

5.1 結果

は図 5.1(b) となり、AUC は 0.955 となった。この場合、Youden's Index より求められた最良の閾値は 0.4 となり、この閾値による正答率は 93.75%、接種株を陽性とした場合の真陽性率は 92%、偽陽性率は 4.35%となった。このとき、真陽性率が 100%となるように閾値を決めた場合、偽陽性率の最小値は 47.83%となった。

1 時間ごとに葉の動きを求めた場合、全体として AUC は 0.84 から 0.95 であり、最良閾値による正答率は 80.85%、93.75%と高い傾向にはあったが、後述する 12 時の画像を基準として葉の動きを求めた場合の方がこれらの値は高かった。また、日中の各時刻の葉の動きの割合を用いて各日の葉の動きの割合を求めた場合よりも、午後の各時刻の葉の動きの割合を用いて各日の葉の動きの割合を求めた場合の方が、AUC や最良閾値による正答率は高くなった。



(a) 日中の葉の動きの割合を用いた場合

(b) 午後の葉の動きの割合を用いた場合

図 5.1: 1 時間ごとに葉の動きを求める方法における ROC 曲線

5.1.2 6 時の画像を基準として葉の動きを求める方法

6 時の画像を基準として葉の動きを求めた場合の ROC 曲線と AUC, Youden's Index における最良閾値による正答率, 真陽性率, 偽陽性率を次に示す。

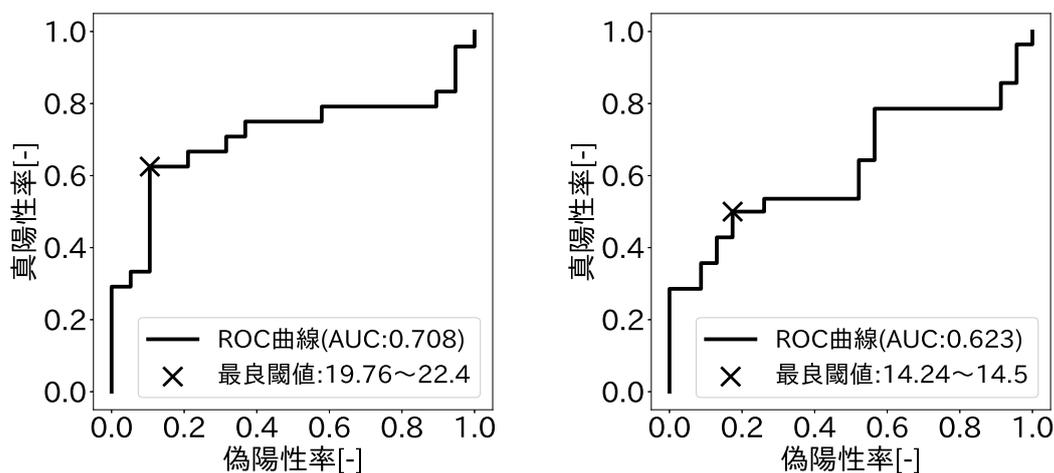
日中の各時刻の葉の動きの割合を用いて各日の葉の動きの割合を求めた場合, ROC 曲線

5.1 結果

は図 5.2(a) となり、AUC は 0.708 となった。この場合、Youden's Index より求められた最良の閾値は 19.76 付近の値となり、この閾値による正答率は 74.42%、接種株を陽性とした場合の真陽性率は 62.5%、偽陽性率は 10.53%となった。このとき、真陽性率が 100%となるように閾値を決めた場合、偽陽性率の最小値は 100%となった。

午後の各時刻の葉の動きの割合を用いて各日の葉の動きの割合を求めた場合、ROC 曲線は図 5.2(b) となり、AUC は 0.623 となった。この場合、Youden's Index より求められた最良の閾値は 14.24 付近の値となり、この閾値による正答率は 64.71%、接種株を陽性とした場合の真陽性率は 50%、偽陽性率は 17.39%となった。このとき、真陽性率が 100%となるように閾値を決めた場合、偽陽性率の最小値は 100%となった。

6 時の画像を基準として葉の動きを求めた場合、全体として AUC は 0.6 から 0.7 付近の値となり、最良閾値による正答率は 74.42%、64.71%と比較的低い傾向にあった。また、日中の各時刻の葉の動きの割合を用いて各日の葉の動きの割合を求めた場合よりも、午後の各時刻の葉の動きの割合を用いて各日の葉の動きの割合を求めた場合の方が、AUC や最良閾値による正答率は低かった。



(a) 日中の葉の動きの割合を用いた場合

(b) 午後の葉の動きの割合を用いた場合

図 5.2: 6 時の画像を基準として葉の動きを求める方法における ROC 曲線

5.1 結果

5.1.3 12時の画像を基準として葉の動きを求める方法

12時の画像を基準として葉の動きを求めた場合のROC曲線とAUC, Youden's Indexにおける最良閾値による正答率, 真陽性率, 偽陽性率を次に示す.

日中の各時刻の葉の動きの割合を用いて各日の葉の動きの割合を求めた場合, ROC曲線は図5.3(a)となり, AUCは0.934となった. この場合, Youden's Indexより求められた最良の閾値は12.91付近の値となり, この閾値による正答率は86.27%, 接種株を陽性とした場合の真陽性率は85.19%, 偽陽性率は12.5%となった. このとき, 真陽性率が100%となるように閾値を決めた場合, 偽陽性率の最小値は29.17%となった.

午後の各時刻の葉の動きの割合を用いて各日の葉の動きの割合を求めた場合, ROC曲線は図5.3(b)となり, AUCは0.989と高い数値となった. この場合, Youden's Indexより求められた最良の閾値は1.97付近の値となり, この閾値による正答率は96.08%, 接種株を陽性とした場合の真陽性率は92.59%, 偽陽性率は0%となった. このとき, 真陽性率が100%となるように閾値を決めた場合, 偽陽性率の最小値は16.67%となった.

12時の画像を基準として葉の動きを求めた場合, 全体としてAUCは0.9より高く, 最良閾値による正答率は86.27%, 96.08%と高い傾向にあった. また, 日中の各時刻の葉の動きの割合を用いて各日の葉の動きの割合を求めた場合よりも, 午後の各時刻の葉の動きの割合を用いて各日の葉の動きの割合を求めた場合の方が, AUCや最良閾値による正答率は高くなった. 午後の各時刻の葉の動きの割合を用いて各日の葉の動きの割合を求めた場合におけるAUCは0.989で, 今回検証した方法の中で最も高い数値となった. 最良閾値による正答率も96.08%と高く, 真陽性率を100%としたときの偽陽性率の最低値は16.67%で他の方法より良好な数値となった.

5.2 考察

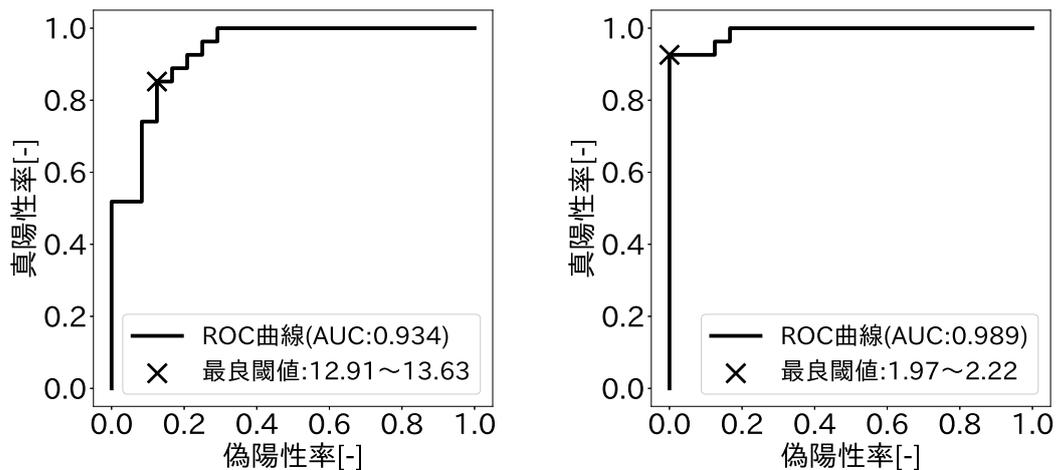
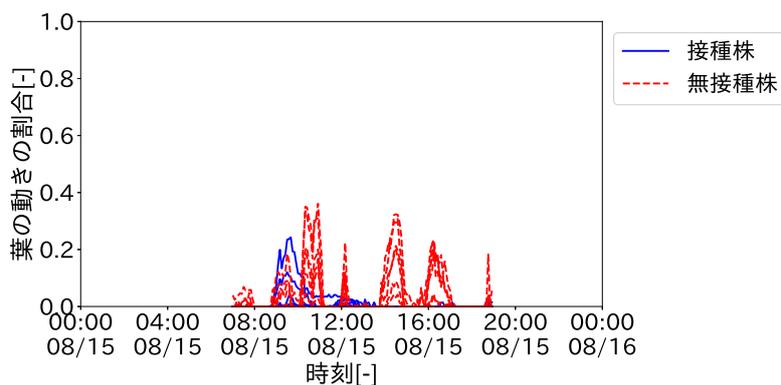


図 5.3: 12 時の画像を基準として葉の動きを求める方法における ROC 曲線

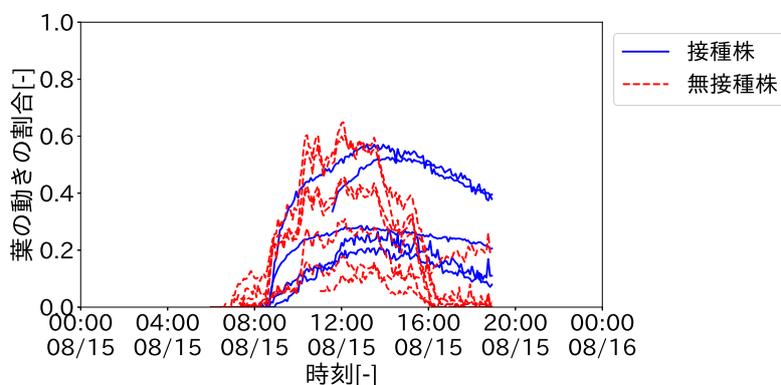
5.2 考察

検証の結果、12 時の画像を基準として葉の動きを求めた場合と 1 時間ごとに葉の動きを求めた場合において、日中の各時刻の葉の動きの割合から各日の葉の動きの割合を求めた場合よりも、午後の各時刻の葉の動きの割合から各日の葉の動きの割合を求めた場合の方が、AUC や最良閾値による正答率は高くなった。しかし、6 時の画像を基準として葉の動きを求めた場合には、これらの傾向はみられなかった。提案手法における 3 つの手法の午前と午後の各時刻の葉の動きの割合の違いの例を図 5.4 に示す。12 時の画像を基準として葉の動きを求めた場合や 1 時間ごとに葉の動きを求めた場合においては、午後の接種株の葉の動きの割合がある程度小さくなっていることがわかる。このため、これらの値について時間方向に累積をとって各日の葉の動きの割合とした場合には、判別精度の改善がみられたのではないかと考える。6 時の画像を基準として葉の動きを求めた場合においては、午後の接種株の葉の動きがあまり小さくなっておらず、時間方向に累積をとって各日の葉の動きの割合とした際に、判別精度の改善がみられなかったのではないかと考える。

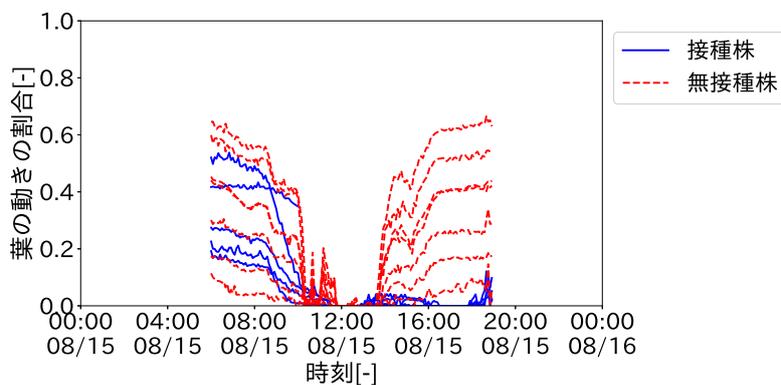
5.2 考察



(a) 1時間ごとに葉の動きを求める方法



(b) 6時の画像を基準として葉の動きを求める方法



(c) 12時の画像を基準として葉の動きを求める方法

図 5.4: 3つの手法における午前と午後の各時刻の葉の動きの割合の違いの例

これらの判別精度の向上の要因となった午前と午後の葉の動きの割合の違いは、期間②における8月15日と8月16日において良く見られたため、この原因について考察した。

5.2 考察

5.2.1 午前と午後の葉の動きの割合の違いが現れた要因

午前と午後の葉の動きの割合の違いが現れた要因について、ショウガの葉の動きは日光と温度との関係性が指摘されていることから [4]，この違いがよくみられた期間②における 8 月 15 日と 8 月 16 日と，これらの午前と午後の葉の動きの割合の違いが確認できなかった期間①の 7 月 31 日における日射量と気温を比較した．ここで比較に使用した日射量は実際にショウガを撮影したハウスに近い別のハウスにおけるデータで，1 分ごとに取得を行ったものであり，気温はショウガを撮影したハウスにおけるデータで 30 分ごとに取得を行ったものである．期間①の 7 月 31 日の日射量と気温を図 5.5，期間②の 8 月 15 日と 8 月 16 日における日射量と気温を図 5.6 と図 5.7 に示す．

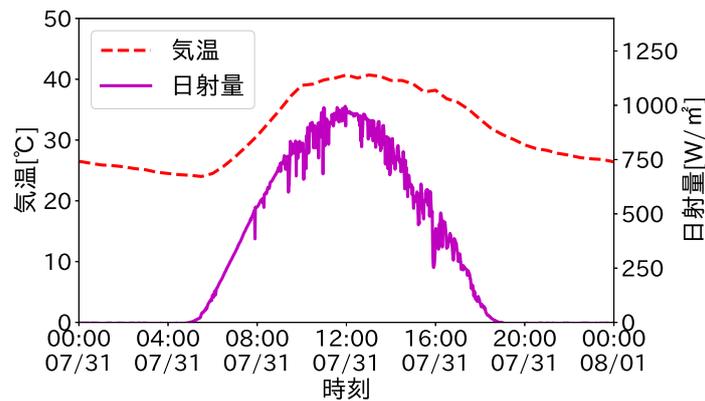


図 5.5: 7 月 31 日の日射量と気温

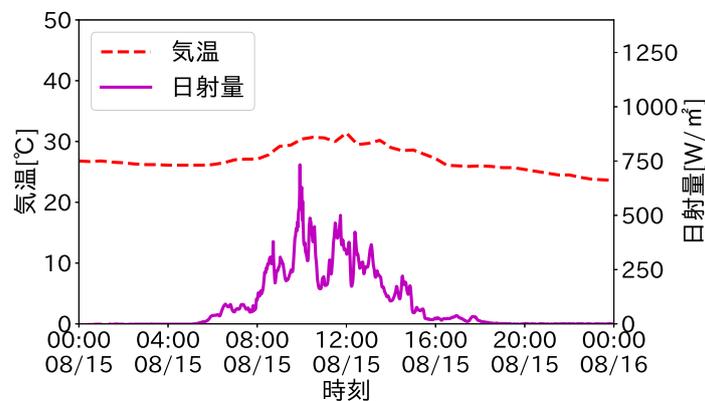


図 5.6: 8 月 15 日の日射量と気温

5.2 考察

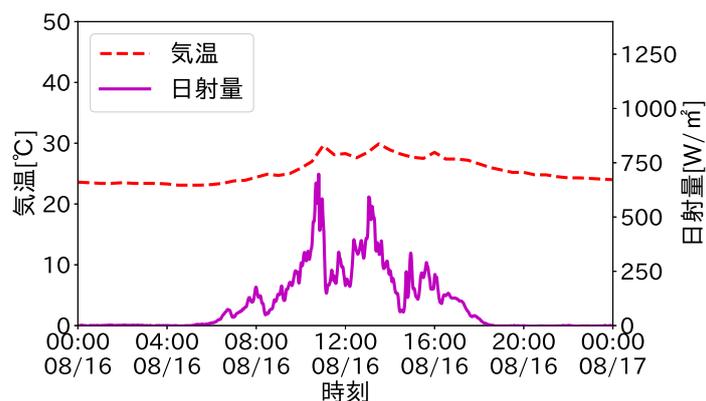


図 5.7: 8 月 16 日の日射量と気温

午前と午後の葉の動きの割合の違いが現れていない 7 月 31 日と、午前と午後の葉の動きの割合の違いが現れていた 8 月 15 日と 8 月 16 日では、日射量と気温の傾向が明らかに異なることがわかる。

接種株と無接種株における午前と午後の葉の動きの割合の違いは、少なからず日射量と気温の影響を受けていると考えられるため、今後日射量と気温との関係性を考慮して、接種株と無接種株における葉の動きを分析することで更に正確な判別が可能になると考えられる。

5.2.2 葉領域検出における誤検出の影響

今回検証を行う中で、葉領域の誤検出が最終的な葉の動きの割合に影響を与える場合があることが確認されたため、この葉領域の誤検出の例や各時刻における葉の動きの割合への影響について紹介し、それを踏まえた上での対策案について述べる。

葉領域の誤検出による影響が顕著であったのは、期間③の 8 月 30 日と 8 月 31 日であった。この影響の例として 12 時の画像を基準として葉の動きを求める場合の 8 月 31 日の各時刻の葉の動きの割合を示したグラフを図 5.8 に示す。

5.2 考察

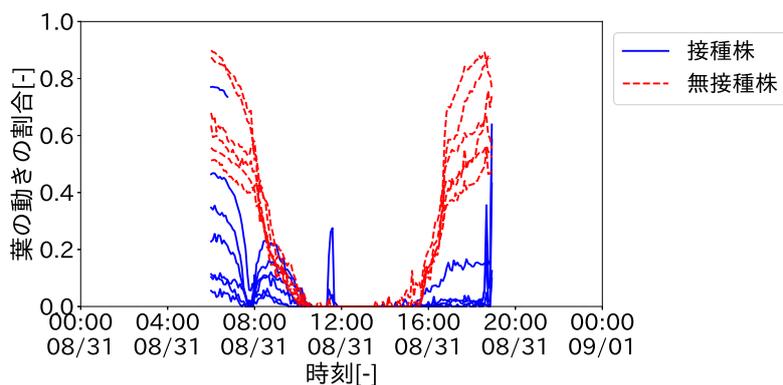


図 5.8: 葉領域の誤検出における各時刻の葉の動きの割合への影響 (8 月 31 日)

このグラフを見ると、接種株において 11 時付近と 18 時付近に不自然な葉の動きの割合の上昇が見られることがわかる。これらに近い時刻においては提案手法で葉領域を検出する際に誤検出が発生していることが確認された。11 時付近において誤検出が確認された葉領域の検出結果の例を図 5.9 に示す。また、18 時付近において誤検出が確認された葉領域の検出結果の例を図 5.10 に示す。

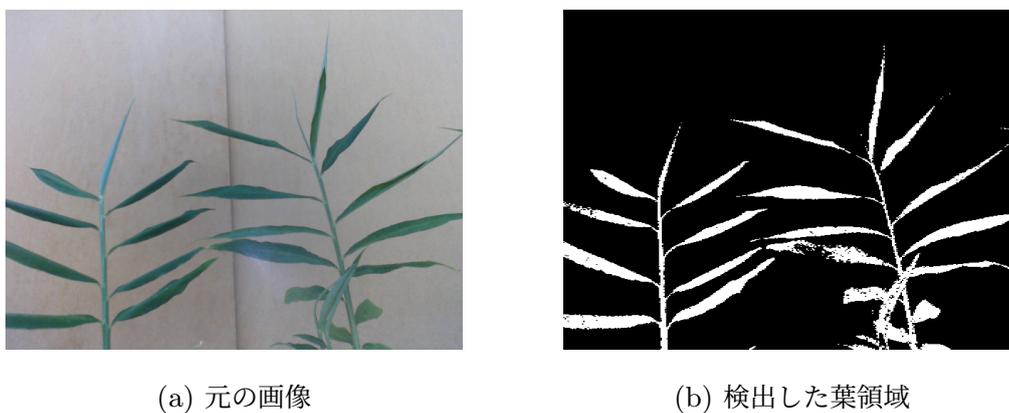


図 5.9: 葉領域の誤検出 (8 月 31 日 11 時 35 分)

5.2 考察



(a) 元の画像

(b) 検出した葉領域

図 5.10: 葉領域の誤検出 (8 月 31 日 18 時 50 分)

これらの画像の左側の株は無接種株，右側の株は接種株である．11 時付近の葉領域の検出結果である図 5.9 では，画像中央付近の接種株の葉領域において照明変化によって白くなっている部分があり，この部分において誤検出が起きていることがわかる．18 時付近の葉領域の検出結果である図 5.10 においては，日暮れの影響で元の画像全体にノイズがのっており，誤検出が起きていることがわかる．

また，各時刻の葉の動きの割合に直接的に影響はないと思われるが，7 時付近においても葉領域の誤検出が確認された．この 7 時付近において誤検出が確認された葉領域の検出結果を図 5.11 に示す．



(a) 元の画像

(b) 検出した葉領域

図 5.11: 葉領域の誤検出 (8 月 31 日 7 時 20 分)

7 時付近の葉領域の検出結果である図 5.11 では，右上の板の部分において照明変化によ

5.2 考察

り誤検出が起きていることがわかる。

このように今回の提案手法では照明変化により葉領域の誤検出が起こる場合が多く、これが葉の動きの割合を求める際に影響を与えている例が複数確認された。提案手法では葉領域を検出し、その葉領域の差分を取って葉の動きとして検出するため、葉領域の誤検出が最終的な結果に大きな影響を及ぼす可能性がある。このため、より正確に葉の動きの割合を求める場合には、葉領域の検出方法の見直しが必要となると考える。現状、葉領域の検出方法の改善策として2つの方法があげられる。

1 つめは、照明変化に強い検出手法に変更することである。今回は葉領域を検出するための指標である ExG に加えて、影による影響を除外するために明度を特徴量とした上で SVM による学習を行い検出を行ったが、教師画像が 2 枚であったため、教師画像以外の照明環境に十分に対応できなかつたと考えられる。教師画像を増やすことも対策として考えられるが、栽培環境における照明環境は生育に必要な日光などの影響も考えると均一化することは難しいため、教師画像を増やして対策を行う場合には教師画像の枚数が膨大になるという問題がある。このため、根本的に照明変化に強い検出手法に変更する必要があると考える。ExG は色度座標を使用しており、本質的に明度を無視した指標になっているため、単体では照明変化に弱い。この ExG の照明変化による影響を考慮して、明度や彩度などを情報を加味した上で照明変化に強い指標として改良した方法 [12] が提案されているため、これらの照明変化に強い手法などを用いて改良を行う必要がある。

2 つめは、葉領域を検出する際の時刻を変更することである。葉領域の誤検出が起きていた 8 月 31 日において、撮影場所である高知県農業技術センター (緯度 33.5916° 、経度 133.6452°) における国立天文台の 8 月 31 日の日の出と日の入りの計算結果は、日の出が 5 時 38 分、日の入りが 18 時 33 分であり、誤検出が少なかった 7 月 31 日の日の出は 5 時 17 分、日の入りは 19 時 7 分であった [13]。今回はこれらの日の出、日の入りを考慮せず、6 時から 18 時 55 分までの間で葉領域を検出し、葉の動きの割合を求めたため、8 月 31 日においては日の入り 18 時 33 分以降の葉領域の検出は照明変化の関係上難しく、葉の動きの割合を求める際に正しく反映されていなかったと考えられる。日の入りなどにより光量が極

5.2 考察

端に下がった場合、葉領域の検出が難しくなると考えられるため、葉領域の検出の際の時刻や葉の動きの割合を求める時刻の範囲を日の出、日の入りに合わせて変更する必要があると考える。

第6章

結論

本研究では、ショウガ根茎腐敗病の早期検出を目的として葉の動きを定量化する方法について提案し、その値を基にして根茎腐敗病の病原菌を接種した接種株と無接種株を判別できるか ROC 曲線や AUC などによって評価した。提案手法では、各日、各時刻の画像から葉領域や葉の動きなどを求めた上で接種株と無接種株における各時刻の葉の動きの割合を求め、これらの値について時間方向に累積をとることによって各日の接種株と無接種株における葉の動きの割合を定量化した。提案手法では定量化の範囲などが異なる方法をいくつか提案したが、その中で最も良かった手法における AUC は 0.989 と高い数値となり、Youden's Index によって求められた最良の閾値における正答率は 96.08%、接種株を陽性とした場合の真陽性率は 92.59%、偽陽性率は 0%となった。このとき、真陽性率が 100%となるように閾値を決めた場合、偽陽性率の最小値は 16.67%となった。

求めた葉の動きの割合は日射量と気温との関係性が示唆されたため、日射量や気温と接種株と無接種株における葉の動きを分析することで更に正確な判別につながる可能性がある。また、提案手法における葉領域の検出工程において、照明環境によって誤検出が確認される場合があり、この葉領域の誤検出が葉の動きの割合を求める際に影響を与えている例が確認された。このため、より正確に葉の動きを検出するために、照明変化に強い葉領域の検出方法へ変更するなどの改善が必要になると考える。

謝辞

本研究を進めるにあたり，ご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，副査を引き受けていただきました福本昌弘教授，吉田真一教授にお礼申し上げます。今回検証データの撮影，発病データ，気象データの提供および研究への助言などにおいてご協力いただきました高知県農業技術センターの皆様に厚く御礼申し上げます。

参考文献

- [1] 高知県病害虫防除所, “農作物有害動植物発生予察事業年報 令和2年度”, pp.122, 2021年3月.
- [2] 窪田伊織, 岡美佐子, 矢野和孝, 栗原徹, “熱画像計測によるショウガ根茎腐敗病発病株の早期検出法の検討”, パターン計測シンポジウム講演論文集, 2019年.
- [3] 岡美佐子, 窪田伊織, 栗原徹, 矢野和孝, “葉温計測によるショウガ土壌病害発病株の早期発見技術の検討”, 令和2年度日本植物病理学会関西支部会, 島根大学, 2020年.
- [4] V.O.Ayodele, O.M.Olowe, “Morphological Traits and Nastism of Mango Ginger (Curcuma Amada Roxb.)”, Agricultural Science Digest - A Research Journal, vol.39, no.3, pp.177-183, 2019.
- [5] デジタル画像処理編集委員会, “デジタル画像処理”, 公益財団法人 画像情報教育振興協会, 2015年.
- [6] 竹内一郎, 烏山昌幸, “サポートベクトルマシン”, 講談社, 2015年.
- [7] 平井有三, “はじめてのパターン認識”, 森北出版, 2012年.
- [8] W.J.Youden, “Index for rating diagnostic tests”, Cancer, vol.3, no.1, pp.32-35, 1950.
- [9] D.M.Woebbecke, G.E.Meyer, K.Von Bargen, D.A.Mortensen, “Color indices for weed identification under various soil, residue, and lighting conditions”, Transactions of the American Society of Agricultural Engineers, vol.38, no.1, pp.259-269, 1995.
- [10] 柴田瞬, 峰野博史, “Optical Flow を用いた複雑背景画像における草姿の変化検出”, 情報処理学会論文誌コンシューマ・デバイス&システム (CDS), vol.7, no.2, pp.97-105, 2017年.
- [11] 内川恵二, “色の計測原理と色の見え”, 計測と制御, vol.31, no.10, pp.1075-1084,

参考文献

1992 年.

- [12] Wan Mahani Abdullah, Shahrul Nizam Yaakob, “Modified excess green vegetation index for uneven illumination”, International Journal of Current Research, vol.9, no.4, pp.48656-48661, 2017.
- [13] 国立天文台, “こよみの計算”, <https://eco.mtk.nao.ac.jp/cgi-bin/koyomi/koyomix.cgi>, 2022 年 2 月 25 日閲覧.

付録 A

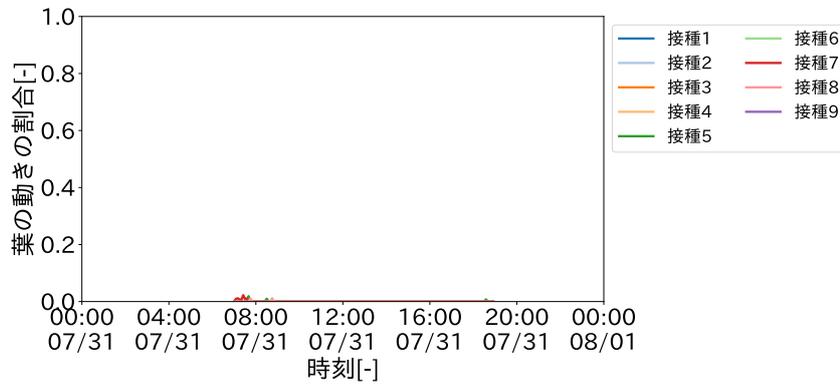
検証データにおける各時刻の葉の動きの割合

本章では、本稿で示さなかった提案手法における各時刻の葉の動きの割合を日ごとにグラフとして出力した結果を示す。各期間の接種株と無接種株の各セルの定義に基づいて番号付けされた接種株と無接種株の各セルの葉の動きの割合をプロットしたもの、セルに関係なく接種株と無接種株における葉の動きの割合をプロットしたものを掲載している。また、各時刻の葉の動きの割合を求める際には葉の動きの検出の仕方が異なる3つの方法を提案したため、これらの方法ごとにグラフを掲載している。

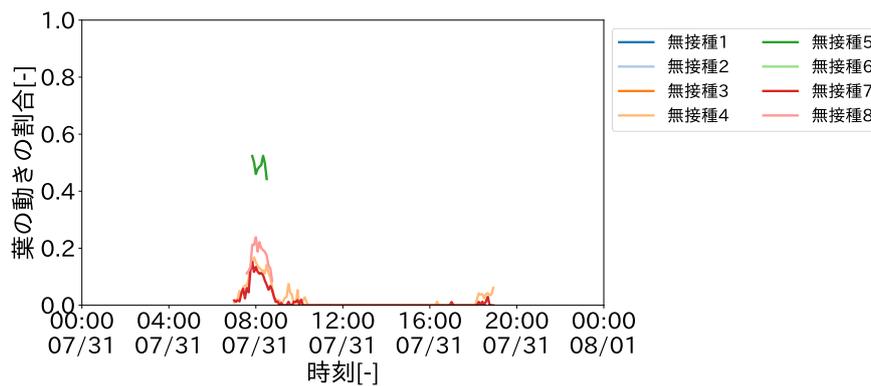
A.1 1時間ごとの葉の動きを求める方法

A.1 1時間ごとの葉の動きを求める方法

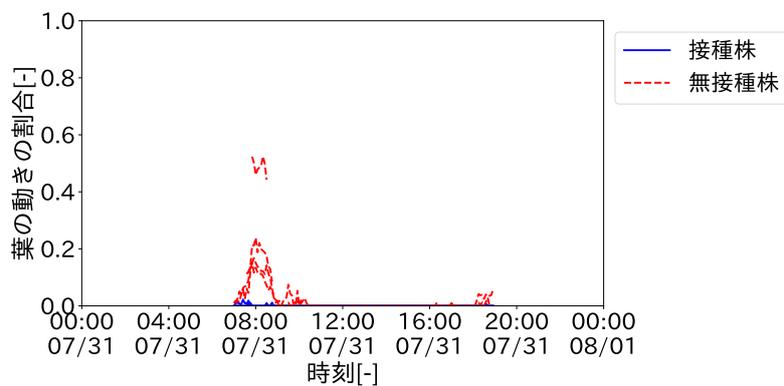
A.1.1 期間①



(a) 接種株の各セルの葉の動きの割合



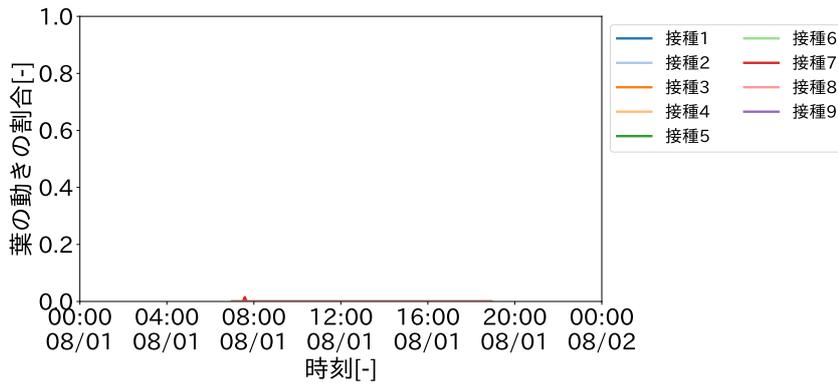
(b) 無接種株の各セルの葉の動きの割合



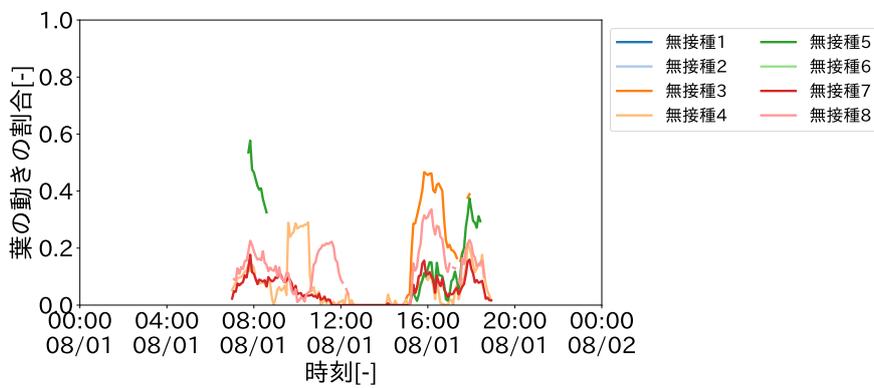
(c) 接種株と無接種株の葉の動きの割合

図 A.1: (1時間ごと) 期間①7月31日の各時刻の葉の動きの割合

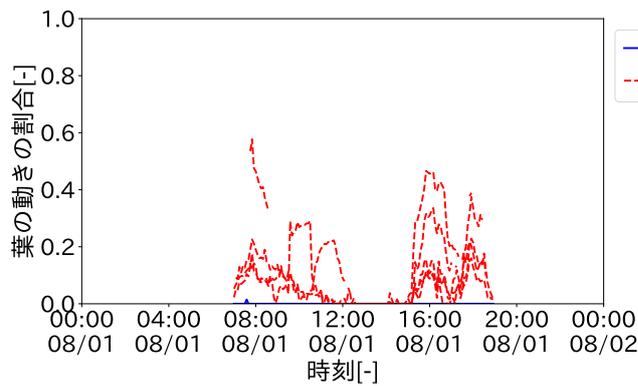
A.1 1時間ごとの葉の動きを求める方法



(a) 接種株の各セルの葉の動きの割合



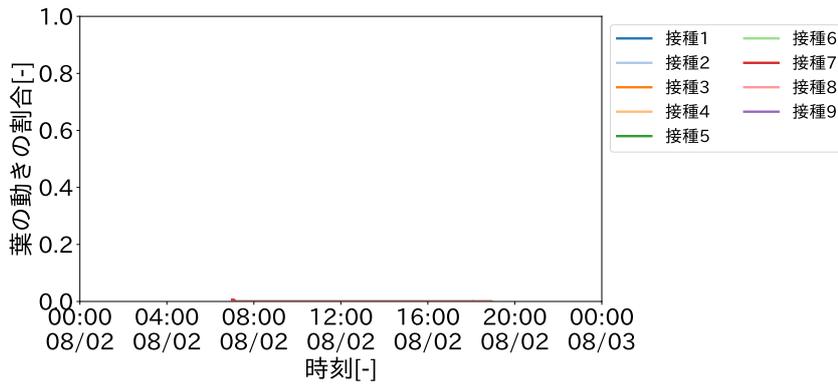
(b) 無接種株の各セルの葉の動きの割合



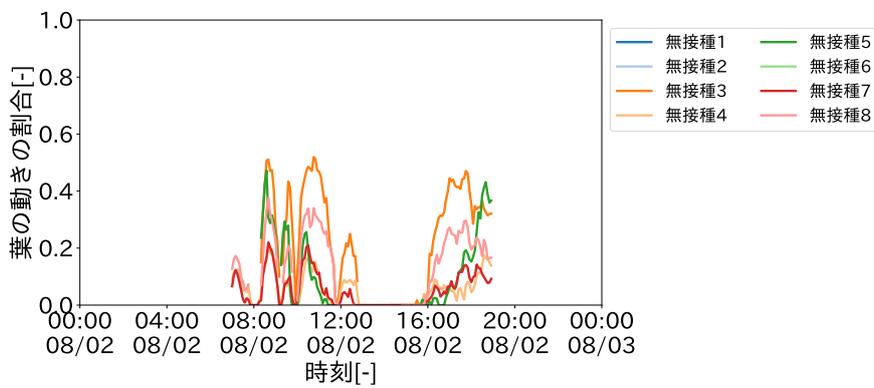
(c) 接種株と無接種株の葉の動きの割合

図 A.2: (1時間ごと) 期間①8月1日の各時刻の葉の動きの割合

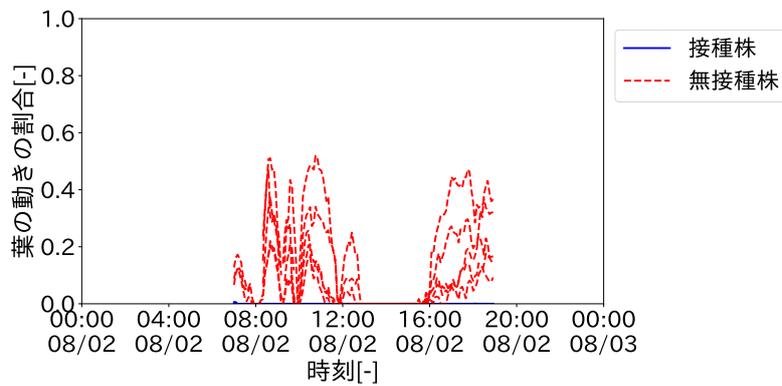
A.1 1時間ごとの葉の動きを求める方法



(a) 接種株の各セルの葉の動きの割合



(b) 無接種株の各セルの葉の動きの割合

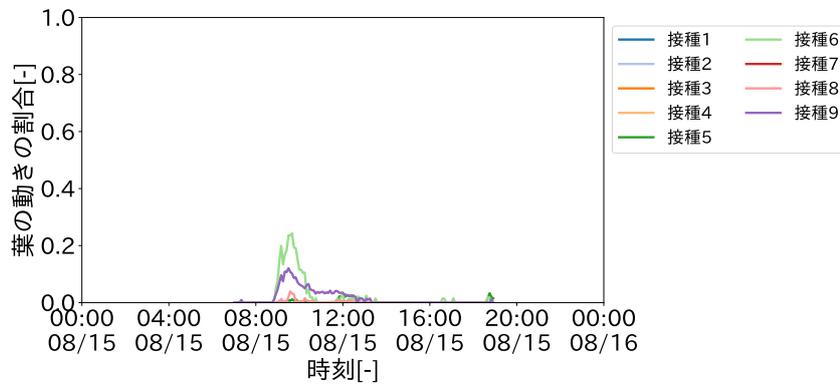


(c) 接種株と無接種株の葉の動きの割合

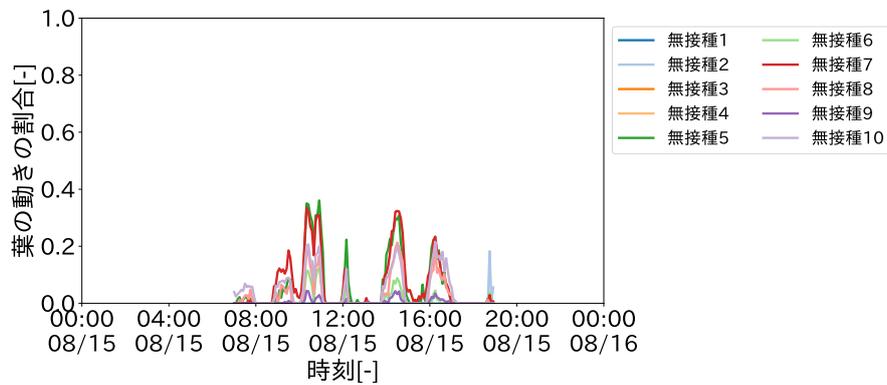
図 A.3: (1時間ごと) 期間①8月2日の各時刻の葉の動きの割合

A.1 1時間ごとの葉の動きを求める方法

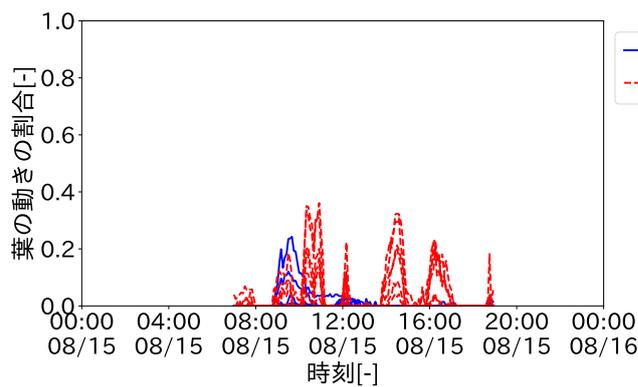
A.1.2 期間②



(a) 接種株の各セルの葉の動きの割合



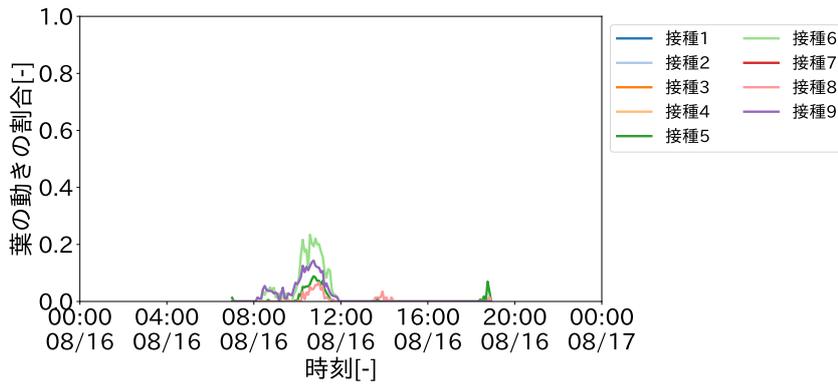
(b) 無接種株の各セルの葉の動きの割合



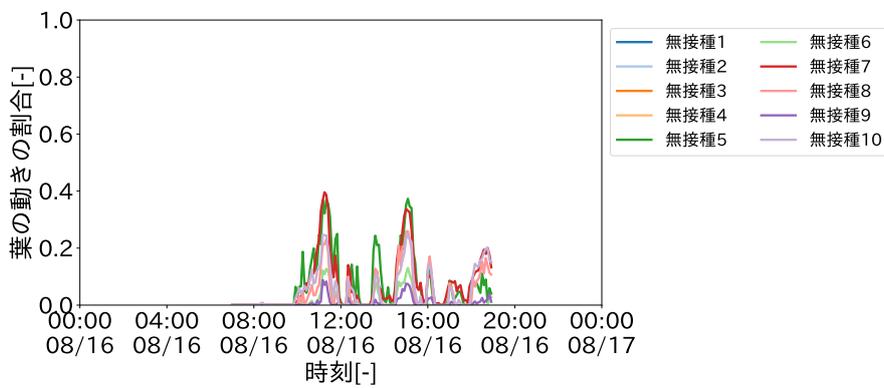
(c) 接種株と無接種株の葉の動きの割合

図 A.4: (1時間ごと) 期間②8月15日の各時刻の葉の動きの割合

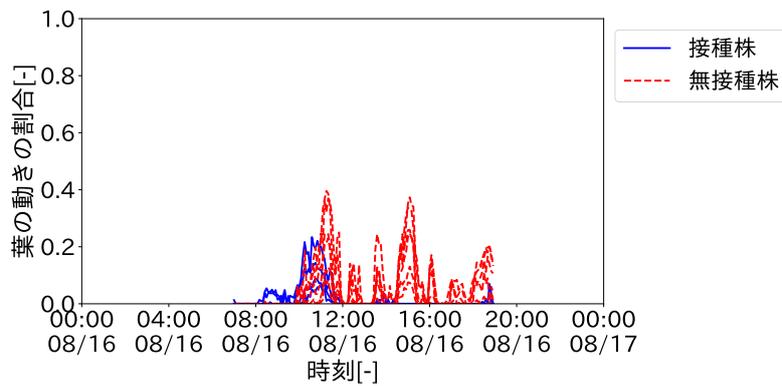
A.1 1時間ごとの葉の動きを求める方法



(a) 接種株の各セルの葉の動きの割合



(b) 無接種株の各セルの葉の動きの割合

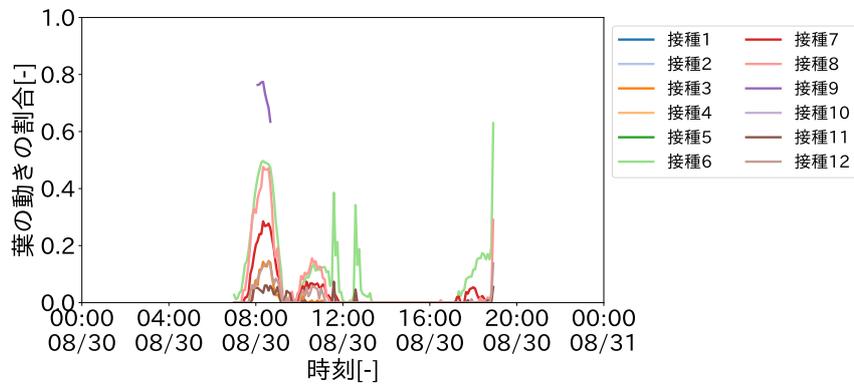


(c) 接種株と無接種株の葉の動きの割合

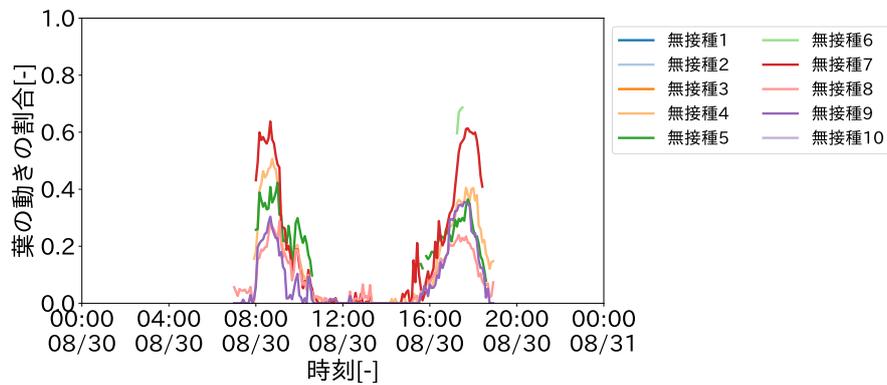
図 A.5: (1時間ごと) 期間②8月16日の各時刻の葉の動きの割合

A.1 1時間ごとの葉の動きを求める方法

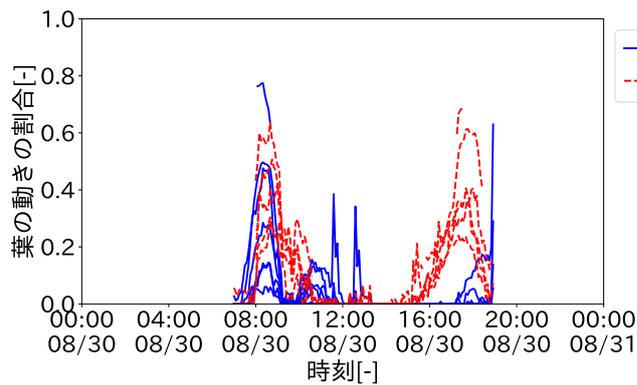
A.1.3 期間③



(a) 接種株の各セルの葉の動きの割合



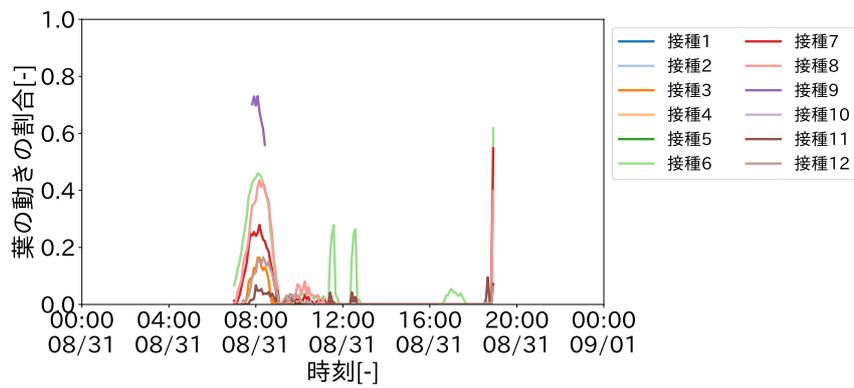
(b) 無接種株の各セルの葉の動きの割合



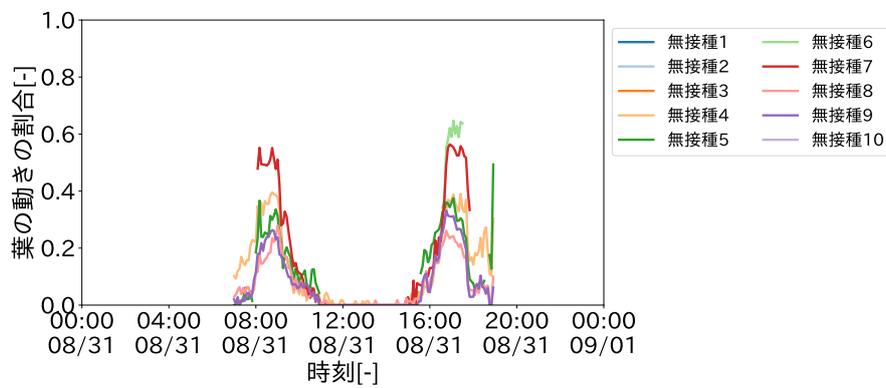
(c) 接種株と無接種株の葉の動きの割合

図 A.6: (1時間ごと) 期間③8月30日の各時刻の葉の動きの割合

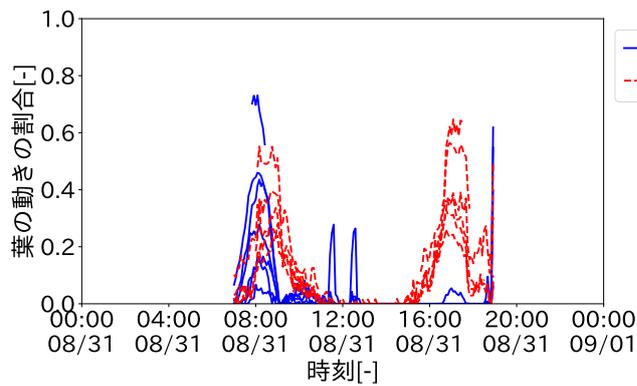
A.1 1時間ごとの葉の動きを求める方法



(a) 接種株の各セルの葉の動きの割合



(b) 無接種株の各セルの葉の動きの割合



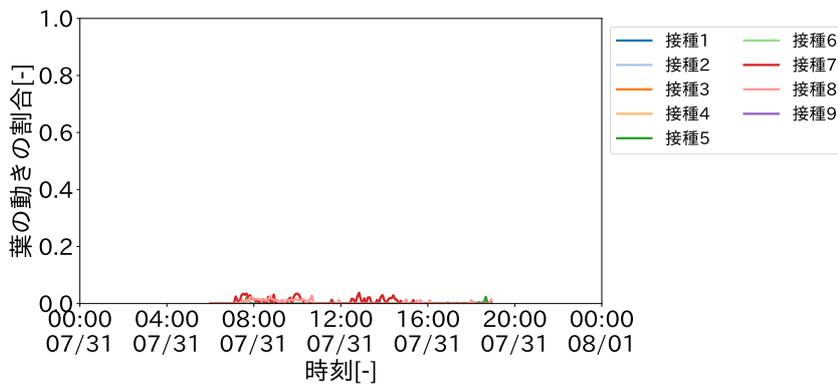
(c) 接種株と無接種株の葉の動きの割合

図 A.7: (1時間ごと) 期間③8月31日の各時刻の葉の動きの割合

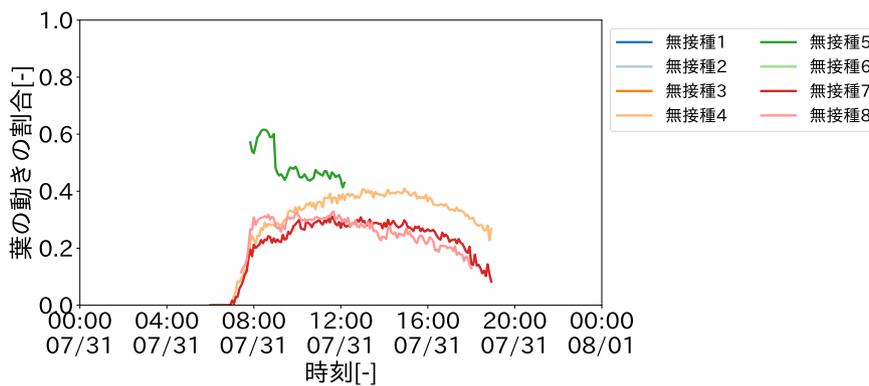
A.2 6時の画像を基準として葉の動きを求める方法

A.2 6時の画像を基準として葉の動きを求める方法

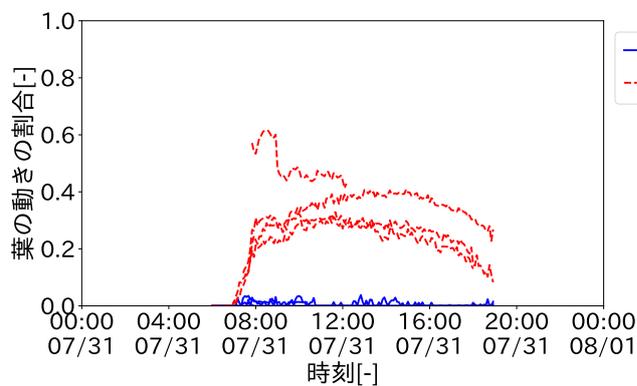
A.2.1 期間①



(a) 接種株の各セルの葉の動きの割合



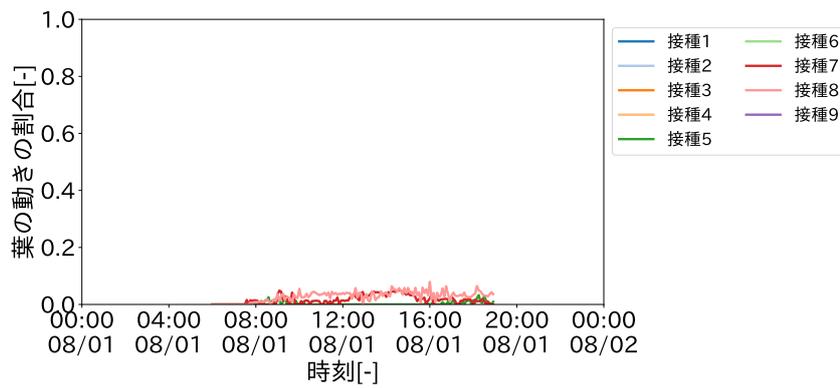
(b) 無接種株の各セルの葉の動きの割合



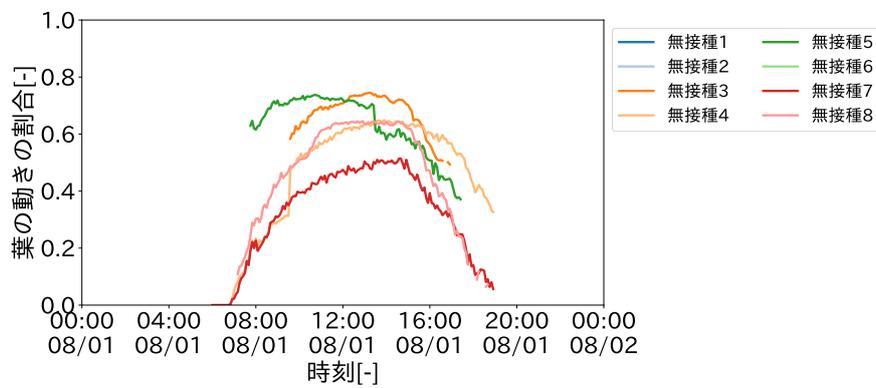
(c) 接種株と無接種株の葉の動きの割合

図 A.8: (6時基準) 期間①7月31日の各時刻の葉の動きの割合

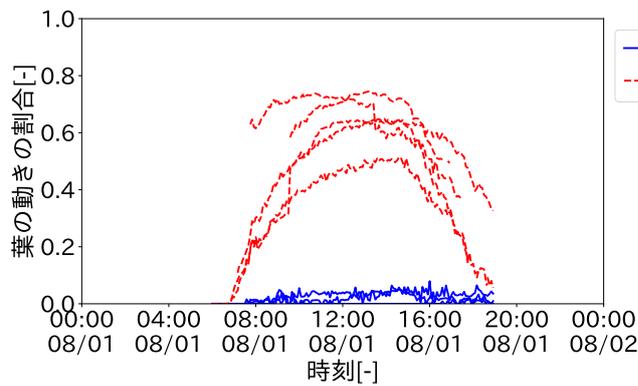
A.2 6時の画像を基準として葉の動きを求める方法



(a) 接種株の各セルの葉の動きの割合



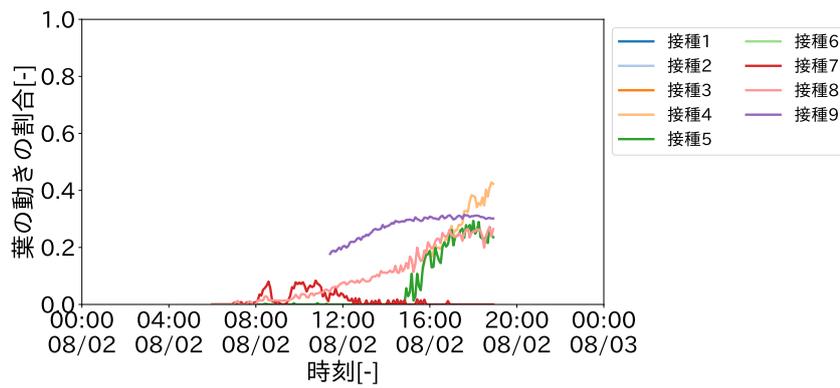
(b) 無接種株の各セルの葉の動きの割合



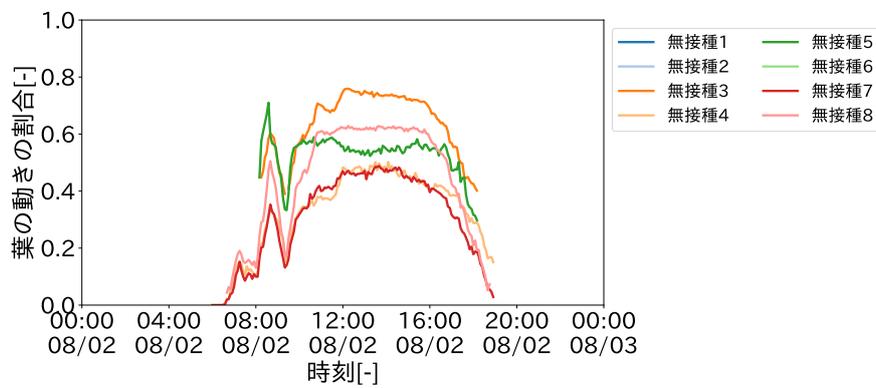
(c) 接種株と無接種株の葉の動きの割合

図 A.9: (6時基準) 期間①8月1日の各時刻の葉の動きの割合

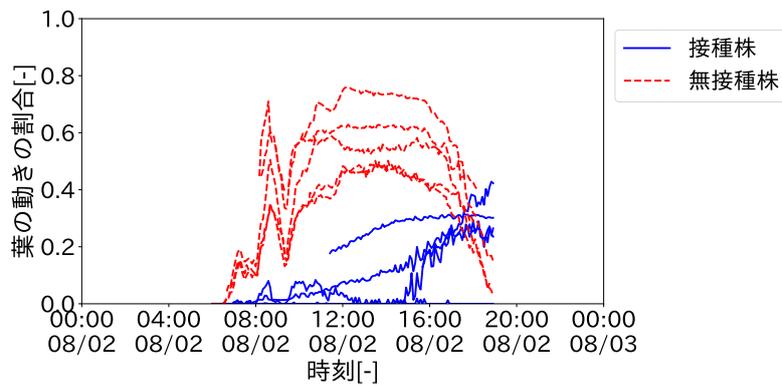
A.2 6時の画像を基準として葉の動きを求める方法



(a) 接種株の各セルの葉の動きの割合



(b) 無接種株の各セルの葉の動きの割合

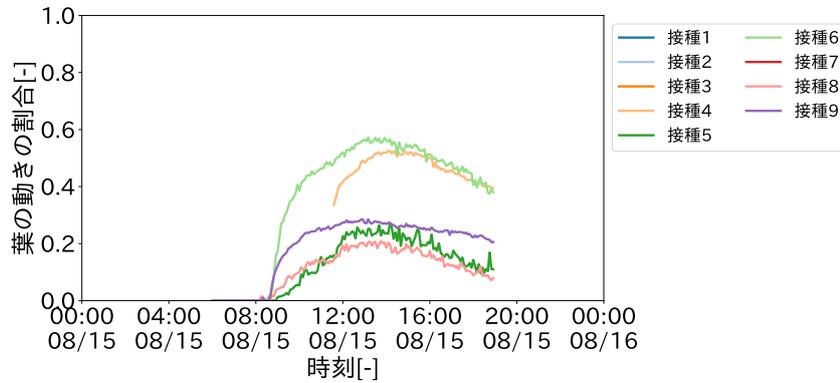


(c) 接種株と無接種株の葉の動きの割合

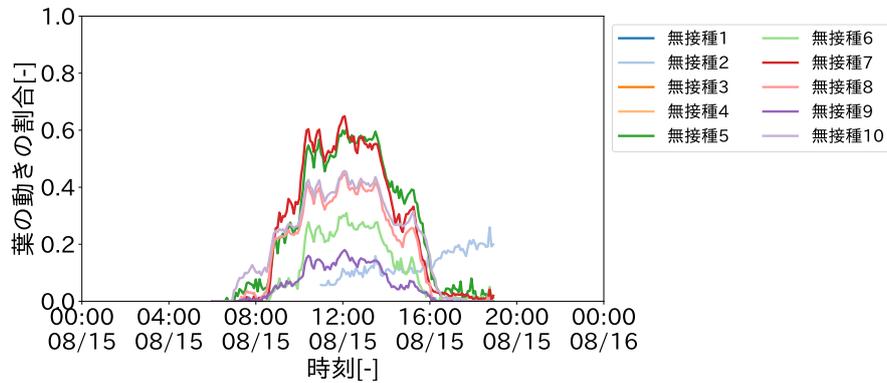
図 A.10: (6時基準) 期間①8月2日の各時刻の葉の動きの割合

A.2 6時の画像を基準として葉の動きを求める方法

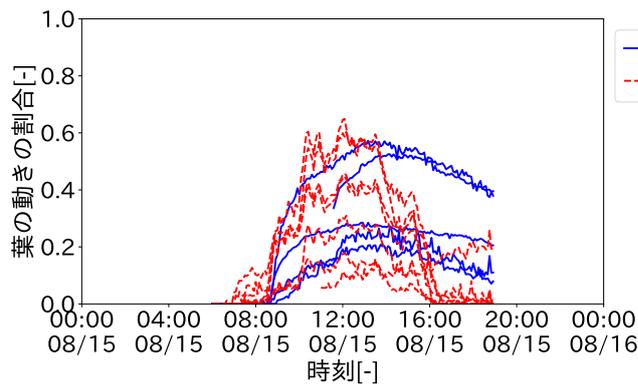
A.2.2 期間②



(a) 接種株の各セルの葉の動きの割合



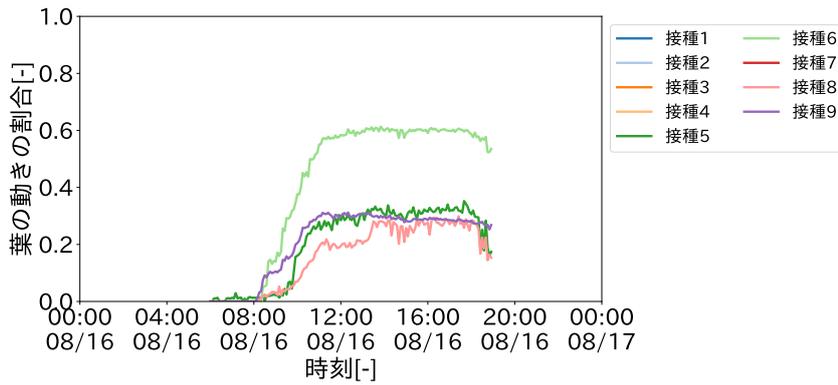
(b) 無接種株の各セルの葉の動きの割合



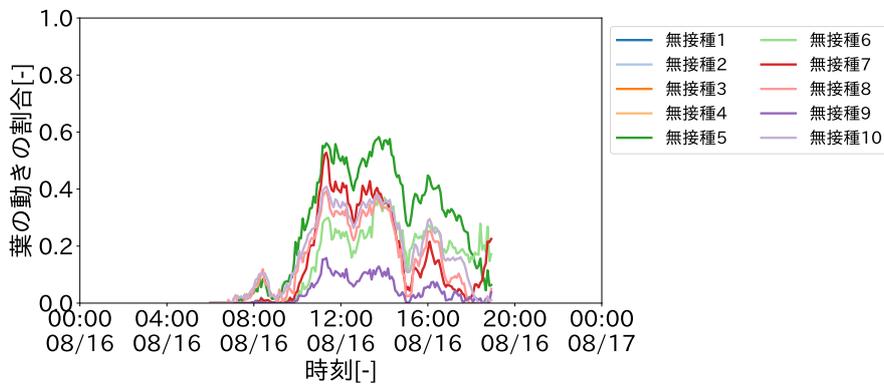
(c) 接種株と無接種株の葉の動きの割合

図 A.11: (6時基準) 期間②8月15日の各時刻の葉の動きの割合

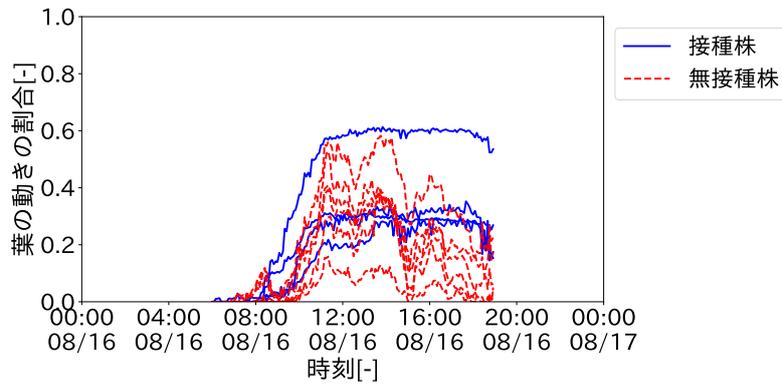
A.2 6時の画像を基準として葉の動きを求める方法



(a) 接種株の各セルの葉の動きの割合



(b) 無接種株の各セルの葉の動きの割合

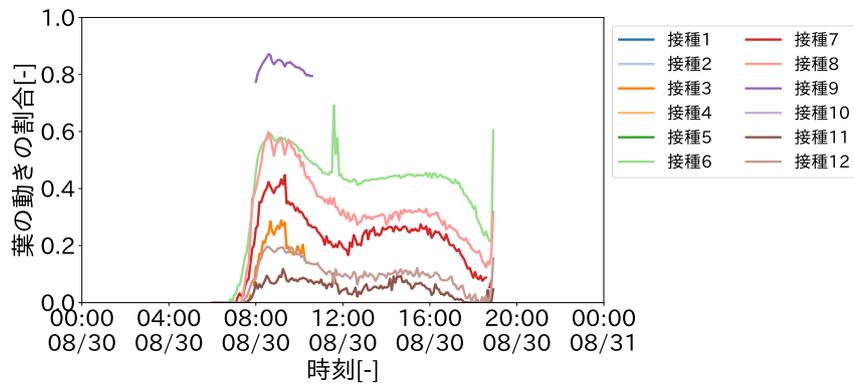


(c) 接種株と無接種株の葉の動きの割合

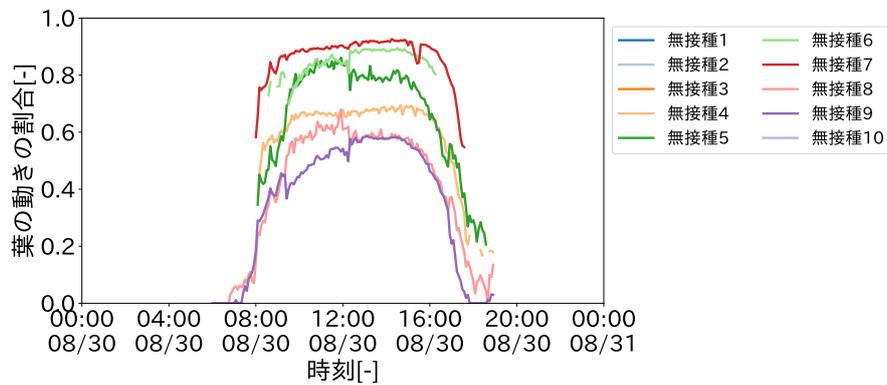
図 A.12: (6時基準) 期間②8月16日の各時刻の葉の動きの割合

A.2 6時の画像を基準として葉の動きを求める方法

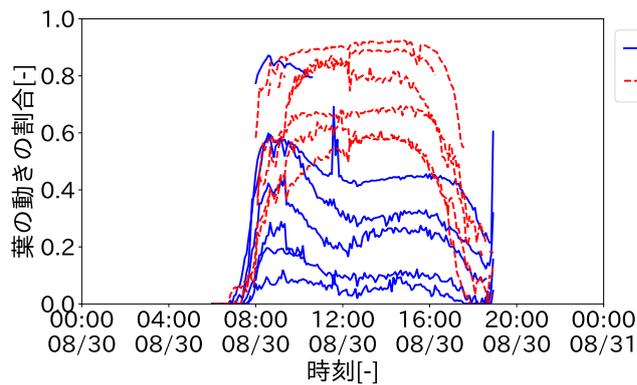
A.2.3 期間③



(a) 接種株の各セルの葉の動きの割合



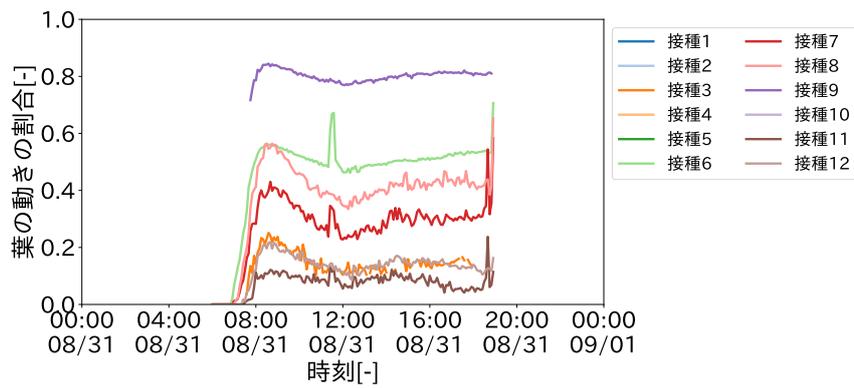
(b) 無接種株の各セルの葉の動きの割合



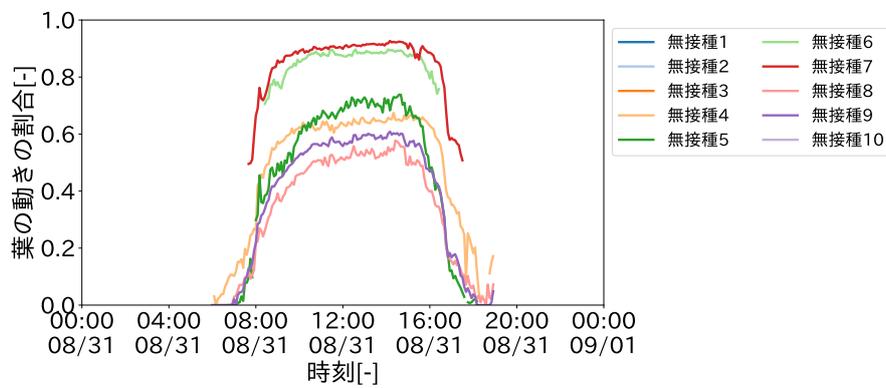
(c) 接種株と無接種株の葉の動きの割合

図 A.13: (6時基準) 期間③8月30日の各時刻の葉の動きの割合

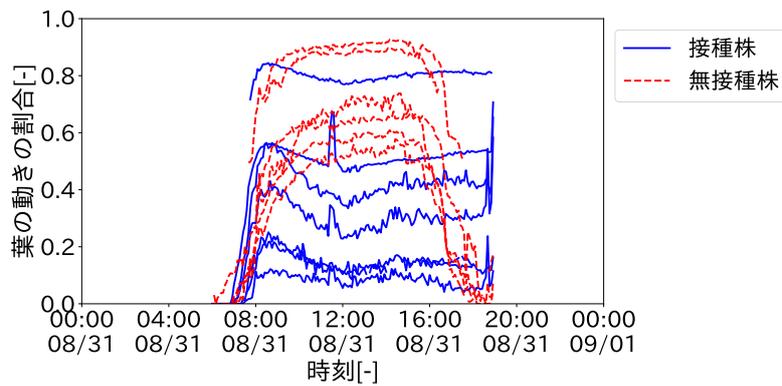
A.2 6時の画像を基準として葉の動きを求める方法



(a) 接種株の各セルの葉の動きの割合



(b) 無接種株の各セルの葉の動きの割合



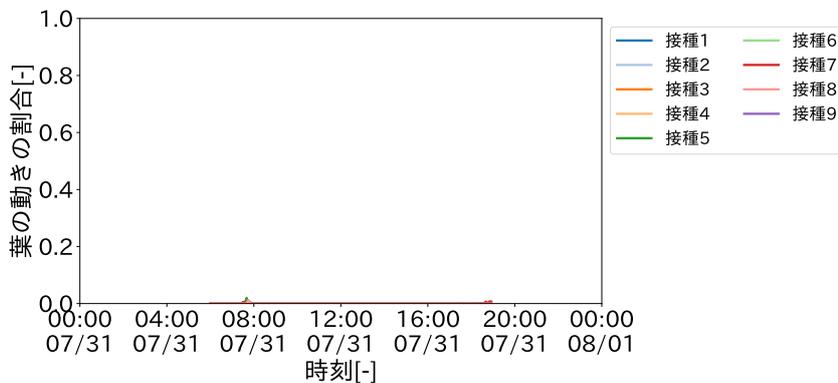
(c) 接種株と無接種株の葉の動きの割合

図 A.14: (6時基準) 期間③8月31日の各時刻の葉の動きの割合

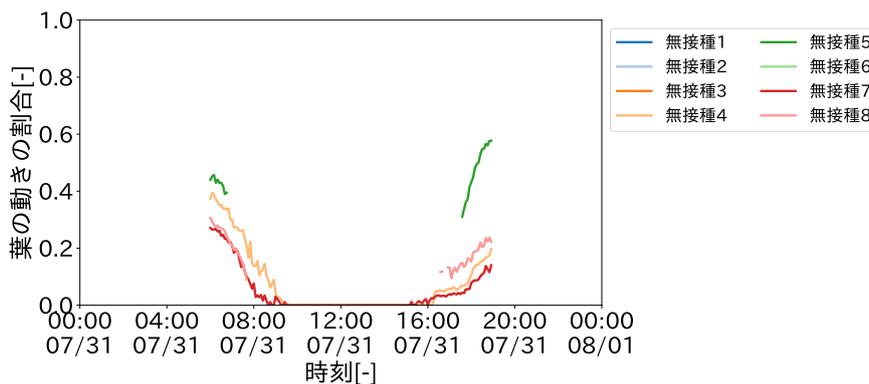
A.3 12時の画像を基準として葉の動きを求める方法

A.3 12時の画像を基準として葉の動きを求める方法

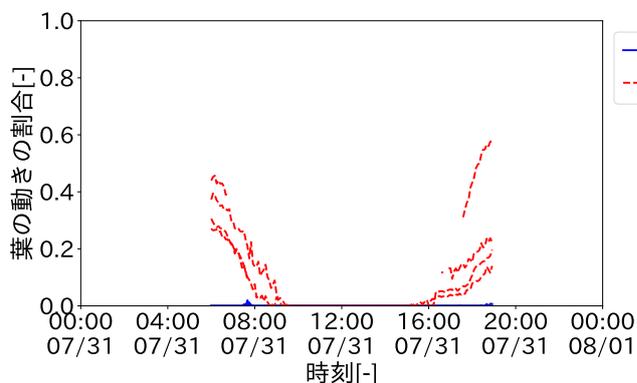
A.3.1 期間①



(a) 接種株の各セルの葉の動きの割合



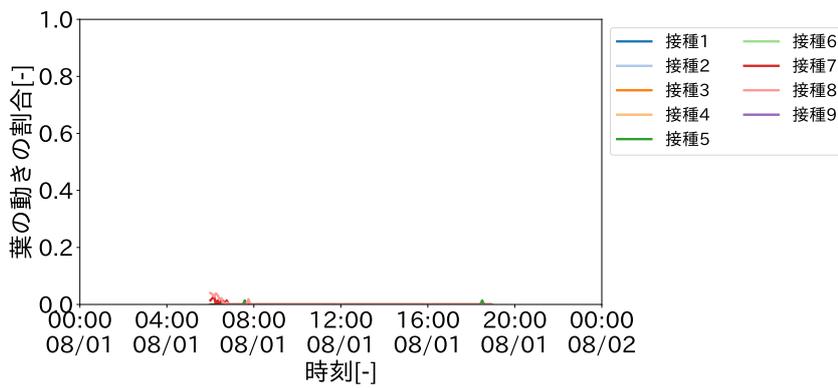
(b) 無接種株の各セルの葉の動きの割合



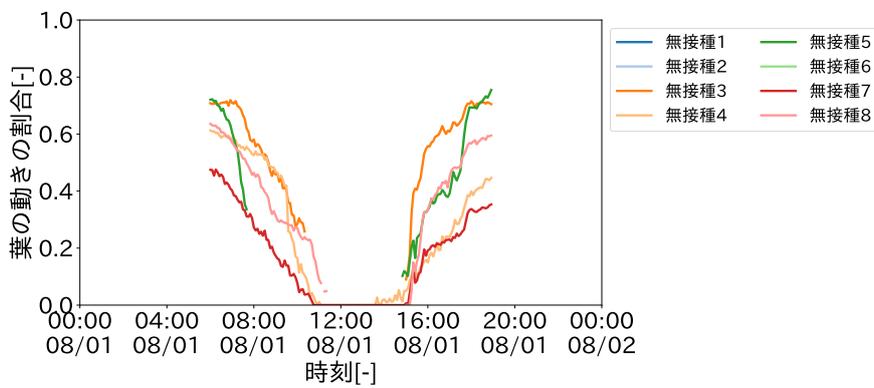
(c) 接種株と無接種株の葉の動きの割合

図 A.15: (12時基準) 期間①7月31日の各時刻の葉の動きの割合

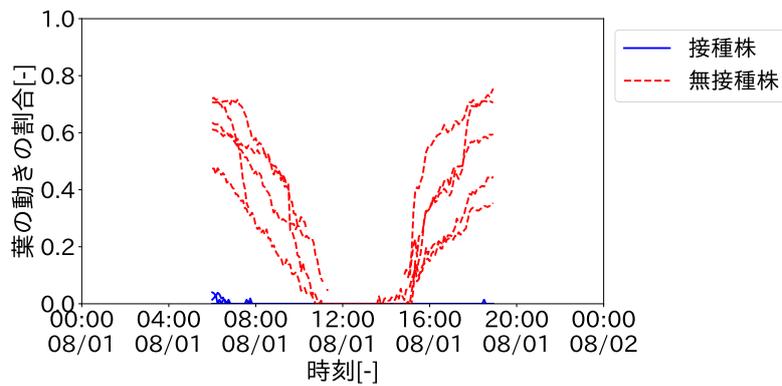
A.3 12時の画像を基準として葉の動きを求める方法



(a) 接種株の各セルの葉の動きの割合



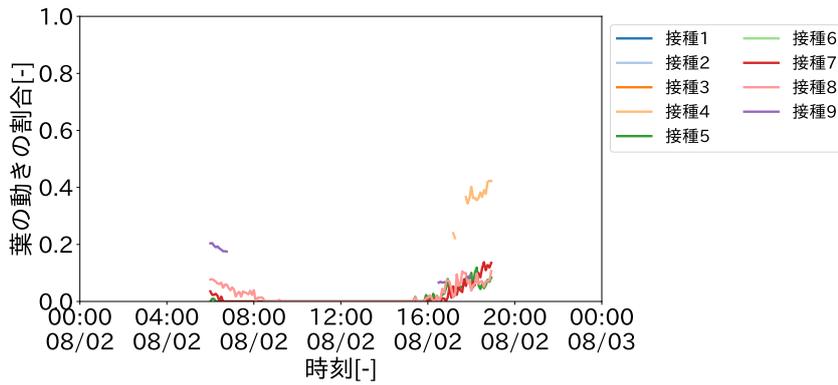
(b) 無接種株の各セルの葉の動きの割合



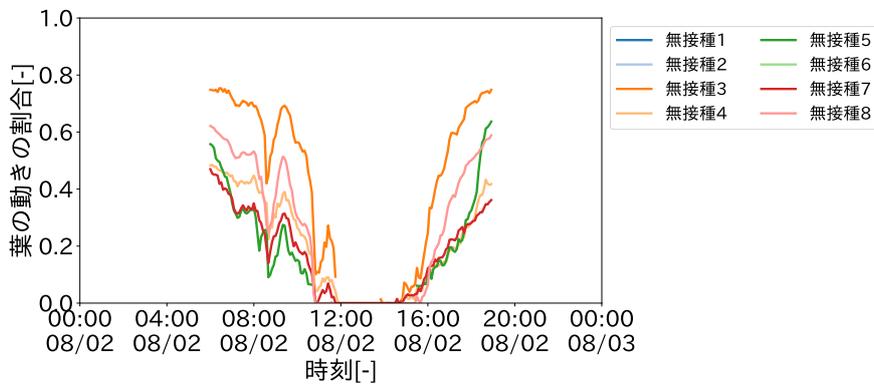
(c) 接種株と無接種株の葉の動きの割合

図 A.16: (12時基準) 期間①8月1日の各時刻の葉の動きの割合

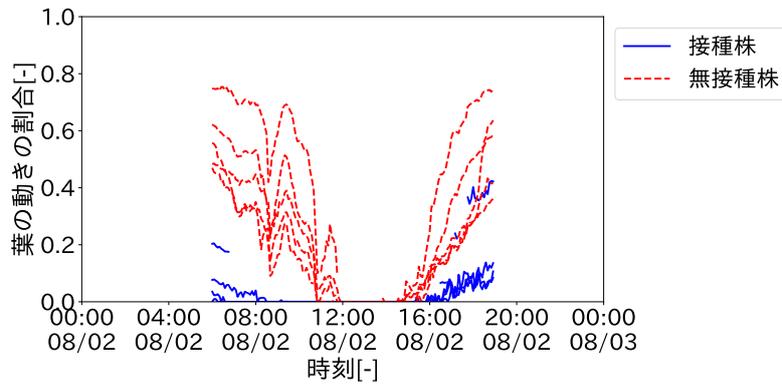
A.3 12時の画像を基準として葉の動きを求める方法



(a) 接種株の各セルの葉の動きの割合



(b) 無接種株の各セルの葉の動きの割合

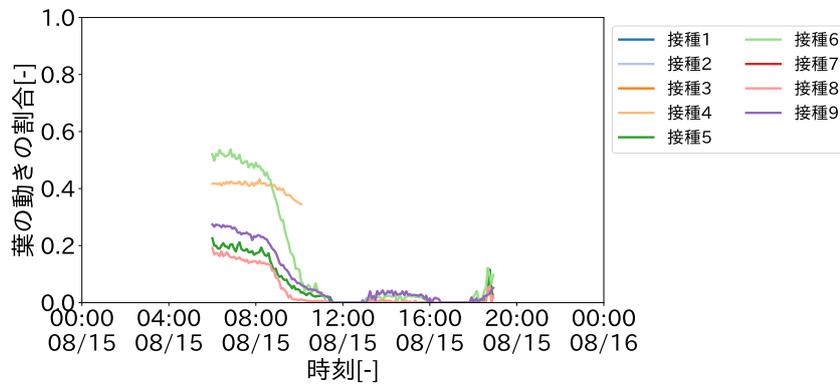


(c) 接種株と無接種株の葉の動きの割合

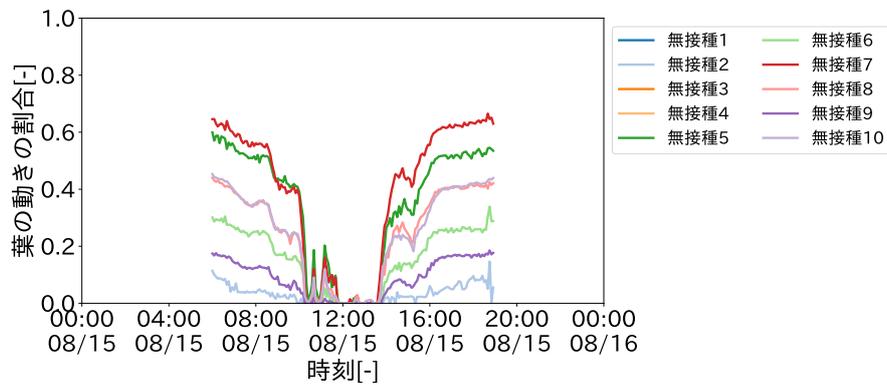
図 A.17: (12時基準) 期間①8月2日の各時刻の葉の動きの割合

A.3 12時の画像を基準として葉の動きを求める方法

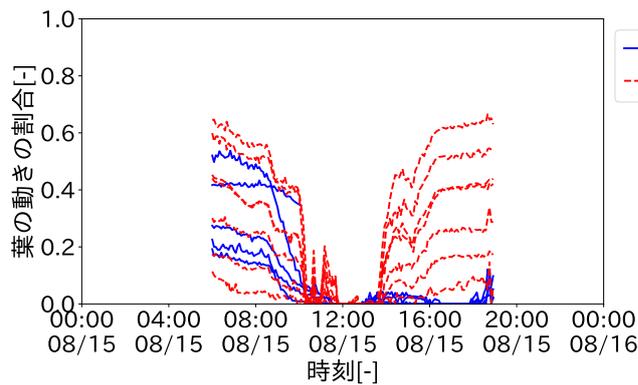
A.3.2 期間②



(a) 接種株の各セルの葉の動きの割合



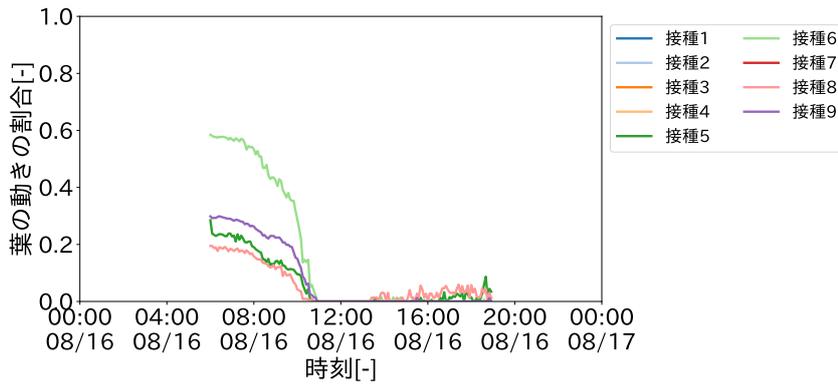
(b) 無接種株の各セルの葉の動きの割合



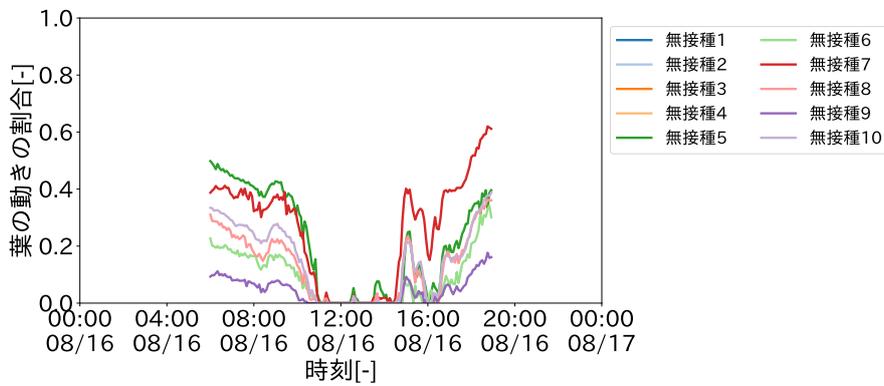
(c) 接種株と無接種株の葉の動きの割合

図 A.18: (12時基準) 期間②8月15日の各時刻の葉の動きの割合

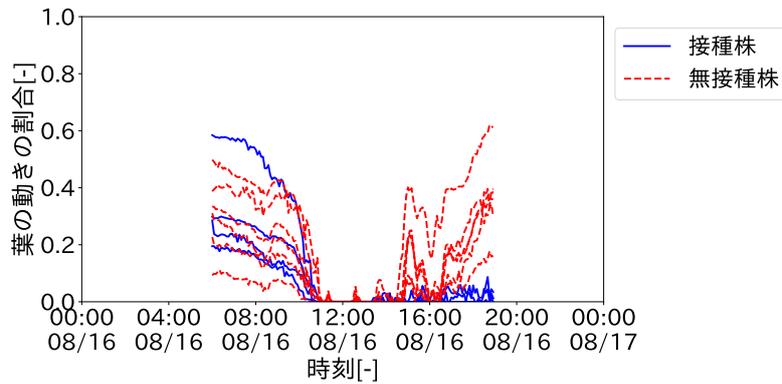
A.3 12時の画像を基準として葉の動きを求める方法



(a) 接種株の各セルの葉の動きの割合



(b) 無接種株の各セルの葉の動きの割合

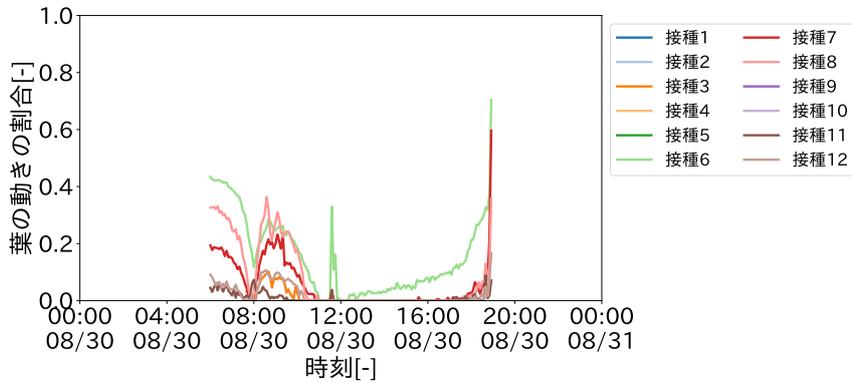


(c) 接種株と無接種株の葉の動きの割合

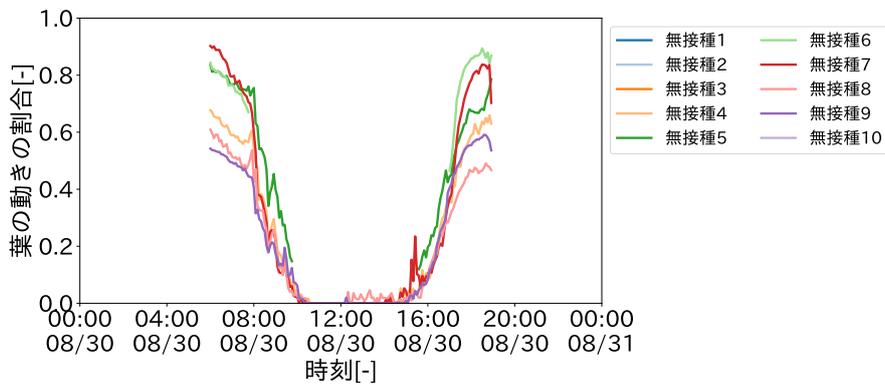
図 A.19: (12時基準) 期間②8月16日の各時刻の葉の動きの割合

A.3 12時の画像を基準として葉の動きを求める方法

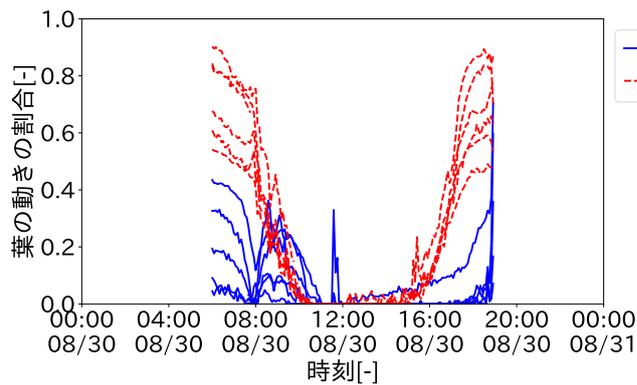
A.3.3 期間③



(a) 接種株の各セルの葉の動きの割合



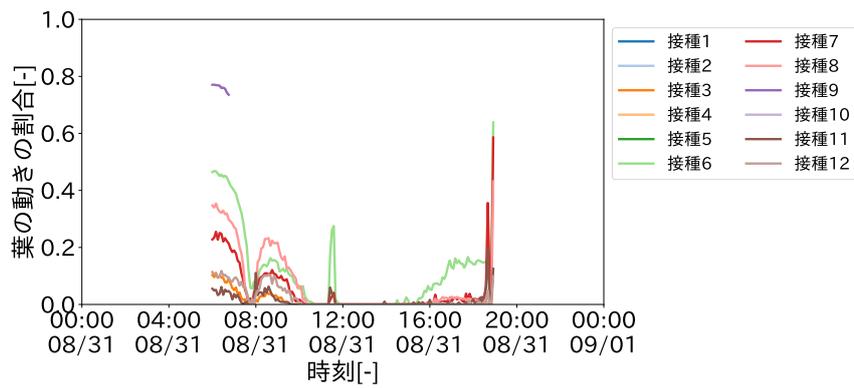
(b) 無接種株の各セルの葉の動きの割合



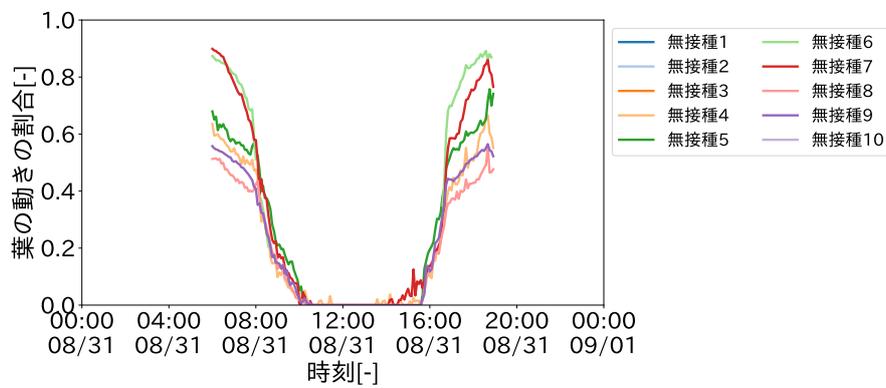
(c) 接種株と無接種株の葉の動きの割合

図 A.20: (12時基準) 期間③8月30日の各時刻の葉の動きの割合

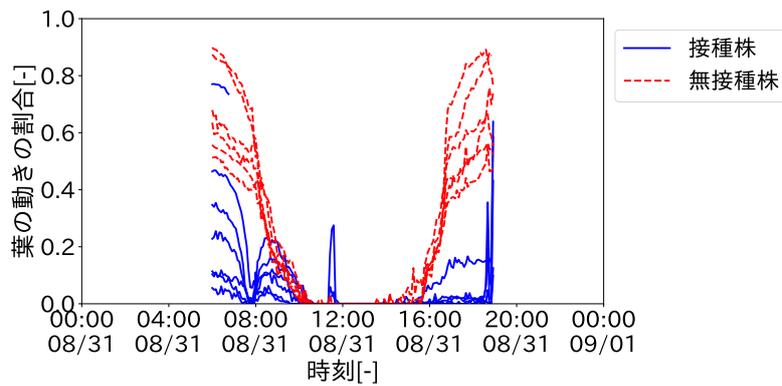
A.3 12時の画像を基準として葉の動きを求める方法



(a) 接種株の各セルの葉の動きの割合



(b) 無接種株の各セルの葉の動きの割合



(c) 接種株と無接種株の葉の動きの割合

図 A.21: (12時基準) 期間③8月31日の各時刻の葉の動きの割合

付録 B

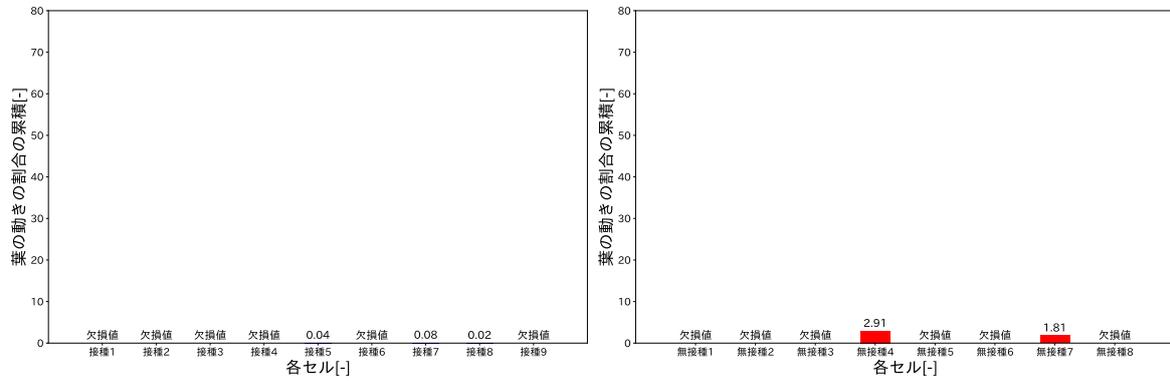
検証データにおける各日の葉の動きの割合

本章では、本稿で示さなかった提案手法における各日の葉の動きの割合を棒グラフとしてプロットした結果を示す。各期間の接種株と無接種株の各セルの定義に基づいて番号付けされた接種株と無接種株の各セルにおける各日の葉の動きの割合を棒グラフとして出力している。グラフでは接種株の各日の葉の動きの割合を青、無接種株の各日の葉の動きの割合を赤で示している。データラベルは各日の葉の動きの割合を小数点以下第3位で四捨五入したものを掲載している。また、葉の動きを求める際に葉の動きの検出の仕方が異なる3つの方法と、各時刻の葉の動きの割合の累積をとる範囲の異なる2つの方法について検証したため、これらの方法ごとにグラフを掲載している。

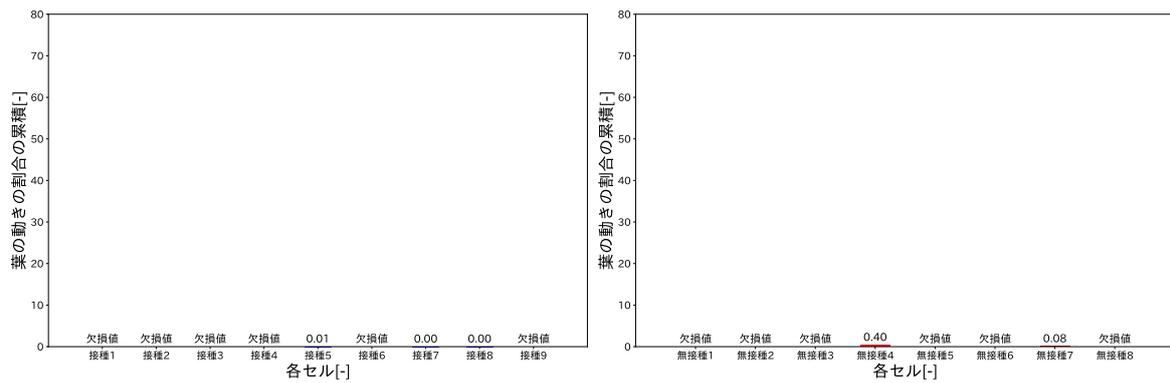
B.1 1時間ごとに葉の動きを求める方法

B.1 1時間ごとに葉の動きを求める方法

B.1.1 期間①



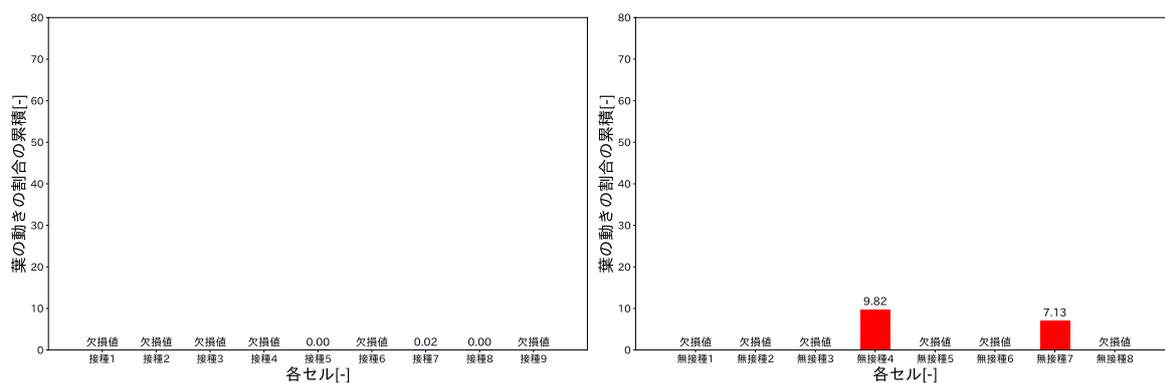
(a) 日中の葉の動きの割合を用いた場合



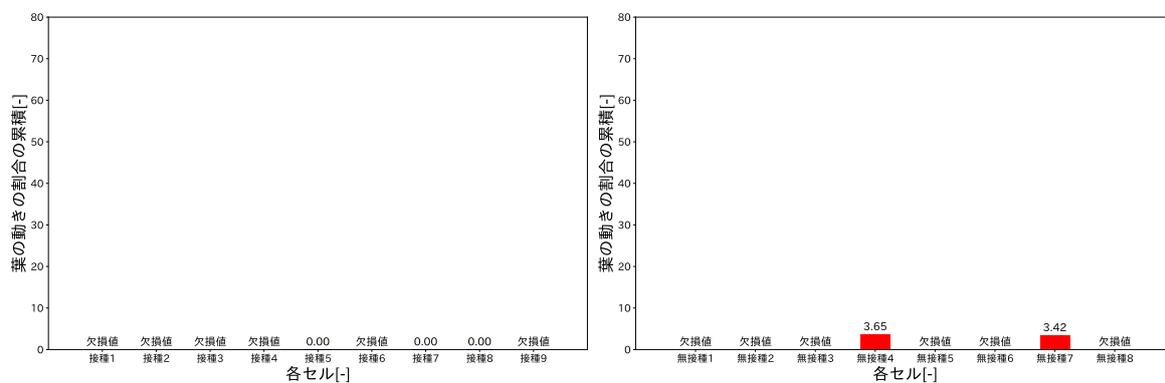
(b) 午後の葉の動きの割合を用いた場合

図 B.1: (1時間ごと) 期間①7月31日の各日の葉の動きの割合

B.1 1時間ごとに葉の動きをを求める方法



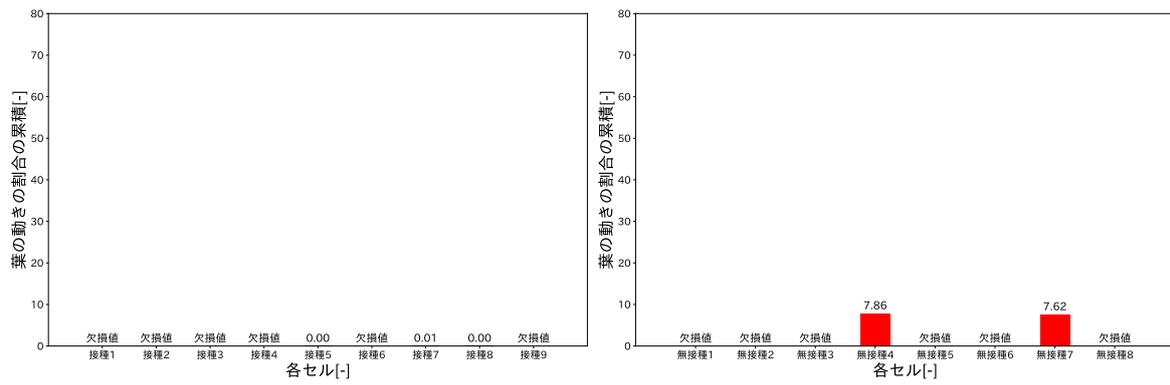
(a) 日中の葉の動きの割合を用いた場合



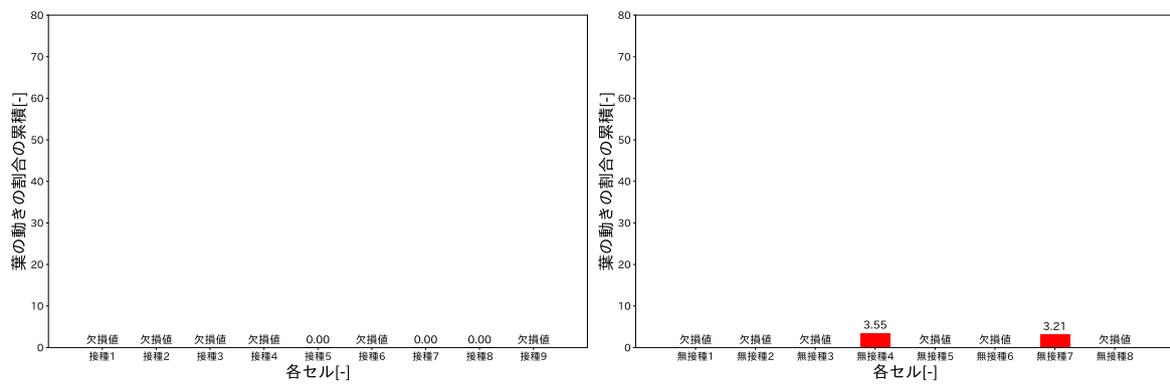
(b) 午後の葉の動きの割合を用いた場合

図 B.2: (1時間ごと) 期間①8月1日の各日の葉の動きの割合

B.1 1時間ごとに葉の動きを求める方法



(a) 日中の葉の動きの割合を用いた場合

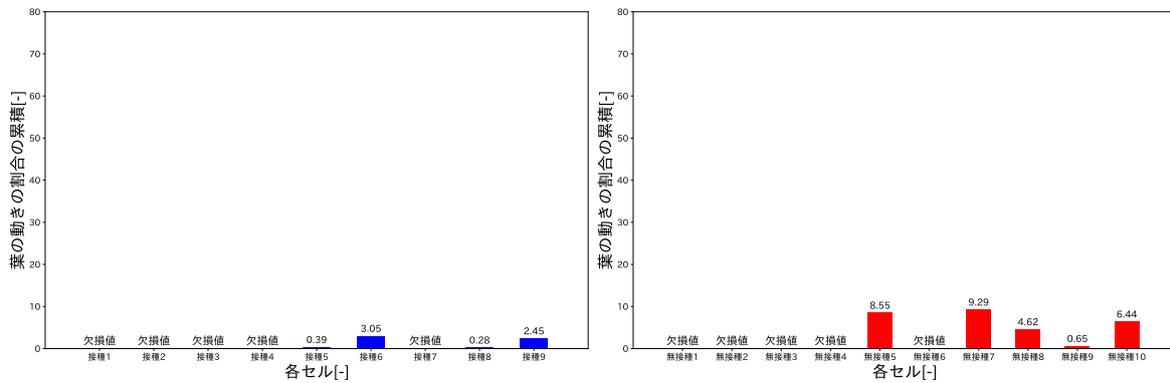


(b) 午後の葉の動きの割合を用いた場合

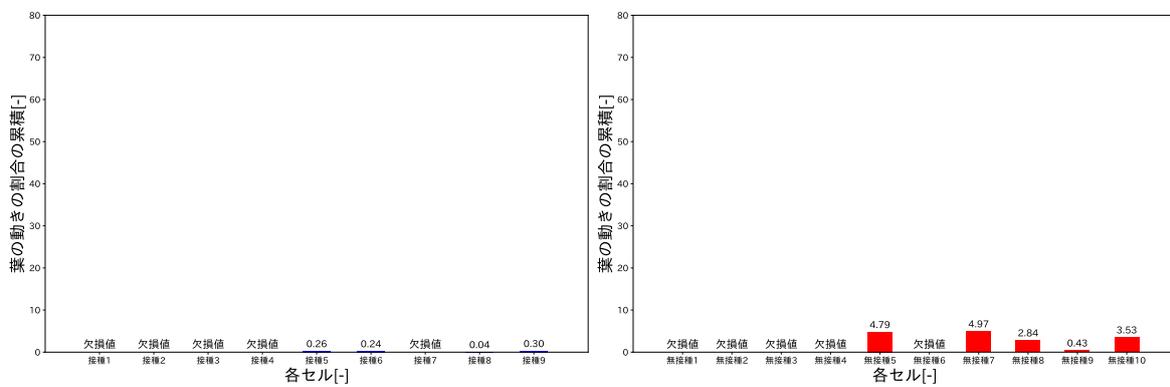
図 B.3: (1時間ごと) 期間①8月2日の各日の葉の動きの割合

B.1 1時間ごとに葉の動きを求める方法

B.1.2 期間②



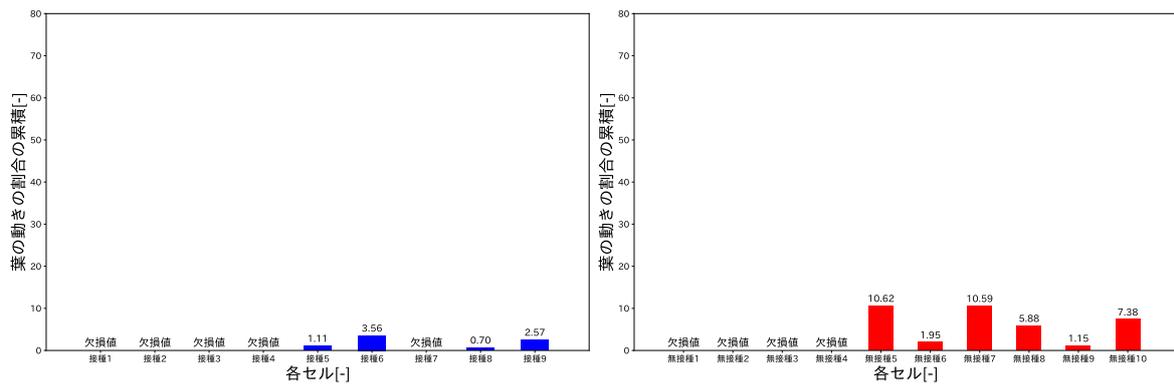
(a) 日中の葉の動きの割合を用いた場合



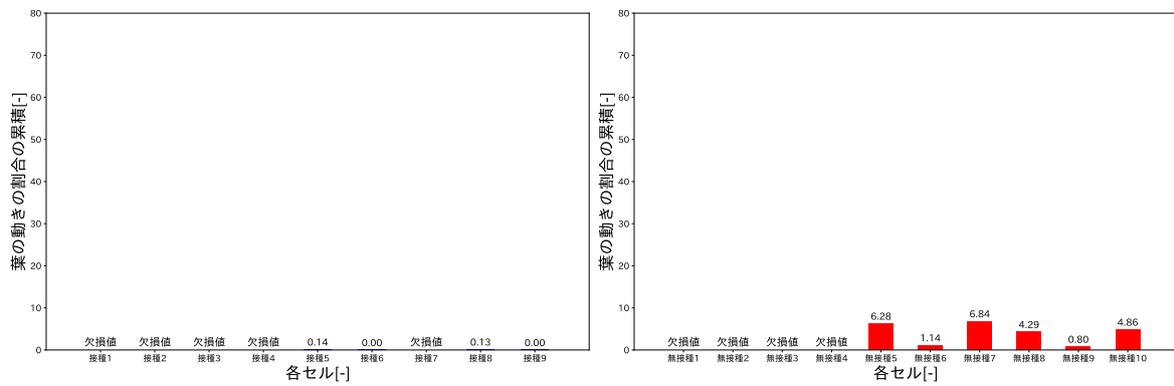
(b) 午後の葉の動きの割合を用いた場合

図 B.4: (1時間ごと) 期間②8月15日の各日の葉の動きの割合

B.1 1時間ごとに葉の動きを求める方法



(a) 日中の葉の動きの割合を用いた場合

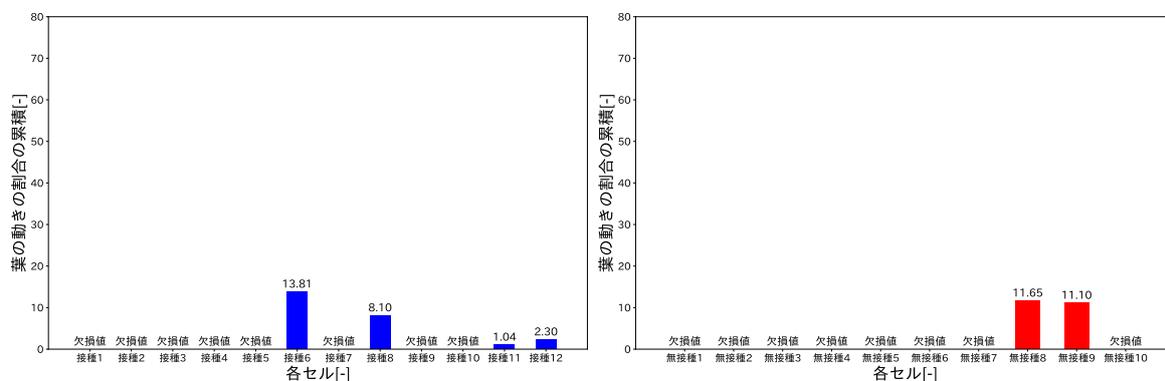


(b) 午後の葉の動きの割合を用いた場合

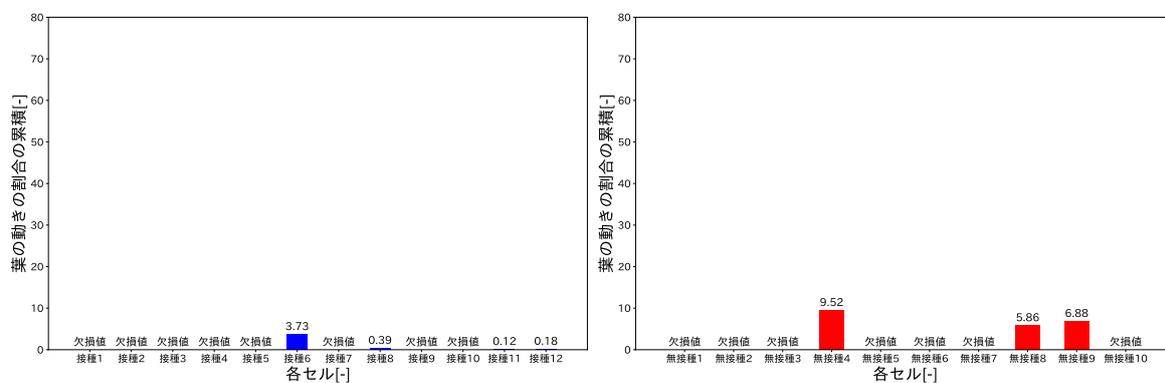
図 B.5: (1時間ごと) 期間②8月16日の各日の葉の動きの割合

B.1 1時間ごとに葉の動きを求める方法

B.1.3 期間③



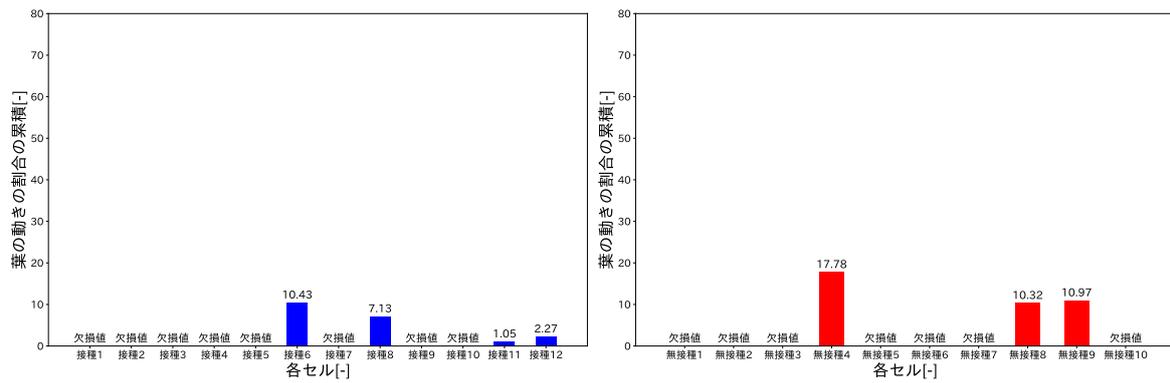
(a) 日中の葉の動きの割合を用いた場合



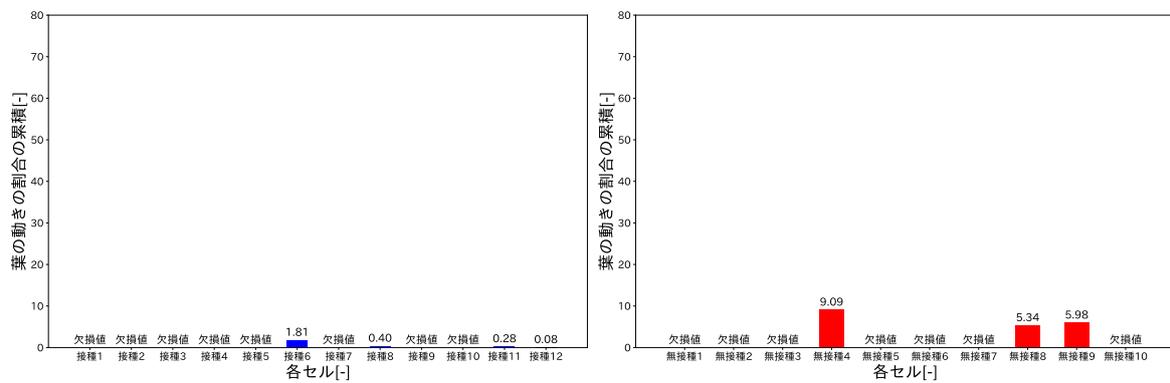
(b) 午後の葉の動きの割合を用いた場合

図 B.6: (1時間ごと) 期間③8月30日の各日の葉の動きの割合

B.1 1時間ごとに葉の動きを求める方法



(a) 日中の葉の動きの割合を用いた場合



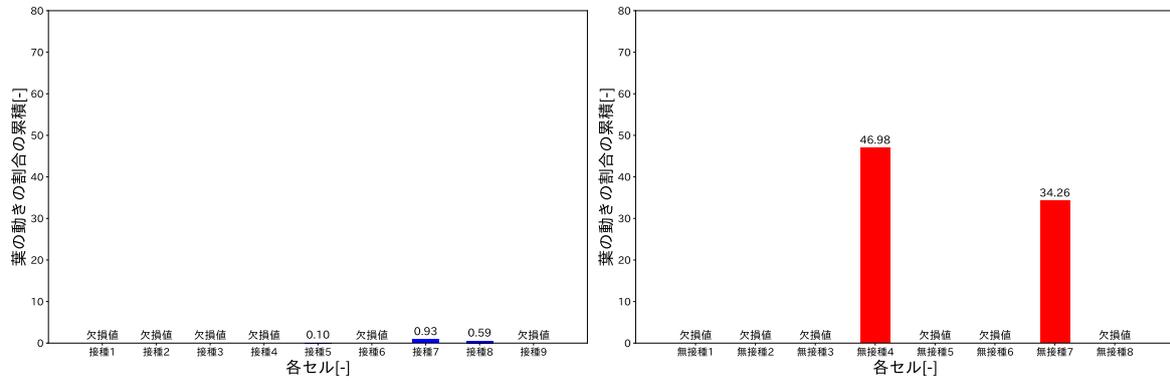
(b) 午後の葉の動きの割合を用いた場合

図 B.7: (1時間ごと) 期間③8月31日の各日の葉の動きの割合

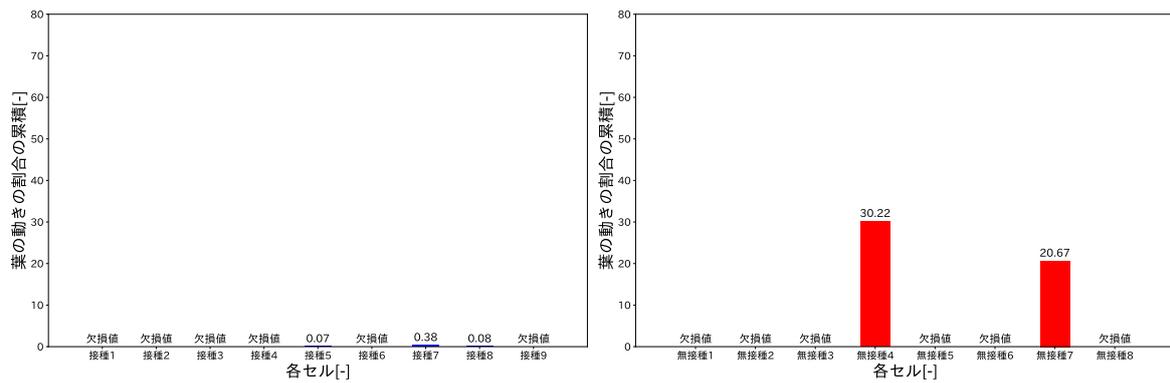
B.2 6時の画像を基準として葉の動きを求める方法

B.2 6時の画像を基準として葉の動きを求める方法

B.2.1 期間①



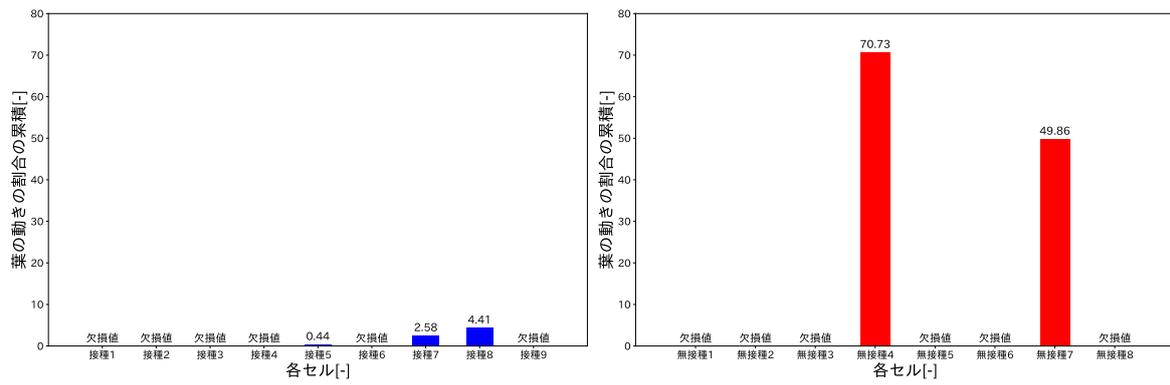
(a) 日中の葉の動きの割合を用いた場合



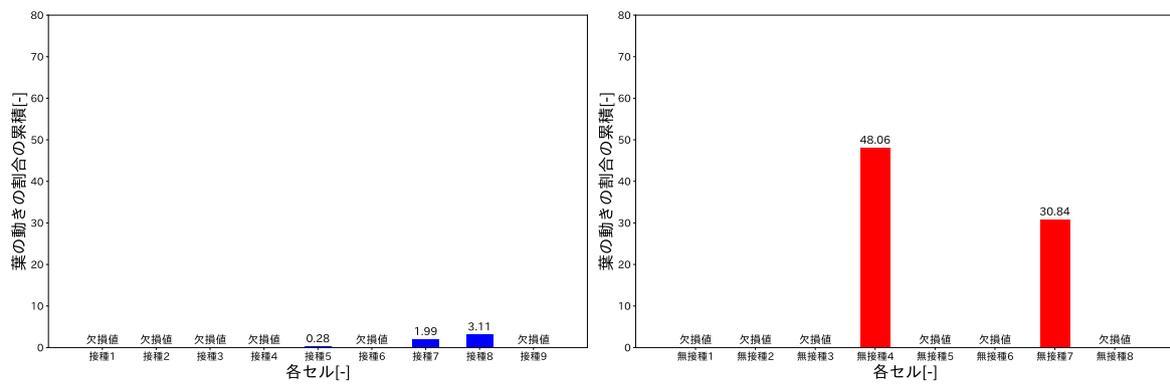
(b) 午後の葉の動きの割合を用いた場合

図 B.8: (6時基準) 期間①7月31日の各日の葉の動きの割合

B.2 6時の画像を基準として葉の動きを求める方法



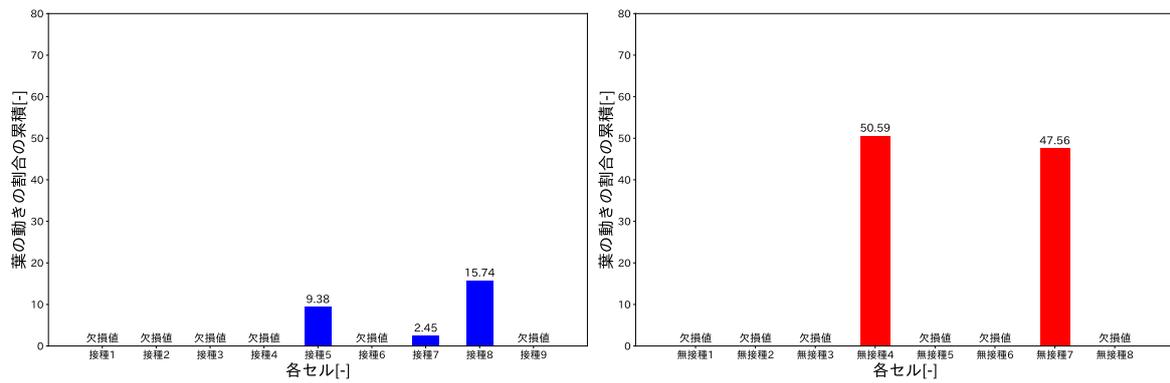
(a) 日中の葉の動きの割合を用いた場合



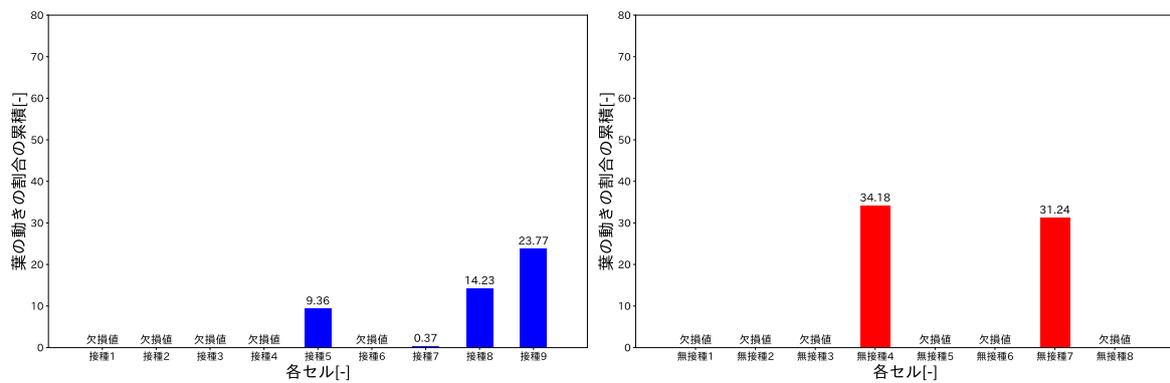
(b) 午後の葉の動きの割合を用いた場合

図 B.9: (6時基準) 期間①8月1日の各日の葉の動きの割合

B.2 6時の画像を基準として葉の動きを求める方法



(a) 日中の葉の動きの割合を用いた場合

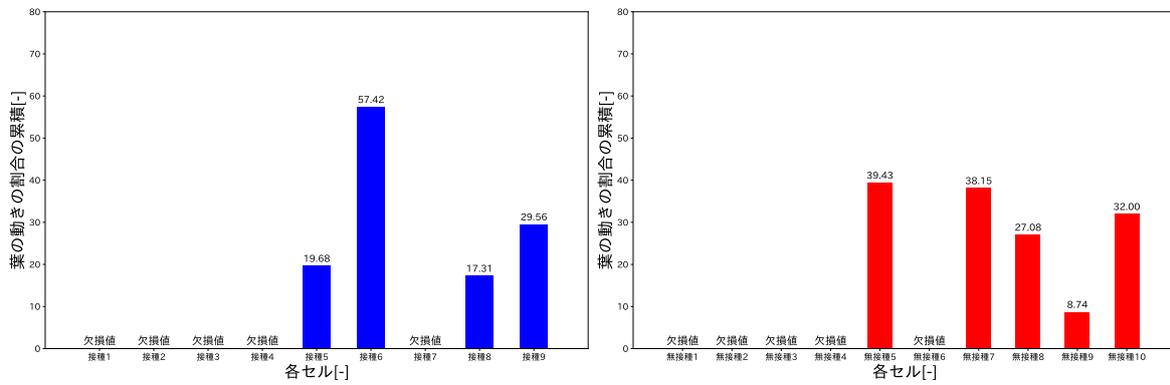


(b) 午後の葉の動きの割合を用いた場合

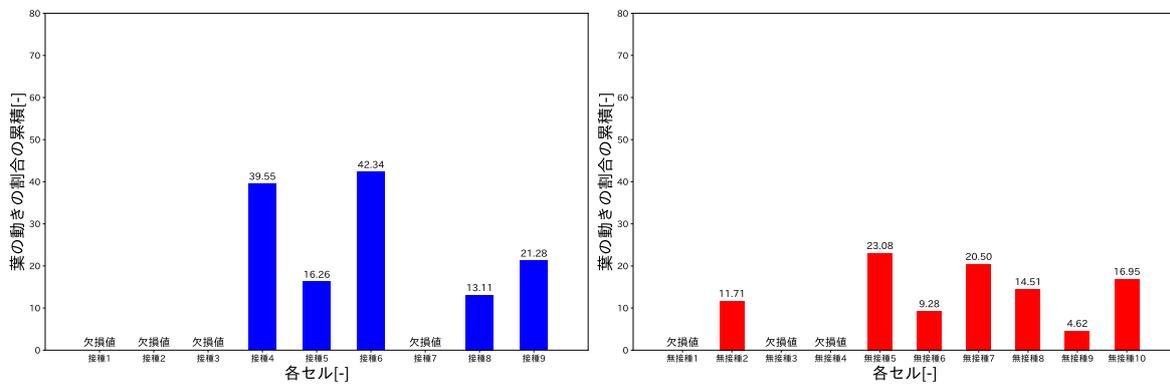
図 B.10: (6時基準) 期間①8月2日の各日の葉の動きの割合

B.2 6時の画像を基準として葉の動きを求める方法

B.2.2 期間②



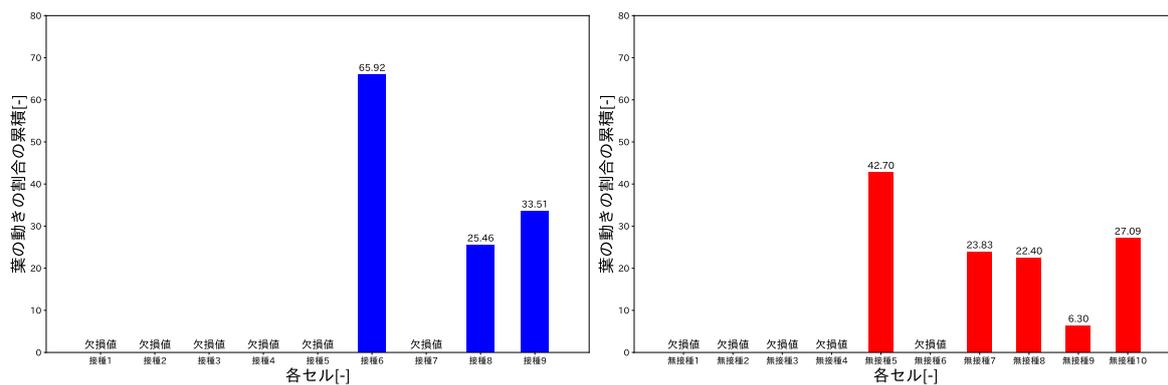
(a) 日中の葉の動きの割合を用いた場合



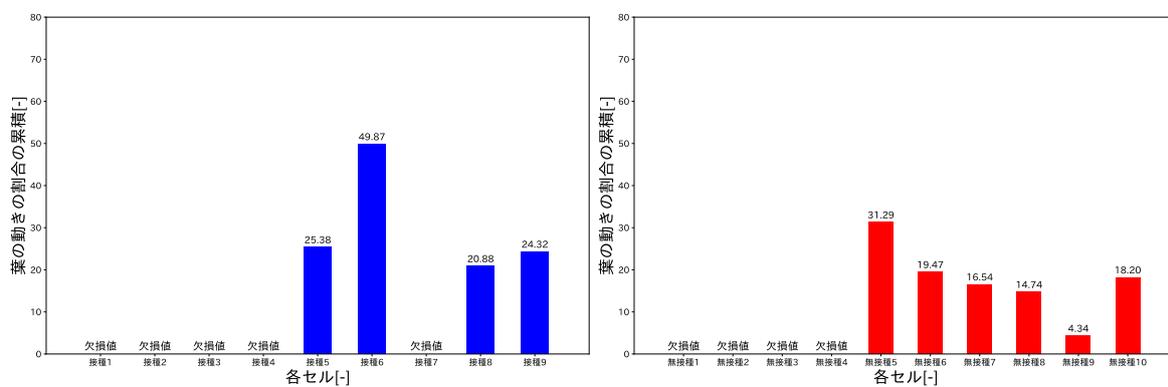
(b) 午後の葉の動きの割合を用いた場合

図 B.11: (6時基準) 期間②8月15日の各日の葉の動きの割合

B.2 6時の画像を基準として葉の動きを求める方法



(a) 日中の葉の動きの割合を用いた場合

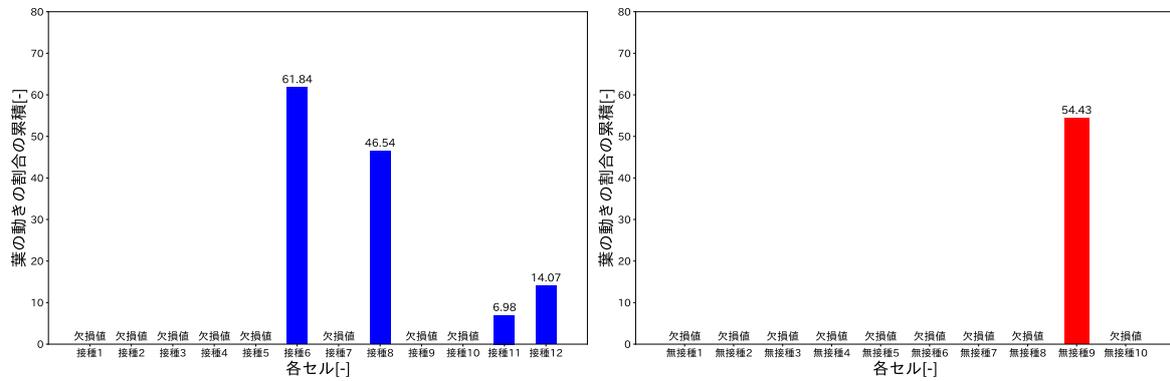


(b) 午後の葉の動きの割合を用いた場合

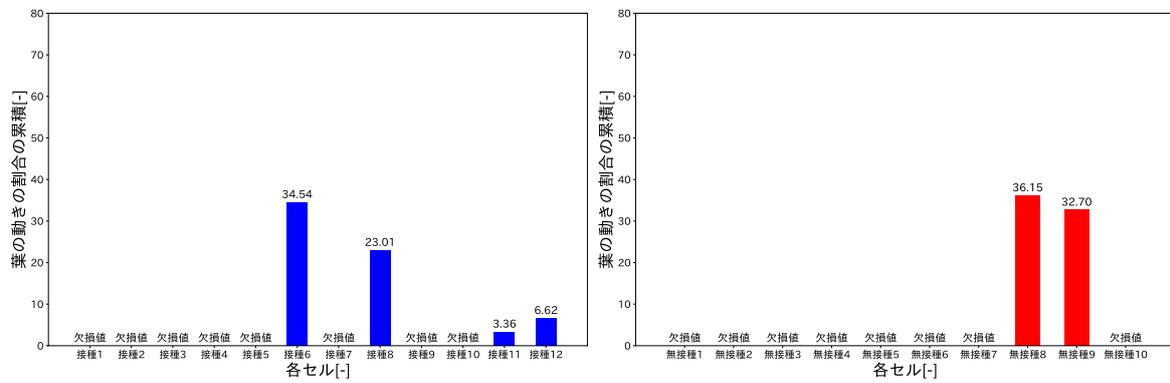
図 B.12: (6時基準) 期間②8月16日の各日の葉の動きの割合

B.2 6時の画像を基準として葉の動きを求める方法

B.2.3 期間③



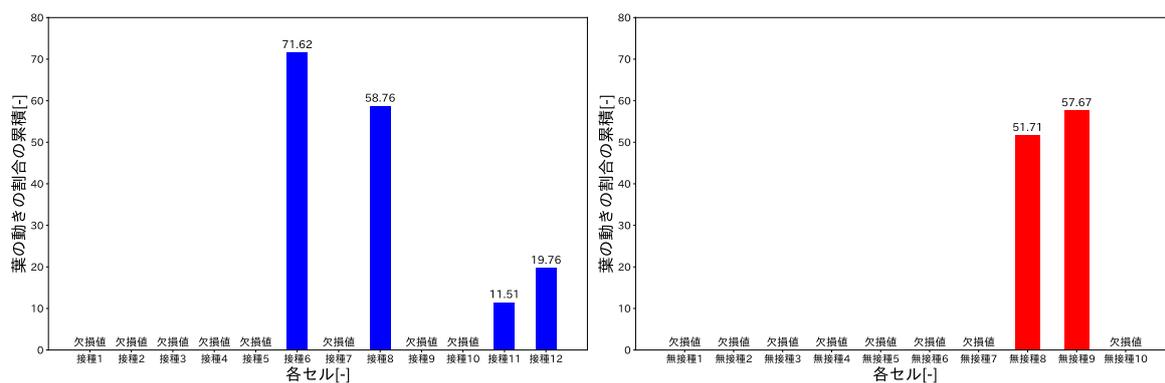
(a) 日中の葉の動きの割合を用いた場合



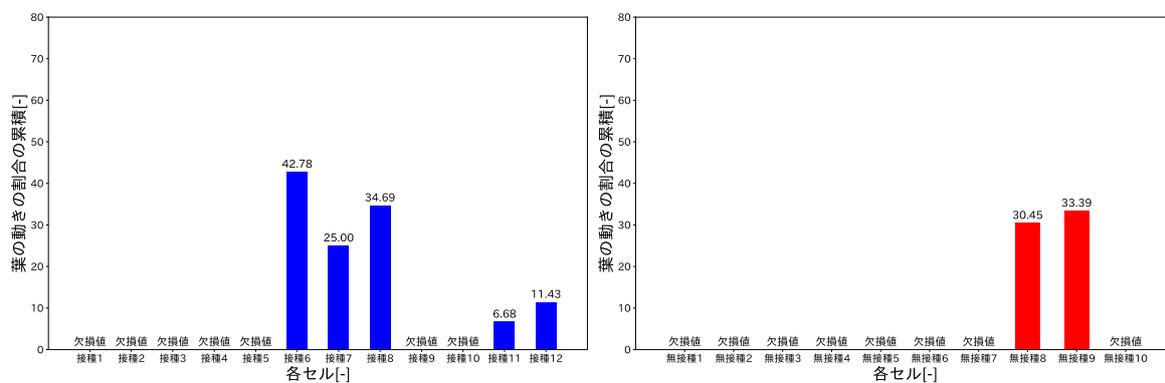
(b) 午後の葉の動きの割合を用いた場合

図 B.13: (6時基準) 期間③8月30日の各日の葉の動きの割合

B.2 6時の画像を基準として葉の動きを求める方法



(a) 日中の葉の動きの割合を用いた場合



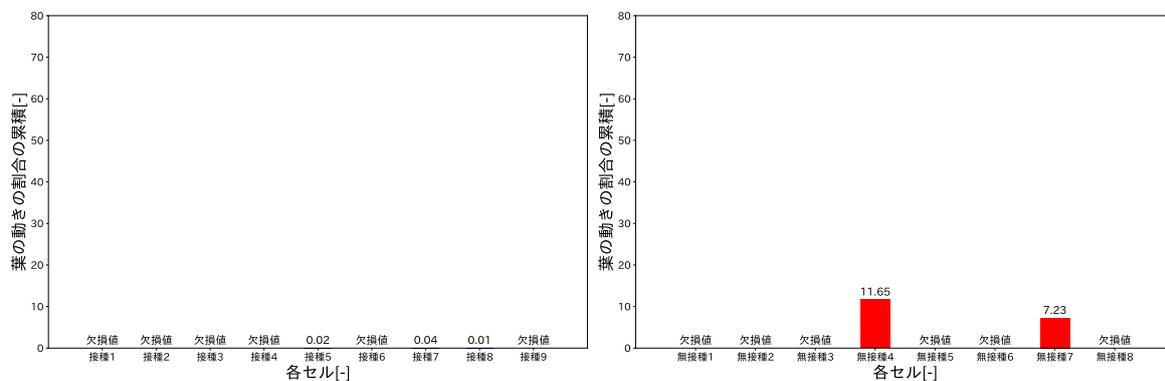
(b) 午後の葉の動きの割合を用いた場合

図 B.14: (6時基準) 期間③8月31日の各日の葉の動きの割合

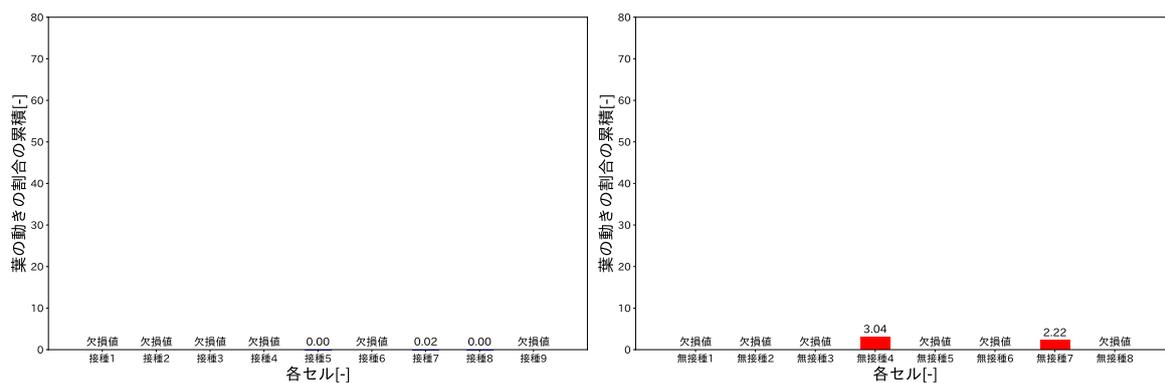
B.3 12時の画像を基準として葉の動きを求める方法

B.3 12時の画像を基準として葉の動きを求める方法

B.3.1 期間①



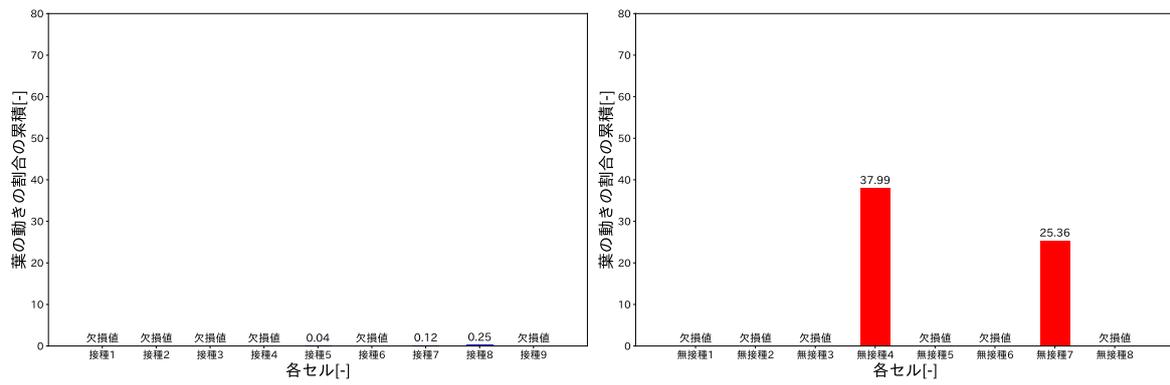
(a) 日中の葉の動きの割合を用いた場合



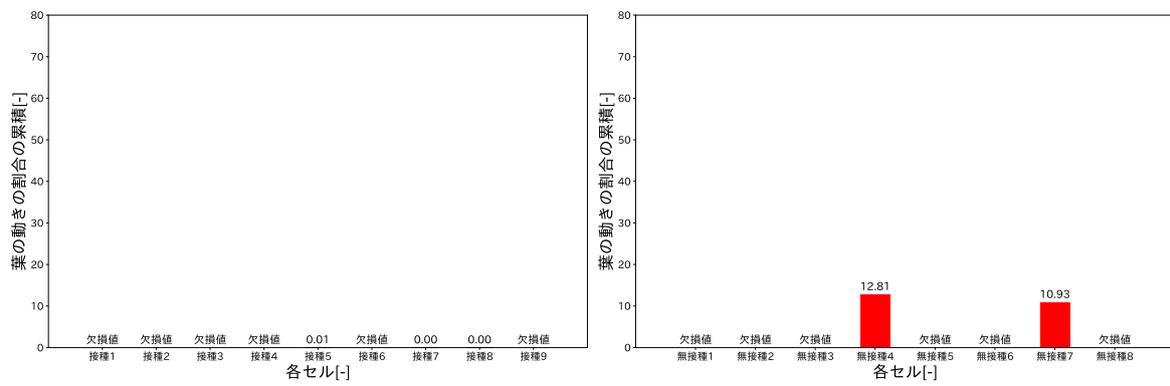
(b) 午後の葉の動きの割合を用いた場合

図 B.15: (12時基準) 期間①7月31日の各日の葉の動きの割合

B.3 12時の画像を基準として葉の動きをを求める方法



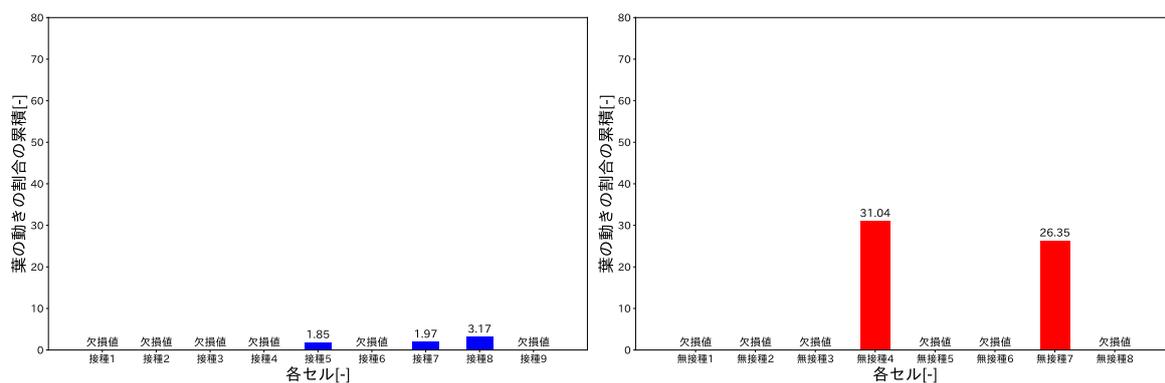
(a) 日中の葉の動きの割合を用いた場合



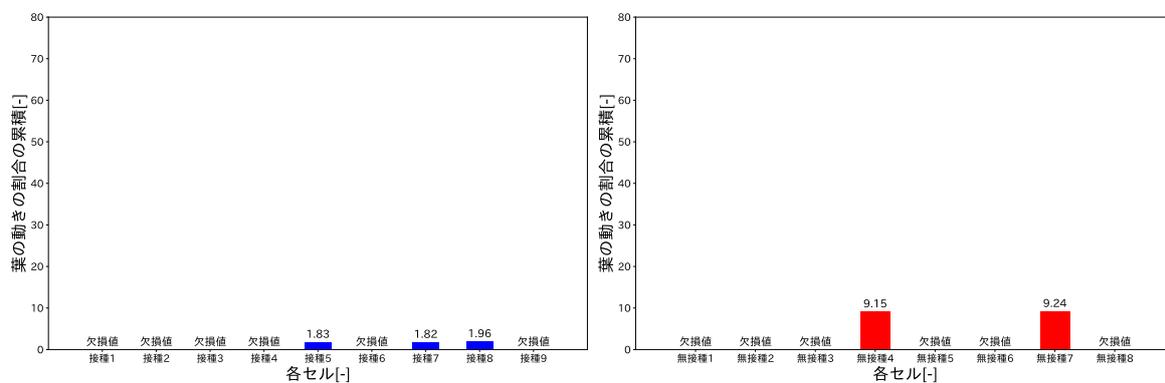
(b) 午後の葉の動きの割合を用いた場合

図 B.16: (12時基準) 期間①8月1日の各日の葉の動きの割合

B.3 12時の画像を基準として葉の動きをを求める方法



(a) 日中の葉の動きの割合を用いた場合

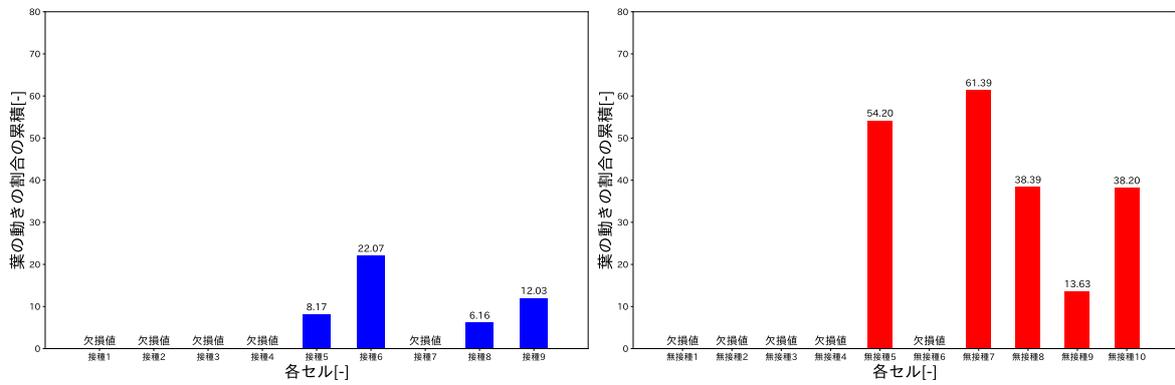


(b) 午後の葉の動きの割合を用いた場合

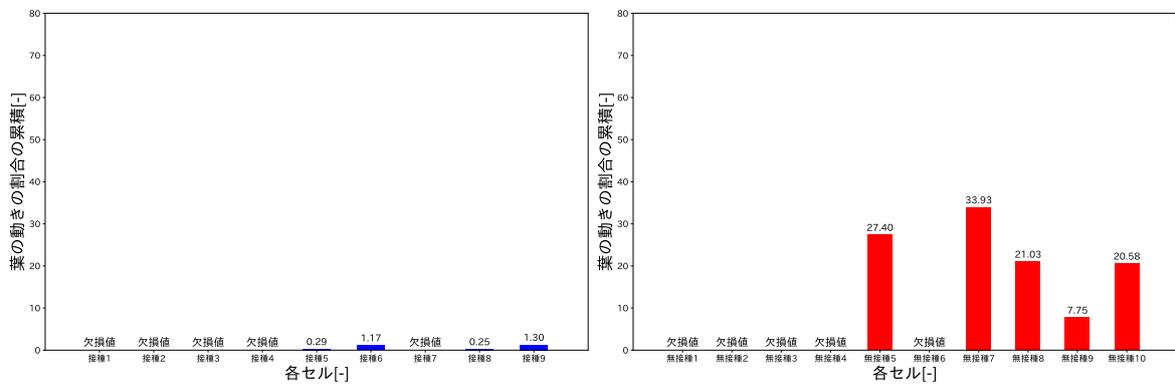
図 B.17: (12時基準) 期間①8月2日の各日の葉の動きの割合

B.3 12時の画像を基準として葉の動きを求める方法

B.3.2 期間②



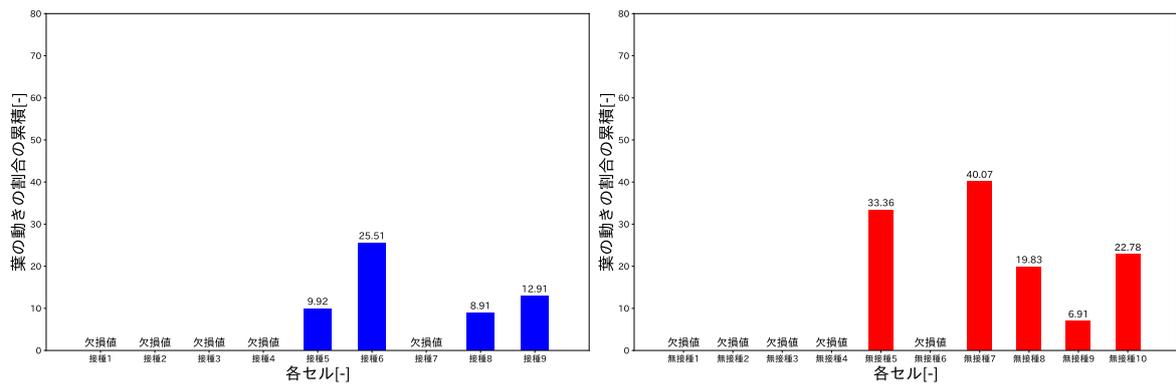
(a) 日中の葉の動きの割合を用いた場合



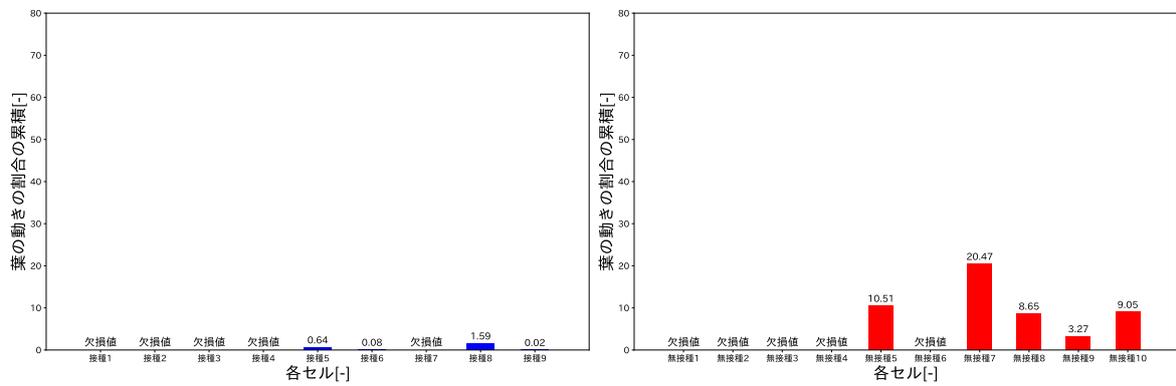
(b) 午後の葉の動きの割合を用いた場合

図 B.18: (12時基準) 期間②8月15日の各日の葉の動きの割合

B.3 12時の画像を基準として葉の動きをを求める方法



(a) 日中の葉の動きの割合を用いた場合

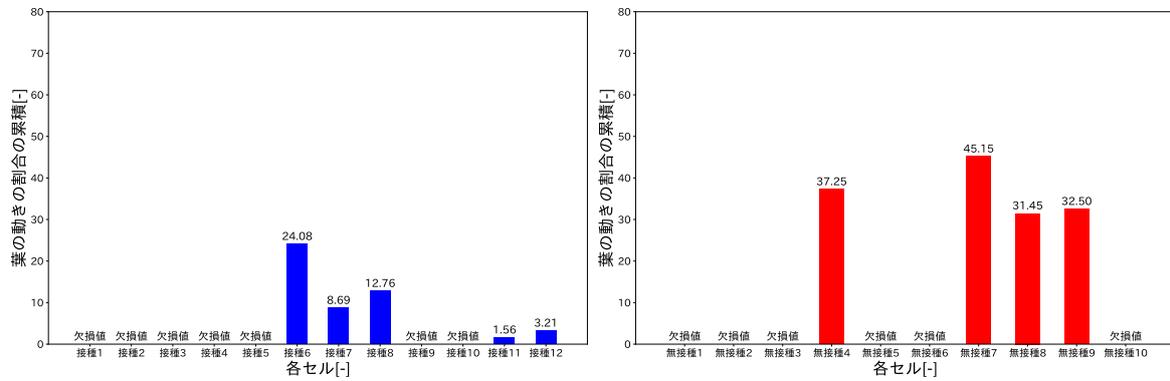


(b) 午後の葉の動きの割合を用いた場合

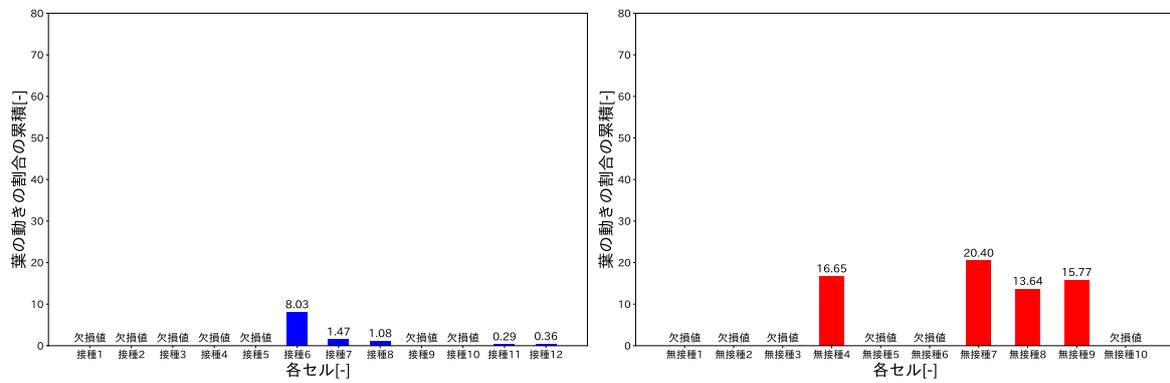
図 B.19: (12時基準) 期間②8月16日の各日の葉の動きの割合

B.3 12時の画像を基準として葉の動きを求める方法

B.3.3 期間③



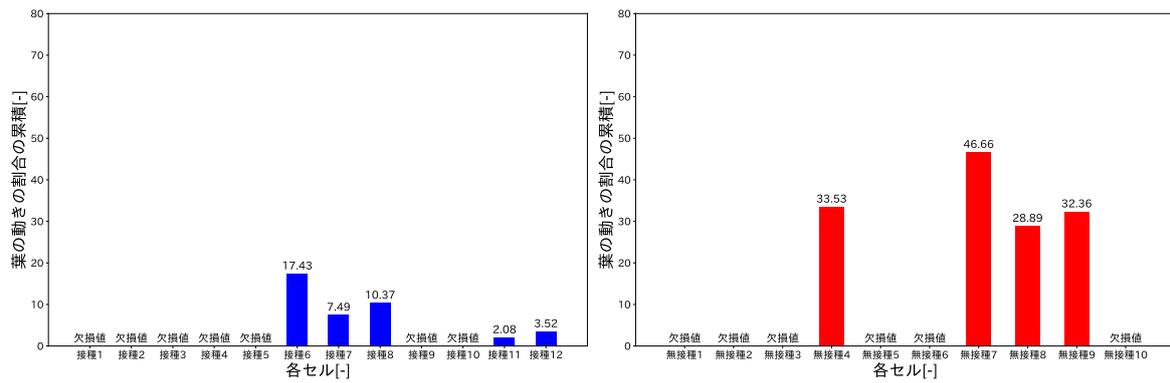
(a) 日中の葉の動きの割合を用いた場合



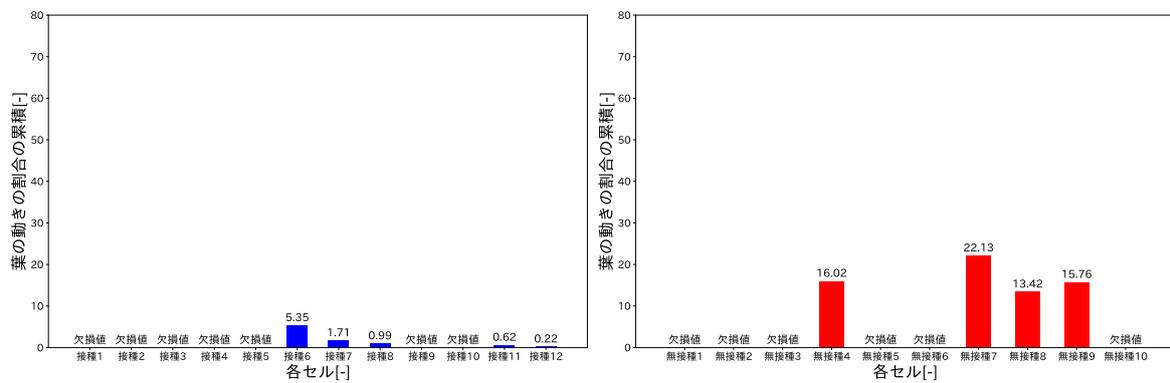
(b) 午後の葉の動きの割合を用いた場合

図 B.20: (12時基準) 期間③8月30日の各日の葉の動きの割合

B.3 12時の画像を基準として葉の動きをを求める方法



(a) 日中の葉の動きの割合を用いた場合



(b) 午後の葉の動きの割合を用いた場合

図 B.21: (12時基準) 期間③8月31日の各日の葉の動きの割合

付録 C

検証データにおける日射量と気温

本章では、本稿で示さなかった検証データにおける日射量と気温のグラフを示す。これらの日射量と気温は検証に使用した撮影画像の撮影場所である高知県農業技術センターで計測されたものである。日射量は検証データにおいて実際にショウガを撮影したハウスに近い別のハウスにおけるデータで、1分ごとに取得を行ったものである。また、気温はショウガを撮影したハウスにおけるデータで30分ごとに取得を行ったものである。

C.1 期間①

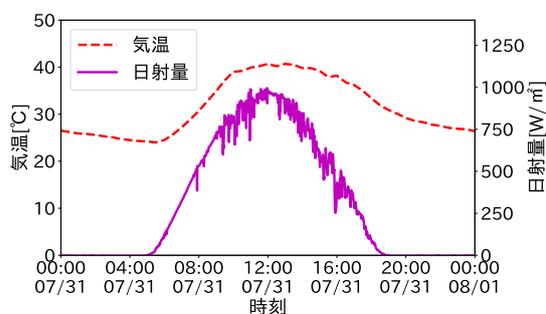


図 C.1: 期間① 7月31日の日射量と気温

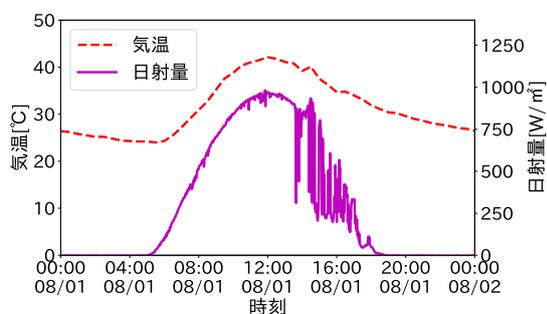


図 C.2: 期間① 8月1日の日射量と気温

C.2 期間②

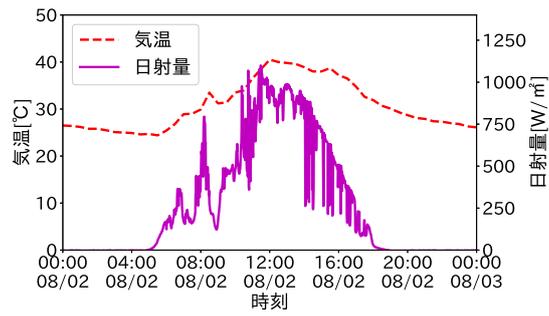


図 C.3: 期間① 8月2日の日射量と気温

C.2 期間②

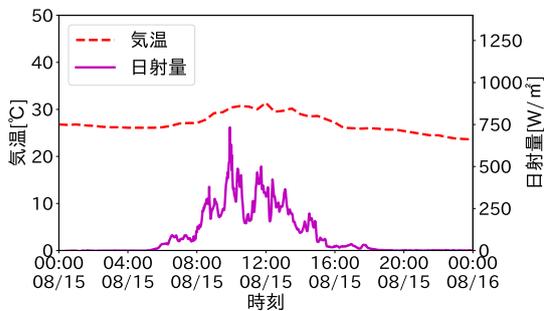


図 C.4: 期間② 8月15日の日射量と気温

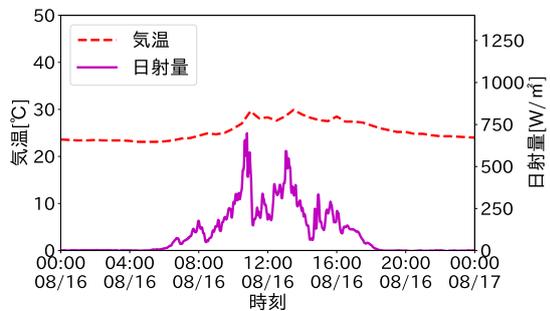


図 C.5: 期間② 8月16日の日射量と気温

C.3 期間③

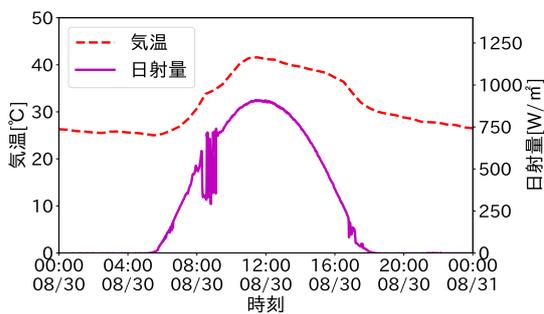


図 C.6: 期間③ 8月30日の日射量と気温

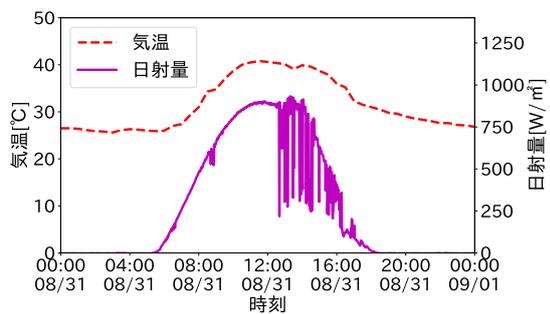


図 C.7: 期間③ 8月31日の日射量と気温