

令和元年度
修士学位論文

PLS 回帰を用いたハイパースペクトル 画像からのピーマン領域検出と評価

Green pepper region detection in hyperspectral
images using PLS regression and its Evaluation

1225123 竹原 慎

指導教員 栗原 徹

2020 年 2 月 28 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

PLS 回帰を用いたハイパースペクトル 画像からのピーマン領域検出と評価

竹原 慎

農業従事者の減少や高齢化から労働力が低下しており、近年多くの自動収穫ロボットが開発されている。それらはカメラを用いて果実の色彩特徴や形状特徴を利用した検出を行っているものが多いが、葉や茎と同じ色を持つ緑色の果実の検出はそれらの手法では難しい。そこで本研究ではハイパースペクトル画像から PLS 回帰によるピーマン果実の検出を行う。

ハイパースペクトラルとは多数波長を取得することができるカメラであり、RGB カメラよりも多くの色情報を活用することができる。

PLS 回帰とは回帰分析手法のひとつで、説明変数を目的変数に応じて次元圧縮して回帰を行うことが特徴であり、多手法に比べて共線性に強く、識別や分類に有効な手法であることが知られている。

ピーマンの赤外光を含むハイパースペクトル画像を取得し、画像中からノイズを除くために LPF をかけ、計算された各画素の反射率を用いた PLS 回帰によって果実部と背景に分類を行う回帰モデルを作成する。この回帰モデルによって得られた推定値を 2 値化し、画像中からピーマンを検出する。また提案手法を用いた評価実験を行った結果、正解率 93.43 %，F 値 0.8005 という結果が得られ、他回帰手法に比べ本手法は高い検出率を持っていることを確認した。

キーワード IoP, 果実検出, ハイパースペクトルカメラ, PLS 回帰, ピーマン

Abstract

Green pepper region detection in hyperspectral images using PLS regression and its Evaluation

Makoto TAKEHARA

The labor force is decreasing due to the decrease in the number of farmers and the aging population, and many automatic harvesting robots have been developed in recent years. Most of these robots use a camera to detect fruits using the color and shape characteristics, but it is difficult to detect green fruits having the same color as leaves and stems. Therefore, in this study, we detect fruits of green pepper in hyperspectral images using PLS regression.

Hyperspectral camera can acquire many wavelengths and can utilize more color information than RGB camera.

PLS regression is one of the regression analysis methods, and the feature is that regression is performed by compressing the explanatory variables dimensionally according to the target variables. It is known that the method is stronger in collinearity than the multiple methods and is effective for identification and classification.

We obtain a hyperspectral image containing peppers' infrared light, apply LPF to remove noise from the image, and create a regression model that classifies fruits and background by PLS regression using the calculated reflectance of each pixel.

The estimated value obtained by this regression model is binarized and green peppers are detected in the image. In addition, as a result of evaluation experiments using the proposed method, we obtain a correct accuracy rate of 93.43 percent and an F value

of 0.8005, confirm that this method has a higher detection rate than other regression methods.

key words IoP, Fruits detection, Hyperspectral camera, PLS regression, Green pepper

目次

第 1 章	はじめに	1
1.1	背景と目的	1
1.2	論文構成	3
第 2 章	関連技術	4
2.1	ハイパースペクトルカメラ	4
2.2	分光反射特性	7
2.3	PLS 回帰	7
2.4	大津法, 判別分析法	8
2.5	ROC 曲線	9
2.6	VIP(Variable Influence Projection) 値	10
第 3 章	関連研究	11
3.1	複数波長を用いた物質判別	11
3.2	果実検出	12
3.3	ハイパースペクトルカメラを用いた果実検出	12
第 4 章	提案手法	13
4.1	LPF	14
4.2	反射率の計算	14
4.2.1	白色拡散反射板検出	15
4.3	PLS 回帰	16
4.3.1	説明変数	16
4.3.2	目的変数	17
4.3.3	交差検証	17

目次

4.4	2 値化による領域検出	18
第 5 章	実験	19
5.1	データセット	19
5.2	LPF	19
5.3	反射板検出結果	19
5.4	交差検証結果	22
5.5	評価実験	22
5.5.1	回帰手法評価比較	23
5.5.2	ROC 曲線による手法評価比較	28
5.5.3	2 値化手法比較	29
5.5.4	波長ごとの寄与率比較	33
第 6 章	まとめ	37
	謝辞	38
	参考文献	39

目次

1.1	農業就業人口の推移	2
1.2	生育中のピーマンの様子	2
2.1	ハイパースペクトルカメラ	5
2.2	RGB 画像	5
2.3	RGB 画像のスペクトラム	6
2.4	各波長域画像	6
4.1	手順図	13
4.2	画像に入るノイズの例	14
4.3	各領域のスペクトル強度	15
5.1	学習データ	20
5.2	使用フィルタ	20
5.3	LPF 結果画像	21
5.4	反射板検出結果	21
5.5	交差検証の結果	22
5.6	提案手法で F 値 0.9 以上の結果画像	25
5.7	提案手法で F 値 0.8 未満 0.6 以上の結果画像	26
5.8	提案手法で F 値 0.4 以下	27
5.9	ROC 曲線	28
5.10	正負での 2 値化で正しく分類されなかった例	30
5.11	大津の 2 値化で正しく分類されなかった例	31
5.12	差分での 2 値化で正しく分類されなかった例	32
5.13	成分抽出の際の各波長成分に対する重み比率	34

図目次

5.14 各主成分までを用いた回帰モデルを用いた推測結果	35
5.15 第 20 成分までを用いた回帰の VIP 値	36

表目次

2.1	分類結果の対応表	9
5.1	手法ごとの評価指標	23
5.2	手法ごとの F 値の個数分布	24
5.3	2 値化手法ごとの評価	29

第 1 章

はじめに

1.1 背景と目的

近年日本では農業就業人口の減少を伴う高齢化が進んでいる。農林水産省が統計をとった農業就業人口の推移を図 1.1 に示す。農業就業人口は 260 万人いた平成 22 年度に対して、平成 31 年度には 168 万人となっており、9 年間で約 100 万人減少している。また、農業就業人口のうち 65 歳以上の割合は平成 22 年度では 61.5 %であったのに対して、平成 31 年度では 70.2 %と、9 年間で約 10 %上がっている。

このように農業労働力不足が深刻化している中で、生産性の向上や、作物の品質向上などを目的としたスマート農業技術の実装が進められている。スマート農業は、ロボット、AI,IoT, ドローン等の先端技術をこれまでの農業に組み合わせた農業のことで、ロボットによる農作業の自動化・省力化、データの AI 分析による栽培管理などが挙げられる。その中でロボットによる作業の自動化のために、自動野菜収穫ロボットが様々な果実を対象に開発されている。これらのロボットはカメラや距離センサーなどが搭載されており、それらを用いて果実の認識やサイズ判別、収穫判断を行っていることが多い。これらは果実の色彩特徴や形状特徴を用いて検出しているが、図 1.2 ピーマンのような緑色の果実は葉や茎といった同色の物体が多く周囲に存在するため、果実特有の色彩特徴を用いることが難しく、輪郭線も見えづらい環境が多いため形状特徴の抽出も難しい。そこで本研究ではハイパースペクトルカメラを用い、撮影されたマルチバンド画像から PLS 回帰 [1] を用いて、ピーマンの果実を検出する。

1.1 背景と目的




図 1.1 農業就業人口の推移



図 1.2 生育中のピーマンの様子

1.2 論文構成

本論文の構成は以下の通りである．

第 2 章は本研究の関連技術として，ハイパースペクトル，分光反射特性，PLS 回帰，判別分析法について記述する．

第 3 章は本研究に関連する研究について記述する．

第 4 章は提案手法におけるシステムの概要とそれぞれの処理手順を順に述べる．

第 5 章では提案手法の実装環境と，評価実験についての説明，結果，考察について述べる．

第 6 章では本論文をまとめ，今後の展望について述べる．

第 2 章

関連技術

2.1 ハイパースペクトルカメラ

一般的な RGB カメラは青色波長域である 450nm～495nm, 緑色波長領域である 495～570nm, 赤色波長領域である 620～750nm からそれぞれ 1 波長ずつの 3 バンドをセンサで受け取り, デジタル化している. これに対し, ハイパースペクトルカメラは通常のカメラが 3 バンドであることに対して, 100, 200 バンド以上の取得を可能にしたカメラである. これにより通常のカメラでは判別不可能な色の違いや, 波長スペクトルの分布を知ることができる. 図 2.1 に使用したハイパースペクトルカメラを示す. 図 2.2 のような対象を撮影すると, それぞれのオブジェの点上で図 2.3 のようなスペクトルデータが取得できる. このスペクトルデータから各波長域で画像化すると図 2.4 のような画像が得られる.

これらの特徴を生かして様々な分野で使われている. 例えば農業分野では植物の特定波長の分光反射率の違いによって導き出される NDVI という植生指標があり, この指標と葉内窒素率や成長率との相関がみられており, 農産物の成分分析や植生観察に用いられている.

2.1 ハイパースペクトルカメラ



図 2.1 ハイパースペクトルカメラ



図 2.2 RGB 画像

2.1 ハイパースペクトルカメラ







図 2.3 RGB 画像のスペクトラム



[1] 赤色波長域の画像



[2] 緑色波長域の画像



[3] 青色波長域の画像

図 2.4 各波長域画像

2.2 分光反射特性

物体に光が入射した際、吸収される光と反射光に分かれる。このとき入射光の強度に対し、反射光の強度の比を反射率という。そして波長ごとの物体の反射率を分光反射特性、分光反射率と呼ばれる。物体の成分ごとに異なる分光反射率を持つため、リモートセンシングや物体判別に用いられている。

2.3 PLS 回帰

PLS 回帰（部分最小二乗回帰）は回帰分析手法の 1 つで、説明変数から目的変数との共分散の絶対値が最大になるように抽出した成分群と目的変数との最小二乗法によって回帰式を導く手法である。説明変数から特定の成分を抽出するため、重回帰分析よりも多重共線性による結果のブレに強く、目的変数も考慮して説明変数から成分を抽出するため、識別や分類に有効であると知られている [2]。

本研究では説明変数に波長スペクトルを用いるため変数が多く、隣り合う波長同士で相関が高くなりやすく多重共線性が起こりやすい。その点において成分を抽出し次元縮小が行われるため、サンプルが少ない場合でも予測精度の高い推定を可能にしている。また、目的変数との相関を考慮して成分を抽出するため、主成分分析によって成分を抽出する PCR（主成分回帰）よりも低次元で高精度な識別が可能となっている。

PLS 回帰は以下のように行われる。説明変数を X ，目的変数を y としたとき式 (2.1) より目的変数との共分散の大きな部分空間の基底ベクトル w を求める。

$$w = \frac{X^T y}{\|X^T y\|} \quad (2.1)$$

次に式 (2.2) のように求めた基底 w 空間に X を射影することで、成分 t を得る。

$$t = Xw \quad (2.2)$$

次の成分を抽出するために説明変数と目的変数から、先ほど得た成分 t の情報を削除する。そのために成分 t から X, y を回帰する回帰係数 p, c を式 (2.3)(2.4) で求め、式 (2.5)(2.6) の

2.4 大津法, 判別分析法

ように削除し, 成分を取り除いた新たな説明変数 X' と目的変数 y' を得る.

$$p = \frac{t^T X}{||t^T t||} \quad (2.3)$$

$$c = \frac{t^T y}{||t^T t||} \quad (2.4)$$

$$X' = X - tp \quad (2.5)$$

$$y' = y - tc \quad (2.6)$$

これを必要な成分数繰り返すことで成分を抽出していく. そして求めた w, p, c の各成分で求まる要素それぞれ連結させたものを W, P, C とすると式 (2.7) のようにすることで, 回帰係数 B が得られる.

$$B = W(P^T W)^{-1} C \quad (2.7)$$

2.4 大津法, 判別分析法

大津法, 判別分析法とはある数値を 2 クラスに分類する際の閾値を対象の数値に応じて決定する手法である [3]. これを 2 値化に当てはめ, 画像中の輝度値のヒストグラムを白のクラスと黒のクラスに分類する.

この手法では閾値をそれぞれのクラス内の分散を小さくしつつ, 各クラスの平均の値が離れたものになるようにすることで, 画像全体の輝度バランスに応じた 2 値化を可能にする. クラスを C_1 と C_2 ととする. 画像全体の画素数を ω , 平均を μ , 分散を σ^2 とし, それぞれのクラスの画素数を ω_1, ω_2 , 輝度値の平均を μ_1, μ_2 , 輝度値の分散を σ_1^2, σ_2^2 とする.

各クラスの分散の平均値であるクラス内分散 σ_ω^2 は以下の式 (2.8) で表せる.

$$\sigma_\omega^2 = \frac{\omega_1 \sigma_1^2 + \omega_2 \sigma_2^2}{\omega} \quad (2.8)$$

各クラスの平均値の分散であるクラス間分散 σ_b^2 は以下の式 (2.9) で表せる.

$$\sigma_b^2 = \frac{\omega_1 (\mu_1 - \mu)^2 + \omega_2 (\mu_2 - \mu)^2}{\omega} \quad (2.9)$$

また, 式 (2.10) は常に成り立つ.

$$\sigma^2 = \sigma_\omega^2 + \sigma_b^2 \quad (2.10)$$

2.5 ROC 曲線

各クラス内の分散を小さくしつつ、各クラスの平均が離れているクラス分類が望ましいため、分離度 $\frac{\sigma_b^2}{\sigma_\omega^2}$ が最大になる閾値を決定する．式 (2.11) より、分離度 $\frac{\sigma_b^2}{\sigma_\omega^2}$ は式となる．

$$\frac{\sigma_b^2}{\sigma_\omega^2} = \frac{\sigma_b^2}{\sigma^2 - \sigma_b^2} \quad (2.11)$$

σ^2 は閾値と関係なく定数であるため、 σ_b^2 が最大となるとき分離度も最大となる．

2.5 ROC 曲線

ROC 曲線とは機械学習のモデルの精度評価に用いられる指標である．

モデルより得られた数値を閾値によって陽性と陰性に分類するが、この時分類された結果は表 2.1 のように 4 種類のような結果になる．このとき真に陽性であるものを陽性と分類した割合を示す真陽性率 (TPR) は $\frac{TP}{TP + FN}$ 、誤って陰性であるものを陽性であると分類した割合を示す偽陽性率 (FPR) は $\frac{FP}{FP + TN}$ と計算される．真陽性率と偽陽性率は閾値によって変動し、一般的に真陽性率の高い閾値を設定すると偽陽性率も高くなり、偽陽性率が低い閾値を設定すると真陽性率も低くなる．

ROC 曲線は縦軸を真陽性率、横軸を偽陰性率としグラフを作成する．閾値を変更しながら分類を行い、それぞれの閾値での真陽性率、偽陰性率を求めグラフにプロットし曲線を描く．真陽性率が高く、かつ偽陰性率が低いモデル程優れているモデルであり、ROC 曲線ではそのようなモデルほど左上に位置されている．

表 2.1 分類結果の対応表

		正解ラベル	
		陽性	陰性
予測結果	陽性	真陽性 (TP)	偽陽性 (FP)
	陰性	偽陰性 (FN)	真陰性 (TN)

2.6 VIP(Variable Influence Projection) 値

VIP 値とは PLS 回帰分析を行う過程で得られるパラメータを用いて求められる，波長の重要度を表す指標である [4]．VIP 値が大きな波長ほど回帰において，高い重要度であることを示す．

式に各波長の VIP 値の求め方を示す． K は特徴次元数， a は a 番目の成分抽出， A は全成分抽出数， W は PLS により求められた基底ベクトルを連結させたもの， C は PLS により求められた成分から y を回帰する回帰係数 c を連結させたもの， P は PLS により求められた成分から X を回帰する回帰係数 p を連結させたものを表す．

$$VIP_k = \sqrt{\frac{K \sum_{a=1}^A (C'_a P_a)^2 W_{ka}^2}{\sum_{a=1}^A (C'_a P_a)^2}} \quad (2.12)$$

第 3 章

関連研究

3.1 複数波長を用いた物質判別

ハイパースペクトルカメラを用いて撮影し，複数の波長を用いて物質判別や特定物質の検出を行う研究がなされている．

竹内ら [5] はハイパースペクトルカメラを用いた異物検出を提案した．分光反射特性を用いて，得られたハイパースペクトルデータをベクトル化し，異物のハイパースペクトルデータと異物以外のハイパースペクトルデータとのコサイン距離を用いて解析した．

安部ら [6] は，近赤外領域の分光反射特性の違いを利用した，複数木材の判別を提案した．得られたスペクトルデータに対し 2 次微分を行い，主成分分析を行うことで，各木材における主成分のローディングスコアの違いを分析した．

枝長ら [7] は，災害時の要救助者を検出するために，赤外領域波長を利用した人肌を抽出する指標 NDHI を提案した．赤外領域の中から人肌の検出に適した波長を選択し，それらを用いた指標を作成することで，様々な背景から人肌領域を検出している．

服部ら [8] は，ハイパースペクトルカメラを用いた物質判別手法を提案した．この手法では分光反射特性に着目し，反射率を用いた PLS 回帰を行うことで，クラス判別を行う回帰式を求め，それらを組み合わせることで多クラス分類を行っている．しかし植物，手（人肌），コンクリートの大きく分光反射特性の異なる 3 物質での分類であり，似た分光反射特性を持つ物質判別は行われていない．

3.2 果実検出

3.2 果実検出

農業分野で自動収穫ロボットなどのために果実を検出する研究がなされている。

太田ら [9] はハロゲン光を果実方向に照射し、それをステレオカメラで捉え、鏡面反射の対応付けすることで、トマトを対象とした果実の 3 次元位置を特定するシステムを提案した。果実の検出は色情報を用いて行っており、そののちに 2 つのカメラで捉えられた鏡面反射を対応付けることで、位置の特定を行っている。

有馬ら [10] は RGB カメラを用い、吊らされているようになっているイチゴを検出した。これも同様に色情報を用いて、果実を検出している。このように赤色の果実は色情報を用いて検出されていることが多い。

林ら [11] は事前に葉を剪定したのちに、RGB カメラを用い茄子果実を検出するちゅうほうを提案した。果実検出には色情報と形状特徴の両方を用い、色情報を用い葉を取り除いたのちに、形状特徴より収穫適期の果実を検出している。

庄野ら [12] は画像処理によってキュウリ果実の検出法を提案している。RGB カメラを用いて果実を撮影し、画像から稜線を検出し、線の形状をもとに検出を行っている。キュウリは緑色であるため、形状特徴を捉えることで、果実を検出している。

3.3 ハイパースペクトルカメラを用いた果実検出

緑色の果実を検出するためにハイパースペクトルカメラが利用されている。

岡本ら [13] はハイパースペクトルカメラで得られた画像から線形判別分析によって、未成熟な緑色の柑橘類を検出法を提案した。線形判別分析によって識別関数を作成し、その後画像処理によって果実の識別を行っている。

DING ら [14] はハイパースペクトルカメラを用いて取得された複数波長から数波長を選択し用いて未成熟な緑色の柑橘類の検出法を提案した。選択された数波長間での強度勾配を計算し、それらの勾配パラメータで分類器を作成し、それをもとに検出を行っている。

第 4 章

提案手法

提案手法ではハイパースペクトルカメラを用いて撮影されたマルチバンド画像から PLS 回帰を用いてピーマンの画素を検出する。検出の手順は、ノイズを取り除くために LPF をかけ、次に画像処理手法を用いて白色反射板領域を検出し、白色反射板の反射スペクトルを用いて、各画素の反射率を求める。次にピーマンの画素の反射率を用いて PLS 回帰を行い、ピーマンの画素であれば 1, それ以外の画素であれば -1 を返すように回帰式を作成する。得られた推定値を 2 値化することでピーマン領域を検出する。手順を図 4.1 に示す。

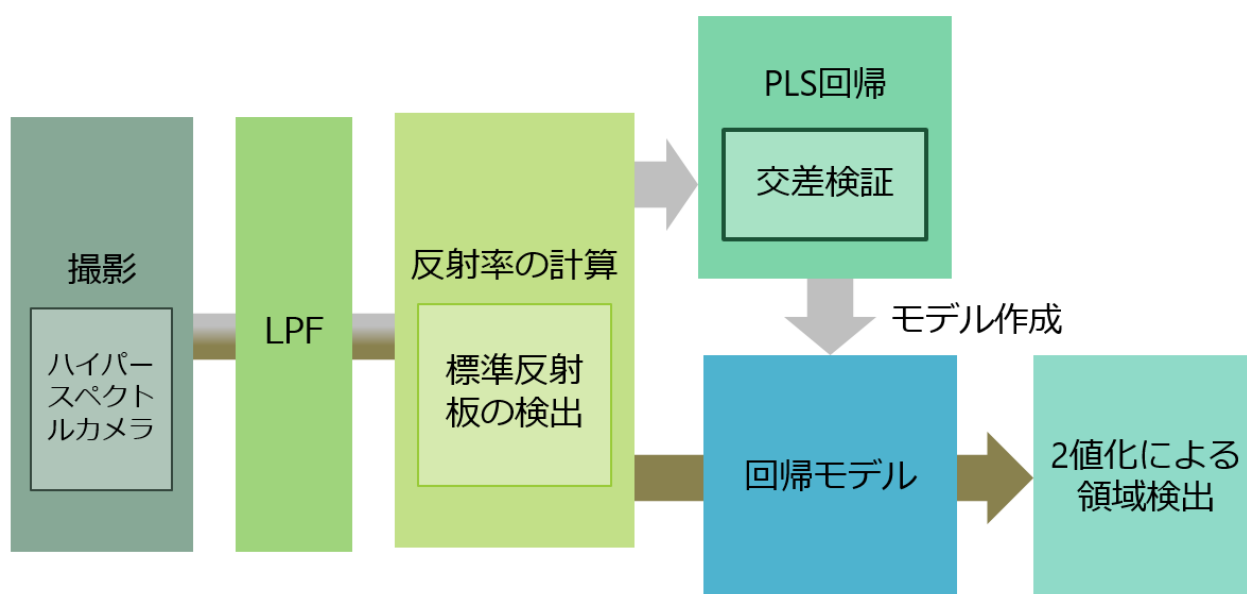



図 4.1 手順図

4.1 LPF

4.1 LPF

ハイパースペクトルカメラで撮影される画像には図 4.2 のように，波長ごとに違う位置に縦，横に直線でノイズが入っている．これらを取り除くために低域通過フィルタによって各波長ごとに高周波成分を取り除く．

撮影画像を各波長ごとに 2 次元フーリエ変換し周波数成分に変換する．変換した各波長ごとの画像に対し，フィルタを適用し，高周波成分の強度を 0 にする．これを 2 次元フーリエ逆変換することで，ノイズを取り除いた画像を作成する．



[1] 波長 500nm での強度画像 [2] 波長 600nm での強度画像 [3] 波長 700nm での強度画像

図 4.2 画像に入るノイズの例

4.2 反射率の計算

取得スペクトルから分光反射率を求めることで光源環境に関わらず，物質の特徴を捉えることができる．本研究では取得スペクトルは光源スペクトルが分光反射率に乗算されているとし，取得スペクトルから光源スペクトルを除算することで，分光反射率を推定する．推定される分光反射率を本稿では反射スペクトルと記述する．

ある画素 (i, j) において波長 k の推定される反射スペクトルを $R(i, j, k)$ ，得られた強度スペクトルを $x(i, j, k)$ ，画像中の光源スペクトルを $L(k)$ とすると式 (4.1) を行い画素ごとの反射スペクトルを求める．

$$R(i, j, k) = x(i, j, k) / L(k) \quad (4.1)$$

光源スペクトルは撮影時の環境によって異なり，一意に定めることが難しい．そこで本手

4.2 反射率の計算

法では画像内に入るように白色拡散反射板を設置し、その領域のスペクトル強度を光源スペクトルと仮定した。また、白色拡散反射板は画像毎で異なる位置に存在するため、画像処理により検出する。

4.2.1 白色拡散反射板検出

画像内には主に葉や実などの植物領域、環境光が直接入っている光背景領域、標準反射板の反射板領域、上記に当てはまらない植物を支える柱や標準反射板を支える三脚などの障害物領域が存在する。これらの領域それぞれは図 4.3 のようなスペクトル強度が得られる。

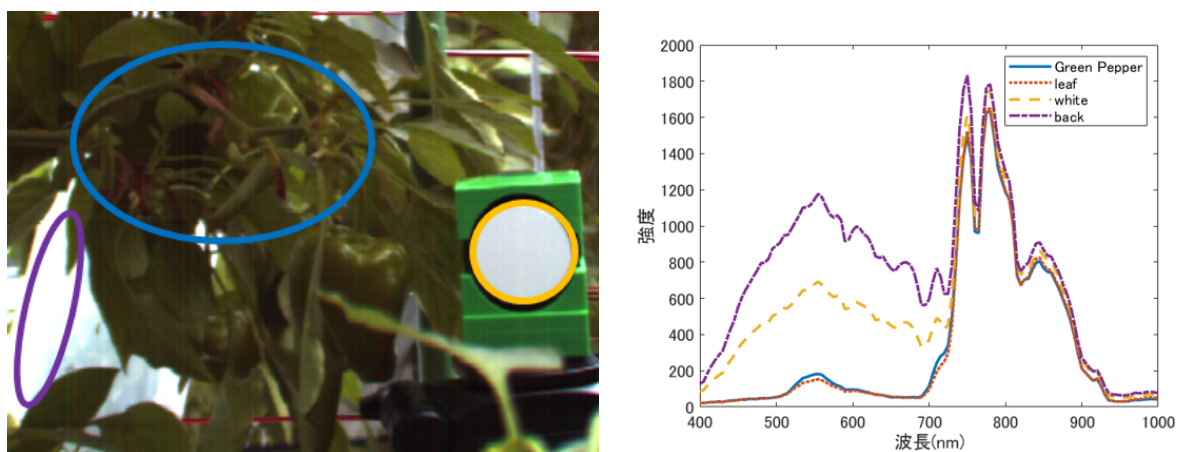


図 4.3 各領域のスペクトル強度

まず光背景領域を取り除く。光領域は他の物質に反射していないため、光が減衰しておらず、ほかの領域よりもエネルギーが強く、高い強度が得られている。そこで閾値を設定し、一定以上の強度を持っている画素を光背景領域として取り除く。

次に植物領域とそれ以外を分類する。植物領域は緑色をしているため、可視波長域の中でも緑色波長域の強度が、青色赤色波長域よりも高い強度が得られると考えられる。反射板は白色であるため 3 波長域間での強度差がそこまで出ないと考えられる。そこで青色波長域である 450 500nm, 緑色波長域である 520nm 570nm, 赤色波長域である 675nm 725nm でそれぞれの平均強度を連結させたベクトルを作成し、それを自身のノルムで割ることで単位ベクトル化する。これにより場所ごとでの絶対的な強度値に関わらず、それぞれ波長域ごと

4.3 PLS 回帰

の強度比を得ることができる．求めた単位ベクトルで 3 要素の分散を取り，閾値以上の分散を持つ箇所は反射板領域でないとして取り除く．

最後に形状特徴を用いて反射板領域の分類を行う．標準反射板は円形であり，領域の大きさも一定以上が見込まれる．そこで，また領域も分類されていない領域に対しラベリング処理によって連結成分を検出する．ここで検出された連結成分の中で大きさが大きい領域を抽出する．これらの領域で円形の領域を反射板領域とした．円形の領域の判断には円形度を用い，領域の円周と面積から最も円に近い領域を選択した．

4.3 PLS 回帰

PLS 回帰によるピーマン検出回帰モデルを作成する．

本研究での説明変数，目的変数を以下に記述する．

4.3.1 説明変数

説明変数には各画素の反射スペクトルを設定する．画素 (i, j) において推定された波長 k の反射スペクトル $R_{(i,j,k)}$ とすると，3 次元行列である R を各波長成分を行，画素位置を列にもつ 2 次元行列に変形する．画像サイズが 640×480 ，波長を 400nm から 1000nm まで 5nm 間隔で取得した反射スペクトルの変形後学習データ X は式 (4.9) のようになる．

$$X = \begin{pmatrix} R_{(1,1,400)} & R_{(1,1,405)} & \cdots & R_{(1,1,1000)} \\ R_{(1,2,400)} & R_{(1,2,405)} & \cdots & R_{(1,2,1000)} \\ \vdots & \vdots & \ddots & \vdots \\ R_{(1,480,400)} & R_{(1,480,405)} & \cdots & R_{(1,480,1000)} \\ R_{(2,1,400)} & R_{(2,1,405)} & \cdots & R_{(2,1,1000)} \\ R_{(2,2,400)} & R_{(2,2,405)} & \cdots & R_{(2,2,1000)} \\ \vdots & \vdots & \ddots & \vdots \\ R_{(640,480,400)} & R_{(640,480,405)} & \cdots & R_{(640,480,1000)} \end{pmatrix} \quad (4.2)$$

4.3 PLS 回帰

4.3.2 目的変数

目的変数には各画素がピーマンであるかどうかを示す値を設定する．ある画素がピーマンであれば 1，ピーマンでなければ-1 を説明変数に対応した列に格納する．そのために，カラー画像や 1 バンドを抽出したグレイスケール画像をもとに，ピーマンの領域のみが白色の 2 値画像を目視で作成する．この 2 値画像をもとに白色の部分を 1，黒色の部分を-1 とする行列を作り，1 行の行列へと変換する．変換前の行列を y とし，画素 (i, j) の値を $y_{(i,j)}$ とすると，目的変数 Y は式 (4.10) のように表される．

$$Y = \begin{pmatrix} y_{(1,1)} \\ y_{(1,2)} \\ \vdots \\ y_{(1,480)} \\ y_{(2,1)} \\ y_{(2,2)} \\ \vdots \\ y_{(640,480)} \end{pmatrix} \quad (4.3)$$

4.3.3 交差検証

交差検証とは標本データを学習データとテストデータに分割し，回帰されたモデルの精度を検証する手法である．今回はこれによって用いる成分数を決定する．

10 分割交差検証とは標本群を 10 分割し，そのうち 9 個で学習を行い，1 個を検証用データとして用い誤差を計算する．検証用データを変更しながらこれを 10 回繰り返し，精度検証を行う手法である．本実験では推定値と真値との 2 乗誤差を平均し，それを成分数ごとに算出する．

4.4 2 値化による領域検出

PLS 回帰によって得られた回帰モデルと説明変数を掛け合わせることで、推定値が得られる。この推定値は 1 に近い画素ほどピーマン領域であると推定され、-1 に近い画素はピーマン領域ではないと推定されている。

そこで推定値と 1 との差の絶対値を取り、それに対し閾値を設定することで大きな外れ値を除外する。その後に残った推定値に対して判別分析法を行い、推定値に対して閾値を設定し、2 値化を行う。

第 5 章

実験

提案手法の有効性を確認するため，MATLAB(R2019a) にて実装し，実験を行う．

5.1 データセット

学習時と評価時で異なる日に撮影されたデータを用いる．画像サイズはどちらも 640×480 画素で，波長 $400 \sim 1000\text{nm}$ 間に 5nm ごと撮影された 121 次元のデータを用いる．学習用データを図 5.1 に示す．6 月 14 日に撮影された 3 枚の画像を用い，合計で画像内に 116075 画素ピーマン果実が含まれており，805525 画素が背景となっている．評価用データは 12 月 19 日に撮影された 54 枚の画像を用いる．

5.2 LPF


提案手法を用いて LPF を適用し，高周波を取り除いた．使用したフィルタを図 5.2 に示す．中心からガウス分布に従って，重みを円形に広がっている．

LPF をかけた結果画像を図 5.3 に示す．ノイズがほぼ取り除かれていることが確認された．

5.3 反射板検出結果

提案手法を用いて評価データから反射板を検出した．図 5.4 に検出に用いた画像と結果画像を示す．54 枚の評価用データのうち全ての画像で正しく反射板の位置を検出できた．

5.3 反射板検出結果



RGB 画像



正解ラベル

図 5.1 学習データ





図 5.2 使用フィルタ

5.3 反射板検出結果



LPF 前画像




LPF 後画像

図 5.3 LPF 結果画像



RGB 画像



検出結果

図 5.4 反射板検出結果

5.4 交差検証結果

PLS 回帰で 10 分割交差検証を行い，成分数での精度を比較した．結果を図 5.5 に示す．図 5.5 より成分数 20 付近で誤差の減少がなくなることが分かった．これにより，この回帰において用いる成分数は 20 個程度が適当であると考えられる．




図 5.5 交差検証の結果

5.5 評価実験

反射率を用いて PLS 回帰と PCR，重回帰分析の 3 種類の手法で作成した回帰モデルと反射率を用いず PLS 回帰で作成した回帰モデルの 4 種類で有効性を比較する．PLS 回帰分析に用いる次元数は交差検証の結果から 20 次元を用いた．PCR も同様に 20 次元を用いて回帰を行った．

5.5 評価実験

また 2 値化手法による結果の比較も行う。

5.5.1 回帰手法評価比較

それぞれの手法で回帰モデルを作成し，回帰手法による結果の比較を行う．反射率を用いた PLS 回帰，PCR，重回帰分析，反射率を用いず PLS 回帰で作成した回帰モデルの 4 種類で推定を行い評価する．PLS 回帰分析に用いる次元数は交差検証の結果から 20 次元を用いた．PCR も同様に 20 次元を用いて回帰を行った．推定された値に対し提案手法 4.4 の手法で 2 値化したものと，正解ラベルとを比べ評価を行う．

それぞれの結果の評価を表 5.1 に示す．評価指標にはクラス分類の正解割合を示す正解率，正解の果実部画素数に対して正しく果実部と分類された割合を示す再現率，果実部と分類された画素数のうち正しい果実部画素であった割合を示す精度，再現率と精度を統合的に評価する F 値の 4 種類の評価指標を用いる．

表 5.1 手法ごとの評価指標

検証法	正解率	再現率	適合率	F 値
反射率 PLS	93.43	77.7	88.78	0.8005
反射率 PCR	89.11	59.7	91.53	0.6638
反射率重回帰	91.81	67.7	89.35	0.7365
非反射率 PLS	50.19	99.5	31.36	0.477

表 5.1 より提案手法は最も高い F 値を示した．適合率ではわずかに PCR，重回帰分析を用いた結果のほうがよかったが，再現率は PLS を用いることで大きく良い結果が得られた．これは他手法より多くの正解画素を検出できたことを示し，より検出の難しい画素まで検出できたことがわかる．また，反射率を用いずに PLS 回帰を行った結果は多くの画素でピーマンであると誤検出しており，反射率を用いている他手法に比べて非常に悪い結果だった．このことより説明変数に反射率を説明変数に用いることで，

表 5.2 に各手法での F 値の個数分布を示す．

5.5 評価実験

表 5.2 手法ごとの F 値の個数分布

検証法	0~0.1	0.1~0.2	0.2~0.3	0.3~0.4	0.4~0.5	0.5~0.6	0.6~0.7	0.7~0.8	0.8~0.9	0.9~1
反射率 PLS	0	1	1	3	0	0	5	6	17	21
反射率 PCR	4	1	5	2	2	1	4	8	19	8
反射率重回帰	2	1	2	0	1	5	4	8	20	11
非反射率 PLS	52	2	0	0	0	0	0	0	0	0

表 5.2 より他手法に比べて提案手法は 0.9 以上の検出画像が多く、0.5 以下の検出画像が少なく、提案手法が多手法に比べて精度の高い検出を行っていることが確認できた。

以下に評価実験に用いた画像と各手法で検出を行った結果画像を示す。画像中の青色の画素は本来果実部であるが、そうでないと分類された画素。赤色の画素は本来果実部でないが、果実部であると検出された箇所を表す。

図 5.6 に提案手法において F 値が 0.8 以上となった結果を示す。これらは良好な結果が得られた。撮影中光量が安定しており、正しく反射スペクトルの推定がなされたためと考えられる。

図 5.7 に提案手法において F 値が 0.8 未満 0.6 以上となった結果を示す。全画素ではないがピーマンの検出はできている。これらの例では撮影されたデータにノイズが目立ち、ピーマン上のノイズが乗っている部分の誤検出が目立っている。

図 5.8 に提案手法において F 値が 0.5 以下となった結果を示す。誤検出箇所が大きく、正しく検出が行えていない。これらの例では撮影途中で光量、光の向きに異常があり、反射板とそれ以外の画素で異なる光源スペクトルとなっている。そのため反射スペクトルの推定がなされなかったと考えられる。光量が非常に低い画像も検出結果がよくなかった。これは全体の強度が小さく、果実とそれ以外で差が出なかったためと考えられる。

5.5 評価実験




図 5.6 提案手法で F 値 0.9 以上の結果画像

5.5 評価実験




図 5.7 提案手法で F 値 0.8 未満 0.6 以上の結果画像

5.5 評価実験



図 5.8 提案手法で F 値 0.4 以下

5.5 評価実験

5.5.2 ROC 曲線による手法評価比較

PLS 回帰分析，PCR，重回帰分析の 3 種類の回帰モデルによる推定を行い，ROC 曲線を求めることでモデルの性能を比較する．

テストデータから得られた推定値に対し，閾値 -2 から 2 まで 0.2 ごとに設定し，2 値化を行い真陽性率，偽陽性率を求め，プロットしたものを図 5.9 に示す．図 5.9 より提案手法である PLS 回帰を用いた回帰モデルは比較手法に比べ左上に位置しており，より優れたモデルであるとわかった．




図 5.9 ROC 曲線

5.5 評価実験

5.5.3 2 値化手法比較

提案手法とその他手法による 2 値化の比較を行う．評価指標は回帰手法の評価で用いたものと同じものを用い，比較する手法は提案手法，閾値を 0 とした 2 値化（PN），判別分析法による大津の 2 値化（Otsu），1 から差分 1.5 以内を 1 とする差分を用いた 2 値化（Sub）の 4 種類を比較し，これらはすべて PLS 回帰を用いた推定値を比較する．表 5.3 に結果を示す．

表 5.3 2 値化手法ごとの評価

2 値化手法	正解率	再現率	適合率	F 値
提案手法	93.43	77.7	88.78	0.8005
PN	91.66	71.02	86.35	0.7264
Otsu	81.74	98.2	61.51	0.7228
差分	86.19	90.21	68.59	0.7364

表 5.3 より提案手法が最も高い F 値が得られた．図 5.10 に正負で正しく分類できなかった例を示す．正負で行った 2 値化の適合率が高いが再現率が低いことから，推定値が 0 以下となっている果実画素も多く存在すると考えられる．図 5.11 に大津の 2 値化で正しく分類できなかった例を示す．データの分離度が大きくなるように閾値を決定する大津の 2 値化の再現率が非常に高く，適合率が低いことから，推定値に含まれるクラスは果実，葉や茎などの果実以外の植物部，それ以外の部分の 3 クラスと分けられ，大津の 2 値化を行うには不十分と考えられる．図 5.12 に差分による 2 値化で正しく分類できなかった例を示す．差分による 2 値化の再現率は大津の 2 値化よりも低く，適合率も大津の 2 値化よりも高いが，まだ十分ではない．提案手法は差分を用いて一度分類することで，大きな外れ値を除くことができ，画像内のクラス数を 2 クラスすることができたため，良好な結果が得られたと考えられる．

5.5 評価実験




図 5.10 正負での2値化で正しく分類されなかった例

5.5 評価実験

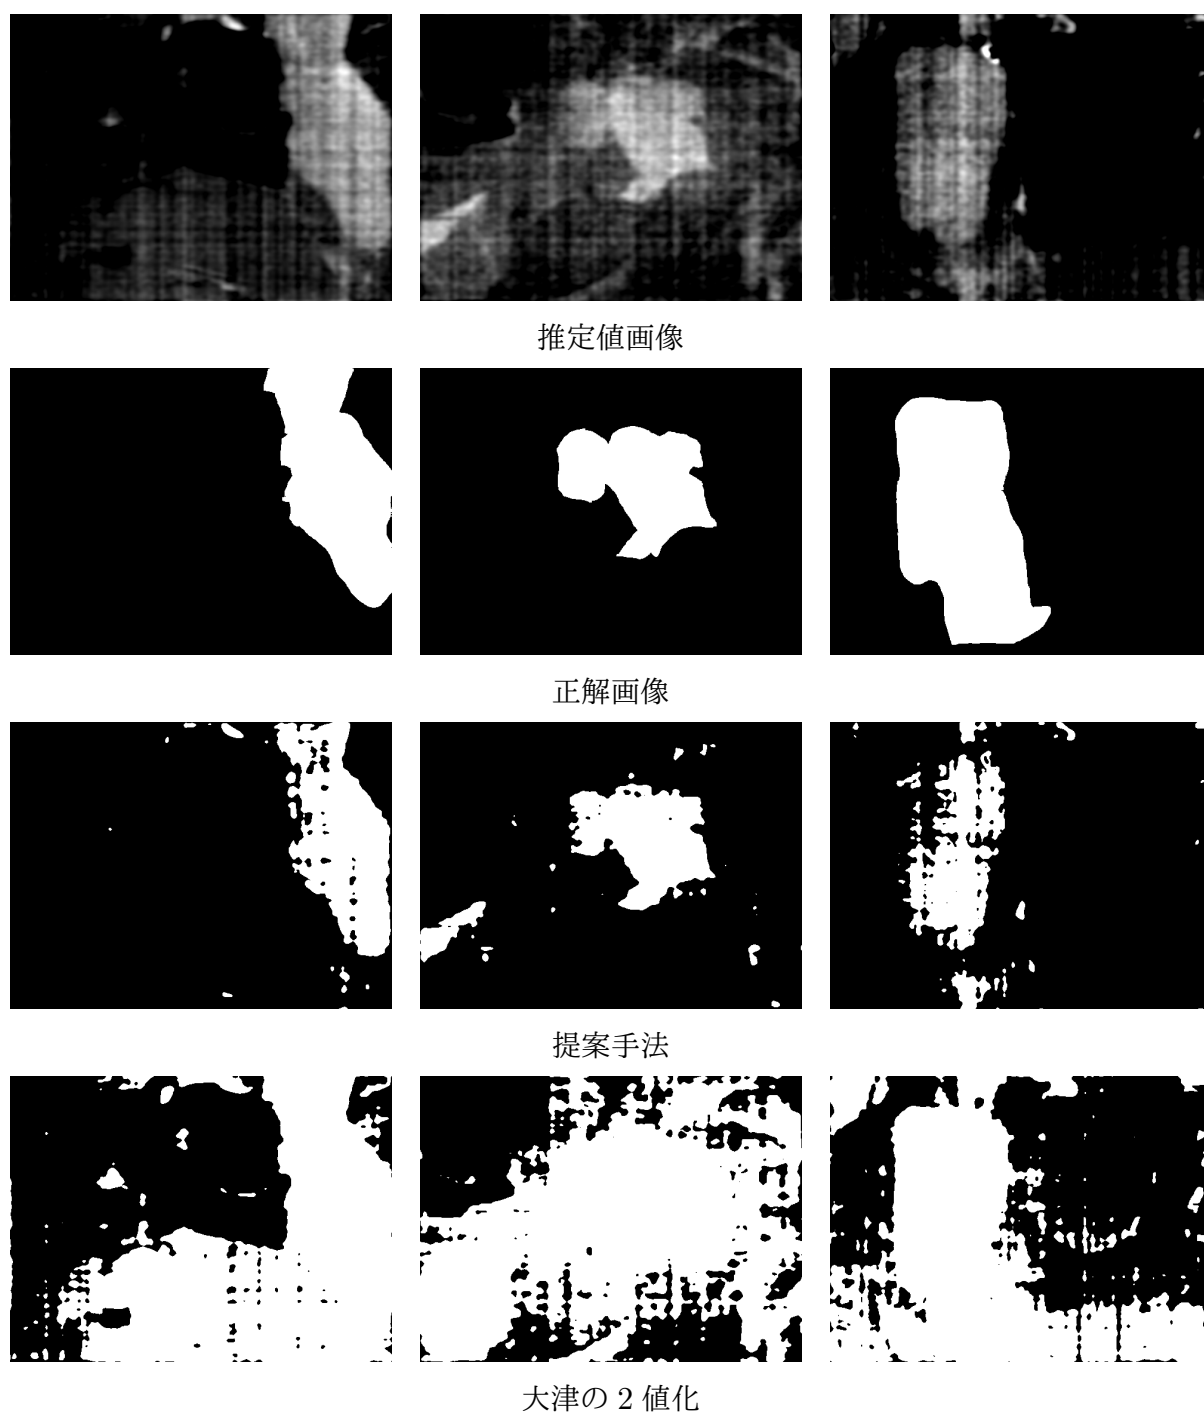


図 5.11 大津の2値化で正しく分類されなかった例

5.5 評価実験

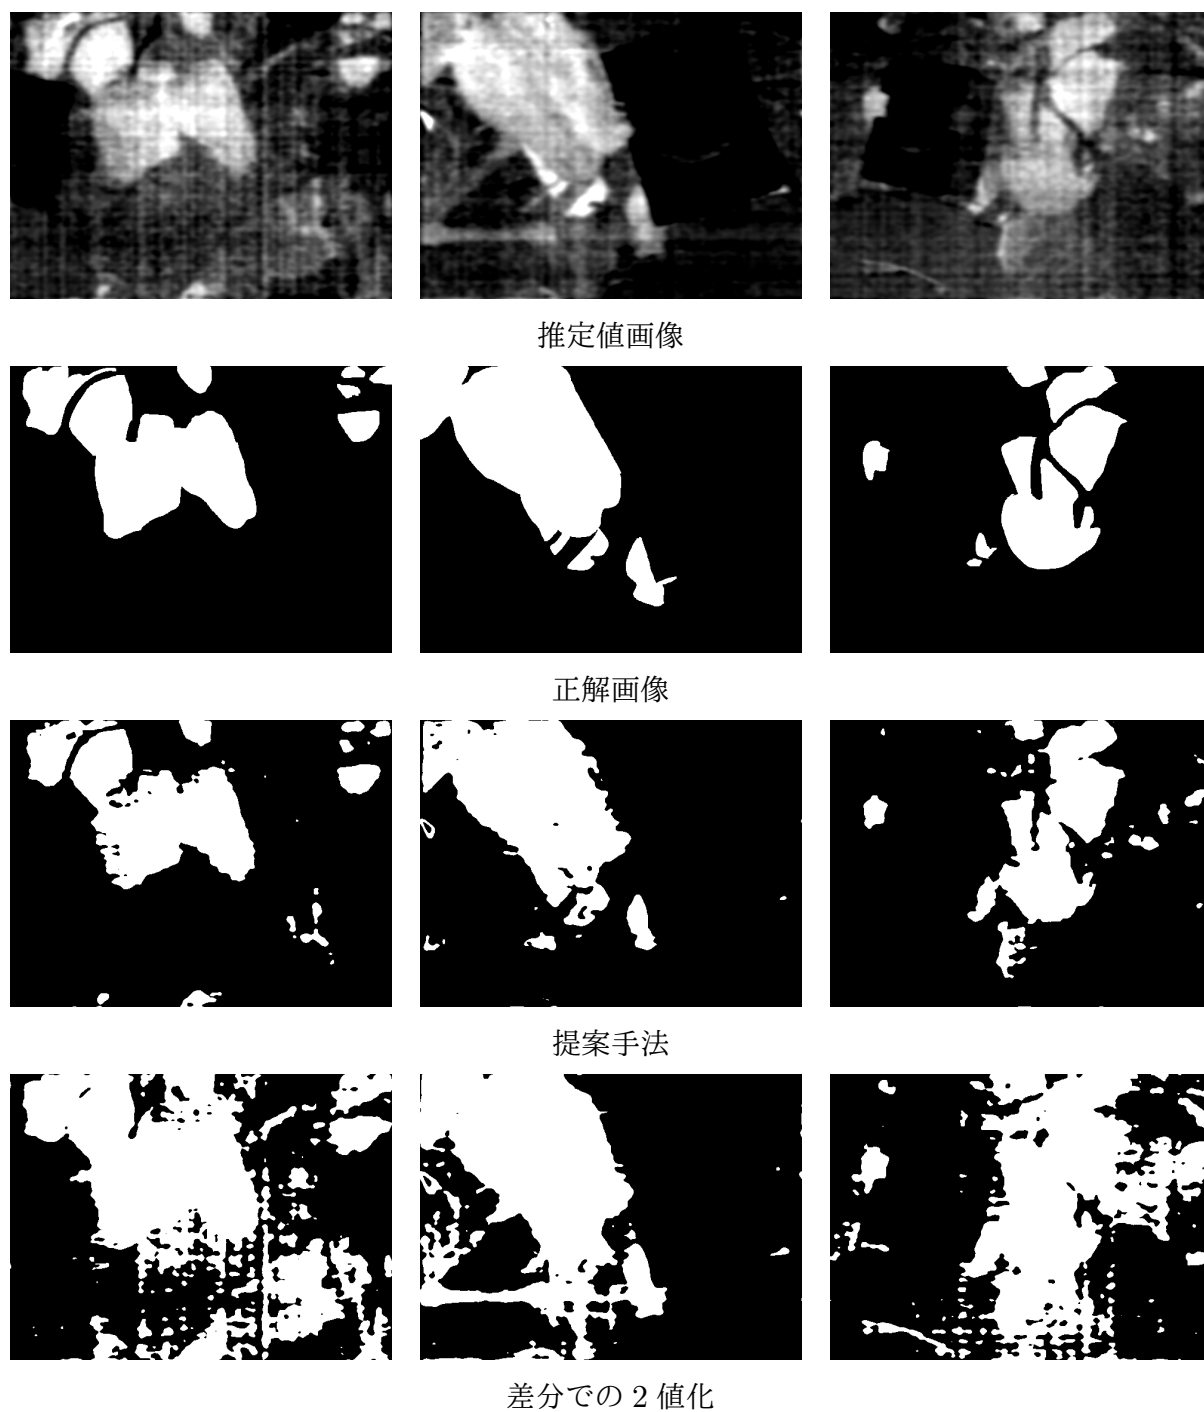


図 5.12 差分での2値化で正しく分類されなかった例

5.5 評価実験

5.5.4 波長ごとの寄与率比較

本手法で行われた回帰モデルより、各波長の寄与率を求め、比較する。

図 5.13 に第 1 成分から第 6 成分まで成分抽出の際に各波長成分に対する重みの比を示す。正の方向への重みが大きいほど、その波長が成分中でピーマン果実の説明に用いられていることを示し、負の方向への重みが大きいほど、その波長が成分中でピーマン果実以外の説明に用いられていることを示している。図 5.14 に第 1 成分から第 6 成分までを用いた PLS 回帰によって作成したモデルを用いて、推定を行った推定値をグレースケール化した画像を示す。

図 5.13 の第 1 成分の寄与率を見ると 400nm から 700nm 付近までの範囲、800nm から 1000nm の範囲では負の重みがあり、それ以外の部分の重みがなかった。図 5.14 の第 1 主成分での回帰モデルを用いた推測結果を見ると、反射板とそれ以外で分類がされている。このことより第 1 主成分の重みは反射板の成分を強く説明していると考えられる。

図 5.13 の第 2 成分の寄与率を見ると 700nm から 900nm 付近までの範囲で大きく正の重みがあった。図 5.14 の第 2 成分までの回帰モデルを用いた推測結果を見ると、植物部とそれ以外のものを分類されている。このことより 700nm から 900nm 付近までの範囲は植物とそれ以外で違いが見られる波長であることが考えられる。

図 5.13 の第 3 成分の寄与率を見るとほとんどの波長で第 2 成分と重みが似ているが、900nm 付近で第 2 成分よりも大きな負の重みがある。図 5.14 の第 3 成分までの回帰モデルを用いた推測結果を見ると、ピーマンの果実部と果実部以外の植物部である葉や茎との差が第 2 主成分までの結果よりも大きくなっている。このことより 900nm 付近の波長帯域は葉と果実の分類に重要な波長であると考えられる。

図 5.13 の第 4 成分の寄与率を見ると 500nm から 600nm までの範囲に特徴的な正の重みが見られる。図 5.14 の第 4 成分までの回帰モデルを用いた推測結果を見ると、第 3 成分までの結果よりも更に葉や茎と果実部の差が大きくなっている。このことより 500nm から 600nm 付近の波長帯域も葉と果実の分類に重要な波長帯域であると考えられる。

5.5 評価実験

図 5.13 の第 5, 6 成分の寄与率を見るとどちらも似た寄与率をしているが, 第 5 成分の寄与率は 400nm から 450nm の波長帯域が正の重みがあり, 第 6 成分の寄与率は 700nm 付近に正の重みがある. 図??の第 5, 6 成分までの回帰モデルを用いた推測結果を見ると, 果実部の推定値がより高く得られている. このことより 400nm から 450nm, 700nm 付近の波長帯域は果実の検出に重要な波長帯域であると考えられる.





図 5.13 成分抽出の際の各波長成分に対する重み比率

5.5 評価実験




カラー画像



正解画像



第 1 成分



第 2 成分



第 3 成分



第 4 成分



第 5 成分



第 6 成分

図 5.14 各主成分までを用いた回帰モデルを用いた推測結果

5.5 評価実験

図 5.15 に第 20 成分までを用いて回帰を行った結果から算出された V I P 値のグラフを示す。図 5.15 のように 400nm, 550nm, 750nm から 900nm, 1000nm 付近で高い V I P 値が得られ、この回帰においてこれらの波長帯域が重要であるとわかった。




図 5.15 第 20 成分までを用いた回帰の V I P 値

これらのことからピーマン果実の検出では 400nm, 550nm, 700nm から 900nm, 1000nm 付近の波長帯域で、他領域と果実部との差があり、これらの波長帯域に着目することで使用波長数の削減が期待される。

第 6 章

まとめ

本研究では、ハイパースペクトルカメラで撮影されたマルチバンド画像から標準反射板を検出、反射率を計算し、反射率を説明変数とした PLS 回帰を用いてピーマン果実部を分類する回帰モデルを作成し、得られる推定値 2 値化することで検出を行うピーマン果実の検出手法を提案した。

評価実験の結果、提案手法は正答率 93.43 %，F 値 0.8005 という評価が得られ、他回帰手法、反射率を用いずに PLS 回帰を用いた方法のいずれよりもよい結果を示した。F 値の個数分布を確認すると、提案手法は画像 54 枚中 38 枚で 0.8 以上の F 値が得られ、多手法より多くの画像で良好な検出を行っていることを確認した。しかし光量に画像内で大きな変化のある画像やノイズが多く含まれる画像は良好な検出が得られなかった。また推定値の 2 値化手法を比較したところ提案手法は他手法に比べ、より正確な分類がなされていた。

今後の課題として、光量が大きく違う場合でも良好に検出すること、LPF でも除去できないノイズの対策が挙げられる。また、ハイパースペクトルカメラは高価であるため、安価での社会実装が難しい。そこで回帰に使用される最適な波長を選択し、安価なマルチバンドスペクトルカメラや赤外線カメラ等でも実現することができれば社会実装が進みやすいと考えられる。

謝辞

研究活動を進める中で多大なご指導を頂いた栗原徹准教授に感謝いたします。また，副査を引き受けてくださった福本正弘教授，吉田真一准教授にも感謝いたします。高知農業技術センターの皆様には生育中の野菜の撮影や研究の協力など，度々お邪魔しました。ここに深く感謝申し上げます。また共に農業関連の研究を行い，過酷な撮影に同行していただいた大平合氏，窪田伊織氏をはじめとする，高知工科大学画像情報工学研究室の面々に深く感謝いたします。

参考文献

- [1] S. Wold, M. Sjöström, L. Eriksson : PLS-regression: a basic tool of chemometrics, Chemometrics and Intelligent Laboratory Systems, 58, 2001, p109.
- [2] Aniruddha Kembhavi, Larry S. Davis, David Harwood : Vehicle Detection Using Partial Least Squares, IEEE Trans of PAMI, 33, 6 , 2011, p.109.
- [3] 大津展之, ” 判別および最小 2 乗基準に基づく自動しきい値選定法 ”, 電子通信学会論文誌, D J63-D-4, 1980, pp.349-356
- [4] R.Teofilo, J.P.A.Martins, M.M.C.Ferreira : Sorting variables by using informative vectors as a strategy for feature selection in multivariate regression, J.Chemometrics, 23, 2009, 32
- [5] 竹内 佑介, 大野 努, 青柳 賢英, 野呂 直樹, 佐鳥 新, “ ハイパースペクトル技術による異物検出 ”, 可視化情報学会誌, 28-1, 2, 2008, p.1189
- [6] 安部 久, 渡辺 憲, 石川 敦子, 能城 修一, 藤井 智之, 岩佐 光晴, 金子 啓明, 和田 浩, “ 近赤外分光法を用いた木彫像用材の非破壊的な樹種識別－木材標本を用いた分析－ ”, 木材保存, 41, 4, 2015, p.162
- [7] 枝長 孝幸, 宇都 有昭, 小杉 幸夫, “ 短波長赤外領域スペクトル情報を用いた人肌領域抽出に関する研究 ”, 写真測量とリモートセンシング, 46, 2, 2007, pp.17-26
- [8] 服部 哲也, 加藤 邦人, “ PLS 回帰分析を用いた近赤外光物質判別及び最適波長選択手法 ”, 精密工学会誌, 83, 2, 2017, pp.158-166
- [9] 太田 智彦, 林 茂彦, 久保田 興太郎, 安食 恵治, 米田 隆志, 大塚 庄一郎, 鏡面反射を利用したトマト果実の検出システム, 農業機械学会誌, 67, 6, 2005, pp.95-104
- [10] 有馬 誠一, 近藤 直, 八木 洋介, 門田 充司, 吉田 裕一, 高設栽培用イチゴ収穫ロボット (第 1 報)5 自由度マニピュレータを用いた収穫ロボット, 植物工場学会誌, 13, 3, 2001, pp.159-166

参考文献

- [11] 林 茂彦, 雁野 勝宣, 黒崎 秀仁, 有馬 誠一, 門田 充司, V 字型整枝されたナスを対象としたロボット収穫システム (第 1 報) システム構成と果実検出, 植物工場学会誌, 15, 4, 2003, pp.205-210
- [12] 庄野 浩資, 天羽 弘一, 高倉 直, 画像処理によるキュウリ果実の位置検出, 農場気象, 45, 2, 1989, pp.87-92
- [13] iroshi Okamoto, Won Suk Lee : Green citrus detection using hyperspectral imaging, Computers and Electronics in Agriculture, Volume 66, 201/208 (2009)
- [14] Yongjun Ding, Won Suk Lee, Minzan Li : Feature extraction of hyperspectral images for detecting immature green citrus, Frontiers of Agricultural Science and Engineering, Volume 5, 475/484 (2018)