

一 般 論 文

Regular Paper

ハイパースペクトルカメラを用いた 作物病害判別に有効な分光反射特性の解析

本間 稔規, 岡崎 伸哉, 山名 利一*

Analysis of Spectral Reflection Characteristics for Detecting Crop Diseases using Hyperspectral Camera

Toshinori HONMA, Shin'ya OKAZAKI, Toshikazu YAMANA*

抄 録

農作物の生育管理において病害の発生は農作物の収穫量や品質に大きく影響するため、発生状況を確認し適切な対策を取ることが重要である。病害を判別できる熟練農業従事者の減少が進む中で、目視確認作業の重要性はIPM（総合的病害虫管理）の普及とともにさらに高まってきている。一方、可視光から近赤外光の波長範囲の分光画像を一度に網羅的に撮影可能な可搬型のハイパースペクトルカメラが開発され、これまで難しかった屋外での分光計測が可能になってきている。このハイパースペクトルカメラを用いることで、人の目では判別しづらいわずかな色の差や、可視光より波長の長い近赤外光領域の情報が得られるため、より高度な病害虫被害検出への応用が期待されている。本研究では、ハイパースペクトルカメラで撮影したデータに対して機械学習を適用し、作物病害を判別する技術を開発した。りんごの腐らん病やてん菜の褐斑病に適用し、良好な結果が得られた。

キーワード：ハイパースペクトルカメラ, 機械学習, りんご腐らん病, てん菜褐斑病

Abstract

In crop management, proper actions for preventing crop damage by pests and diseases are important. Without those actions, the yield and the quality of agricultural products are severely affected. Although the population of skilled farmers with ability of discriminating crop disease decrease, the role of visual inspection become more important to make integrated pest management (IPM) to put into practical use. In recent years, handheld hyperspectral cameras capable of acquiring spectral images from visual range to near infrared (NIR) has been developed and commercialized. These hyperspectral imaging devices are expected to be utilized in agricultural fields for detecting crop damage by pests and diseases those are not inspected easily. In this study, we developed a technology to discriminate crop damage by pests and diseases by analyzing the data from hyperspectral camera with machine learning techniques. We obtained good results by this technology at detecting apple Valsa canker and Cercospora leaf spot of sugar beet.

KEY-WORDS : Hyperspectral camera, Machine learning, apple Valsa canker, Cercospora leaf spot of sugar beet

1. はじめに

農作物の生育管理において病害の発生は農作物の収穫量や品質に大きく影響するため、発生状況を確認し適切な対策を取ることが必要である。病害を判別できる熟練農業従事者が減少する一方、IPM（総合的病害虫管理）の普及に伴い目視確認作業の重要性はますます高まってきている。IPMに

よる管理では予防、判断、防除の3つのアクションが基本である。

予防、防除では様々な手段が用意されているが、「判断」については、最終的に農家による現場確認に大きく依存しており、IPMを効果的に運用する上での課題となっている。一方、可視光から近赤外光の波長範囲の分光画像を一度に網羅的に撮影可能な可搬型のハイパースペクトルカメラが開発

*道総研中央農業試験場, Central Agricultural Experiment Station, Hokkaido Research Organization

事業名：経常研究（理事長枠）

課題名：ハイパースペクトルカメラを用いた作物病害虫被害判別に有効な分光反射特性の解析

され、これまで難しかった屋外での分光計測が可能になってきている。このハイパースペクトルカメラを用いることで、人の目では判別しづらい色の差や、見ることができない近赤外光領域の情報が得られるため、より高度な病害虫被害検出への応用が期待されている¹⁾。本研究では、農作物の病害をハイパースペクトルカメラで撮影し、そのデータを解析することにより病害検出を行う技術を開発した。

2. ハイパースペクトルカメラ

圃場での農作物のハイパースペクトルデータ収集にはハイパースペクトルカメラSpecim IQ (SPECIM, SPECTRAL IMAGING LTD.製) (図1)を用いた。波長範囲は400~1000nm、波長分解能7nmである。1回の撮影で取得できるハイパースペクトルデータのサイズは512×512×204 (空間x軸, 空間y軸, 波長軸)であり、カメラ内部に駆動機構を備えたラインスキャン方式で撮影され、ENVI (Environment for Visualizing Images) 形式で保存される。データ取得時間は撮影環境の明るさにより10~30秒程度を要するため、基本的に撮影時は三脚が必要である。



図1 ハイパースペクトルカメラ Specim IQ

3. データ収集を行った作物／病害

作物病害と防除方法を表1に示す。防除方法は作物病害の


表1 作物の病害と防除方法
(着色した項目は本報告中に記載した作物／病害)

作物	病害	病害個体のサンプリング	対策
てん菜	褐斑病	健全個体に病原菌を接種	発病前から薬剤散布
馬鈴しょ	疫病	健全個体に病原菌を接種、または、まん延ほ場に設置したポット苗	発病前から薬剤散布
小麦	うどんこ病	圃場での自然発生個体	小麦の抵抗性と生育時期に対応した薬剤散布
小麦	赤さび病	圃場での自然発生個体	小麦の抵抗性と生育時期に対応した薬剤散布
てん菜	ヨトウガ被害	圃場での自然発生個体	被害株率50%で薬剤散布
馬鈴しょ	モザイク病	圃場での自然発生個体、または、ポット苗にウイルスを接種	発見次第、罹患個体を除去
りんご	腐らん病	圃場での自然発生個体	発生部位を物理的に削り取る
りんご	黒星病	圃場での自然発生個体	発病前から薬剤散布

種類により異なる。表1に示す作物／病害のうち、てん菜／褐斑病、馬鈴しょ／疫病、馬鈴しょ／モザイク病、小麦／うどんこ病、小麦／赤さび病については、伝染のしやすさから発病前、あるいは発病初期において判別すべき病害であるため、健全な作物に対し、病原菌、あるいはウイルスを接種して時系列でのデータ取得を行った。

りんご／腐らん病、りんご／黒星病、てん菜／ヨトウガ被害については、伝染速度は速くないため発生状況に応じて対応することが可能な病害である。そのため、これらについては圃場での自然発生個体を対象とした。

以上のように、本報告では病変部検出の解析対象として、てん菜／褐斑病とりんご／腐らん病を取り上げた (図2)。



てん菜／褐斑病 りんご／腐らん病
図2 データ収集を行った作物／病害の一部

4. 圃場におけるハイパースペクトル撮影の最適化

ハイパースペクトルカメラで圃場の作物を撮影する場合、様々な要因によりハイパースペクトルデータの品質が低下する可能性がある。屋外撮影においては天候による日射の変動や風による作物の揺動が大きく影響すると考えられる。そこで本研究では、撮影対象の作物の葉に入射する太陽光角度の影響についての評価、また、風による葉の揺動の補正方法についての開発を行った。

4.1 葉に対する入射光角度の影響の評価

曇天や快晴など、天候の変化による太陽光照明の変動 (分光放射特性、拡散特性) が圃場で取得するスペクトルデータに影響を及ぼす。特に、葉のスペクトル情報の多くは拡散反射成分に含まれ、光源の影響が支配的になる正反射成分にはほとんど含まれない。快晴の場合は正反射成分が多くなることから、スペクトル品質が低下することが考えられる。そこ



図3 イメージング分光器とEM-CCDカメラ

で、葉に入射する光線の角度の違いがスペクトルデータに与える変動について評価を行った。この実験は、室内に設置した、光学系の条件を制御可能な装置を用いて行った。実験装置の検出部の分光測定装置としてイメージング分光器 (Specim Inspector V10C) と高感度 EM-CCD カメラ (Andor Technology DL-658M) を用いた (図 3)。照明にはハロゲンファイバー光源を使用し、光源の射出部にテレセントリックイルミネータを配置してサンプルに平行光を照射する構造とした。ハロゲンファイバー光源とイメージング分光器の光学系は拡散反射測定で一般的に用いられる 45° 照明・0° 受光の光学系とした (図 4)。




図 4 計測光学系

計測に用いる葉は表面が平らになるようにサンプルステージに挟んで固定した (図 5)。サンプルステージは照明の光軸とイメージング分光器の光軸の交点を中心とし、照明の光軸に対して垂直な軸 (図 4 において紙面に垂直方向) 周りをステッピングモータによる駆動機構により角度を 0° (水平位置) から 45° まで 5° ずつ回転させて計測した。計測サンプルには光沢が弱い馬鈴しょ (品種: スノーマーチ) と光沢が強いてん菜を用いた (図 6)。角度に対する吸光度の変化を図 7 に示す。この図より、角度が 22.5° 付近 (図中の矢印部分) で吸光度が最小となった。吸光度が小さくなるということはすなわち反射率が大きいということであり、光沢の高いてん菜の方がより顕著であった。




図 5 サンプルステージの構造




図 6 計測サンプル
(左: 馬鈴しょ, 右: てん菜)




図 7 葉面への入射光の角度を 0°~45° で変更して計測した吸光度
(左: 馬鈴しょ, 右: てん菜)

次に、光の入射角度の変化に対する葉の吸光度スペクトルへの影響について評価した。比較対象として、0° (水平位置) のサンプルステージにおける葉面中心付近の 121 スペクトルの平均吸光度とその標準偏差を用いた。馬鈴しょの結果を図 8 に、てん菜の結果を図 9 に示す。図 8 に示す馬鈴しょでは葉面に対する光の入射角度を変えた場合と葉面中心の 121 スペクトルとでわずかに差があるものの、スペクトルの形状は類似していた。一方、図 9 に示すてん菜については、葉面に対する光の入射角度を変化させて取得したデータの方が平均の吸光度スペクトル、標準偏差ともに大きく変化した。




図 8 葉面への入射光角度を変更して計測した平均吸光度と標準偏差 (馬鈴しょ)




図 9 葉面への入射光角度を変更して計測した平均吸光度と標準偏差 (てん菜)

これは、馬鈴しょの場合はほとんど拡散反射成分の吸光度となっているためであり、てん菜の場合は光沢が強いため、拡散反射成分よりも正反射成分の影響が大きくなったのが原因と考える。以上より、光沢の弱い馬鈴しょの葉の場合は快晴時でもスペクトル品質の低下は少ないが、光沢の強いてん菜の場合はスペクトルの誤差が大きくなるため、葉の成分の非

破壊定量分析への影響も大きくなることがわかった。しかし、いずれの場合もスペクトルのピーク位置は変わらないため、病害判別の目的では日射角度の影響は少ないと考えられる。

4.2 風による葉の揺動の影響

ハイパースペクトルカメラでは1フレームの撮像で空間軸と波長軸の2次元のデータを取得する。これを先の空間軸に対して直交する方向にスキャンすることで2次元の空間軸と波長軸で構成される3次元のハイパースペクトルデータを得る。Specim IQの場合、空間軸(図10の画面の縦ライン)を右から左にスキャンさせてハイパースペクトルデータを取得する。そのため、データ取得開始から完了までには時間を要する。Specim IQの撮像時間は照明環境にも依存し10~30秒程度かかることから、圃場での撮影では風による葉の揺動により正確なデータ取得が困難となる。

そこでSpecim IQのファインダー用カラーカメラの画像と、ハイパースペクトルデータから生成した画像間でagast画像特徴量²⁾によりマッチングを行い、2つの画像間の対応点を求めた(図11)。その対応点の座標から変換行列を求め、抽出した葉の輪郭部分の領域が重なるように補正する手法を開発した(図12)。しかし、揺動の方向がスキャンする方向と平行である場合、スキャンの向きと反対側に葉が動くとその部分のデータは取得できず、一方でスキャン方向と同じ側に葉が動くとその同じ部分のデータが連続して取得されることになるため、その方向の動きに関しては補正が困難であることがわかった。この影響を低減する方法として、圃場での撮

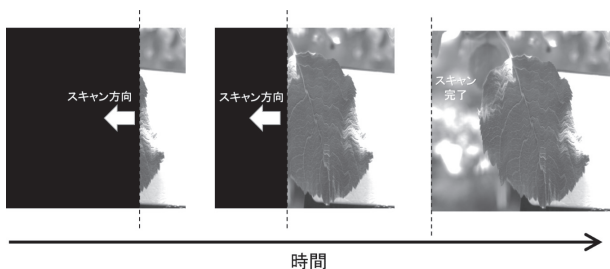


図10 ハイパースペクトルカメラのデータ取得



図11 ハイパースペクトルデータから生成した画像とファインダ画像の特徴量

影時に対象作物の左右に防風用の板を配置すること、さらに、日射以外の照明を追加することで撮影速度を向上させることなどが考えられる。




図12 風の揺動による葉のずれを補正

5. 機械学習による作物病害判別

作物の病害を判別する機械学習手法として、取得可能なデータセットの内容により、「教師あり学習」または「教師なし学習」の2通りの手法を適用できる。教師あり学習の場合は正解値のラベルが付与されたデータセットが必要である。一般的に、ばらつきが多いデータやハイパースペクトルデータ(204波長の多変量データ)のように変数(波長数)が多い多次元データの場合、判別精度を高めるためにはラベルごとに多数のデータが必要となる。一方、教師なし学習は入力データのみから機械学習モデルを作成する方法であり、データに内在する本質的な構造を抽出するために用いられる。多数の正常なデータの中から少数の異常データを検出する異常検知では、多数の正常データの構造を抽出することで、正常とは構造が異なる異常値を判別することができる。

今回対象とするりんごの腐らん病については病変部に一定の大きさがあり、多数の病変部データが得られる。このことから、教師あり学習の手法であるランダムフォレスト⁴⁾を用いて病変部判別モデルを開発した。一方、てん菜の褐斑病については、葉に発生する初期の病変部がスポット状であり、それ以外のほとんどの部分が正常である。このように病変部の教師データがわずしかか得られないため、ランダムフォレストのような教師あり学習の適用は難しい。そこで正常データのみを用い、教師なし学習手法の主成分分析(Principal Component Analysis³⁾、以下、PCA)をベースとした異常検知アルゴリズムによる病変部判別モデルを開発した。

5.1 ランダムフォレストによるりんご腐らん病検出

りんご樹木の枝や幹に発生する腐らん病について、2019年から2021年に中央農業試験場において収集したハイパースペクトルデータを用いて病変部判別モデルの開発を行った。教師データは、目視で確認した病変部の位置をハイパースペク

トルデータと同時に撮影されるカラー画像にマーキングすることにより作成した。そのマーキング部位を参照し、病変部に含まれる領域の一部を病変部位として指定した。また、対照として、健全部の一部の領域を健全部位として指定した。図13に示す2019年5月29日のデータでは、健全部、病変部それぞれ951スペクトル、726スペクトルを取得できた。教師データとして健全部、病変部の吸光度（図14、15）もしくは吸光度の二次微分スペクトルを用い、ランダムフォレストにより判別モデルを構築した。この判別モデルにより健全部と病変部を判別した結果を図16に示す。吸光度スペクトル、吸光度二次微分スペクトルのどちらを用いても健全部、病変部の検出ができた。このりんご腐らん病の判別モデルについては、教師データ以外の未知サンプルの樹木に対しても良好に判別できることを確認した。

以上の結果から、ハイパースペクトルカメラによりりんご腐らん病の検出が可能であることがわかった。今後、現場への普及を進めていくためにはコストの低減化とデータ取得時間の短縮化、さらに使いやすさが課題となる。低コスト化をはかる方法として、多眼式分光イメージングセンサ³⁾のような複数の分光画像を取得するマルチスペクトルカメラを用いる方法がある。りんごの腐らん病に対して数バンドの波長で十分な検出能力が得られるのであれば低コスト化、リアルタイム化を実現することが可能となる。そこで、ランダムフォレストによる判別モデル構築過程で求められる、特徴量の重要度（feature importance）を用いて、病変部判別に寄与する波長を調べた。その結果、660～750nmの間の波長領域の寄与が大きく、それ以外の波長領域の寄与は小さいことがわかった（図17）。この波長領域のみの吸光度二次微分スペクトルを入力データとして使い、改めてランダムフォレストにより判別モデルを構築したところ、全ての波長を使った場合と同様の結果が得られた（図18）。以上の結果からマルチスペクトルカメラによるシステム構築の可能性が得られた。

5.2 異常検知手法によるてん菜褐斑病の検出

てん菜褐斑病などの防除では、遅くとも発病（病斑発生）直後すぐに薬剤を散布しなければならないため、病斑発生の初期か、あるいは発病前に予測できることが望ましい。発病部位は元々健全な葉であること、また発病初期には病斑部の数が少なく訓練用のデータセットの作成が難しいことから、教師なし学習のPCAによる異常検知の手法を用いた。てん菜の褐斑病のサンプルについては、病原菌を健全な葉に接種して作成した。発病前から時系列でハイパースペクトルデータを収集し、病斑部の初発以前の段階から病斑部の検出が可能かを試みた。供試したてん菜（図19）では2021年10月29日に最初の病斑部が発生し、続いて11月1日、11月2日に発生した（図20）。今回のサンプルでは図21の白枠で囲んだエリア（10月29日に発生した部位）を対象に解析を行った。解析で




図 13 りんご樹木の健全部と病変部の位置を指定




図 14 りんご樹木病変部全体の吸光度スペクトル（左）
吸光度二次微分スペクトル（右）




図 15 りんご樹木健全部全体の吸光度スペクトル（左）
吸光度二次微分スペクトル（右）



図 16 ランダムフォレストによる健全部と病変部の判別結果
（左：吸光度スペクトルによる結果）
（右：吸光度二次微分スペクトルによる結果）

は、大部分が健全部である葉のスペクトルデータをPCAにかけ、主成分スコアを求める。大部分を占める健全部は性質が似ているため、そのスコアは一定のクラスタを形成する。一方、健全部と性質が異なる病斑部のスコアは健全部のクラスタから離れた位置に形成される。健全部と病斑部のスコアを判別するには、適切な識別境界面を設定することが必要で




図 17 各サンプルについてランダムフォレストで求めた特微量の重要度の重複部分の波長を選択



図 19 てん菜サンプル




図 18 660 ~ 750nm の波長範囲のデータについてランダムフォレストで予測した病変部位 (上: 2019年5月29日のデータ, 下: 2021年6月16日のデータ)




図 20 褐斑病の病斑部の位置と初発日

ある。この識別境界面は1-class SVM (サポートベクターマシン)⁶⁾、Local Outlier Factor (LOF: 局所外れ値因子法)⁷⁾の2通りの手法を用いて求めた (図22)。以上の処理を病斑の発生以前の10月21日のデータに対して行ったところ、これから病斑が発生する位置では異常は検出できなかったが (図23左)、病斑発生後の11月3日のデータに対しては検出することができた (図23右)。今回のてん菜の褐斑病については、1-class SVMでは病斑部以外の箇所も検出しているが、LOFの場合は病斑部分を正確に検出していることから、1-class SVMよりもLOFの方が高精度な結果が得られた。以上から、病斑部は初発の小さい状態から検出可能であったが、病斑部発生以前の検出は困難であることがわかった。



図 21 病斑部検出対象の領域を設定 (白枠で囲んだ領域)




図 22 PCA および LOF を適用して異常部位を検出 (図中の黒丸部分が異常部位)

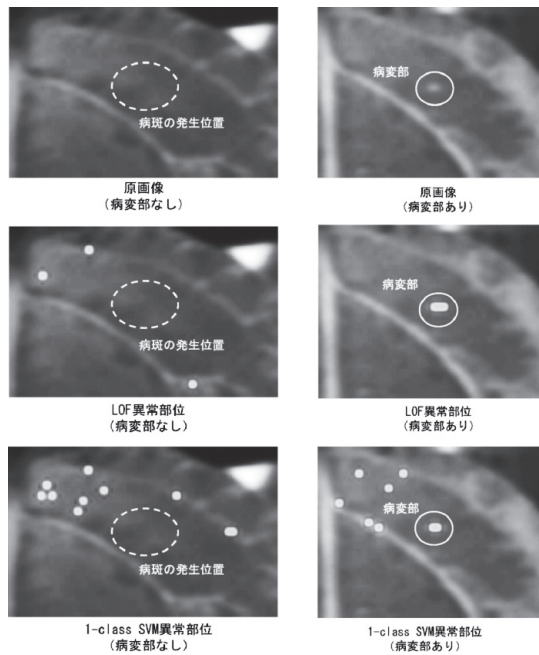


図23 てん菜褐斑病の検出結果
 左：病斑発生前、右：病斑発生後
 図中の白い部分が病斑と判別した位置

6. おわりに

可搬型のハイパースペクトルカメラを用いて作物病害虫被害の判別手法の開発を行った。圃場でのデータ収集の最適化については、ハイパースペクトルデータの品質低下につながる日射の影響の評価と、風による作物の揺動により生じる空間軸でのスペクトルデータの位置ずれを補正する技術を開発した。さらに、病変部の面積が大きく、健全部と病変部の両方を含んだ教師データが用意できる対象に対しては教師あり学習のランダムフォレスト、また病変部のデータが少ない対象に対しては教師なし学習のPCA、1-class SVM、LOFなどを用いた病変部判別手法を開発した。さらに、これらの手法をりんごの腐らん病やてん菜の褐斑病に適用し、良好な結果が得られた。

ハイパースペクトルカメラが小型化されたことで農業現場での応用が可能となってきたが、普及を進めるには未だ高価である。今後は本研究で得られた知見をもとに、判別に重要な波長範囲を絞り込み、複数波長のバンドパスフィルタを搭載した現場向けのマルチスペクトル検査装置の開発へと展開していく予定である。

引用文献

1) Behmann, J., Acebron, K., et.al, Specim IQ: Evaluation of a New, Miniaturized Handheld Hyperspectral Camera and Its Application for Plant Phenotyping and Disease Detection. Sensors

(2018), 18, 441.
 2) Mair, E., Hager, et.al, Adaptive and generic corner detection based on the accelerated segment test. Computer Vision ECCV (2010), Springer, 183-196.
 3) Wold, Svante, Kim Esbensen, and Paul Geladi. "Principal component analysis." Chemometrics and intelligent laboratory systems 2.1-3 (1987) : 37-52.
 4) Breiman, Leo. "Random forests." Machine learning 45.1 (2001) : 5-32.
 5) 本間稔規, 岡崎伸哉, 他: 食品検査用分光イメージングシステムの開発, 北海道立総合研究機構工業試験場報告 No.315 (2016)
 6) B. Schölkopf, A. Smola, et.al, New support vector algorithms. Neural Computation, 12,(2000), 1207-1245.
 7) Breunig, Markus M., et.al, "LOF : identifying density-based local outliers." Proceedings of the 2000 ACM SIGMOD international conference on Management of data. (2000)

